




DOI: 10.12086/oe.2021.210040

混合梯度稀疏先验约束下的 图像盲复原

徐宁珊^{1,2}, 王琛³, 任国强^{1*}, 黄永梅¹¹中国科学院光电技术研究所, 四川 成都 610209;²中国科学院大学, 北京 100049³航天系统部装备部军代局成都室, 四川 成都 610041

摘要: 图像盲复原旨在无参考的情况下准确估计模糊核并恢复潜在的清晰图像。现有研究表明, 利用全变分模型对高阶图像梯度先验约束进行描述可以有效抑制复原图像中产生的阶梯效应。本文在实验观察和研究的基础上, 提出了采用稀疏先验约束模型对盲复原过程进行正则化的方法, 以获得更佳的图像复原效果。该方法利用图像高阶梯度的稀疏性, 通过与低阶梯度相结合来构造混合梯度正则项。同时, 在正则项中引入基于图像熵的自适应因子, 来调节迭代优化过程中两类梯度先验的比例, 以此获得更好的收敛性。仿真与实验证明, 与现有图像盲复原先进方法相比, 本文方法具有更优越的图像复原性能。

关键词: 图像盲复原; 高阶梯度; 稀疏先验; 自适应加权

中图分类号: TP391.41

文献标志码: A

徐宁珊, 王琛, 任国强, 等. 混合梯度稀疏先验约束下的图像盲复原[J]. 光电工程, 2021, 48(6): 210040

Xu N S, Wang C, Ren G Q, et al. Blind image restoration method regularized by hybrid gradient sparse prior[J]. *Opto-Electron Eng*, 2021, 48(6): 210040

Blind image restoration method regularized by hybrid gradient sparse prior

Xu Ningshan^{1,2}, Wang Chen³, Ren Guoqiang^{1*}, Huang Yongmei¹¹Institute of Optics and Electronics, Chinese Academy of Sciences, Chengdu, Sichuan 610209, China;²University of Chinese Academy of Sciences, Beijing 100049, China;³Chengdu Office of Military Representative Bureau of Equipment Department of Aerospace System Department, Chengdu, Sichuan 610041, China

Abstract: Blind image restoration aims to accurately estimate the blur kernel and the wanted clear image with no-reference. Existing researches show that the use of the Total Variation to model the high-order image gradient prior constraints can effectively suppress the blocking artifact generated in the restored image. On the basis of experimental observation and research, this paper proposes to use the sparse prior constraint model to regularize the blind restoration process to obtain a better image restoration performance. Our method makes use of the sparsity of

收稿日期: 2021-01-27; 收到修改稿日期: 2021-05-06

基金项目: 国家重点研发计划资助项目(2016YFB0500201)

作者简介: 徐宁珊(1994-), 女, 博士研究生, 主要从事无参考图像质量评价及图像复原技术的研究。

E-mail: xuningshan16@mails.ucas.ac.cn

通信作者: 任国强(1971-), 男, 博士, 研究员, 主要从事光电成像领域信号与信息处理、电子与通信工程的技术的研究。

E-mail: renguoqiang@ioe.ac.cn

版权所有©2021 中国科学院光电技术研究所

the high-order gradient of the image and combines it with the low-order gradient to construct the mixed gradient regularization term. At the same time, an adaptive factor based on image entropy is introduced to adjust the ratio of the two types of gradient priors in the iterative optimization process so as to obtain better convergence. Simulated and experimental results prove that compared with the existing state-of-the-art methods of blind image restoration, the proposed method has superior image restoration performance.

Keywords: blind image restoration; high-order gradient; sparse prior; adaption

1 引言

数字图像在成像、存储及传输等环节会受到不同形态的图像退化, 主要包括离焦模糊、运动模糊、噪声污染等。这些退化因素造成图像质量下降, 从而影响后续图像理解、图像解译等应用。因此, 为了对退化图像的质量进行提升, 提高其应用价值, 需要进行图像复原处理。实际上, 在卫星遥感、医疗、天文等诸多领域, 由退化图像来恢复原始信息一直是非常重要的问题, 长期以来受到了广泛地关注和研究。

图像退化过程的一般形式可描述为

$$g = f * h + n, \quad (1)$$

其中: h 表示点扩展函数(point spread function, PSF), 又称模糊核; n 表示随机噪声; g 表示降质图像。图像复原的目的是从观测图像 g 恢复出潜在清晰图像 f 。根据图像退化的模糊核是否已知, 图像复原技术可分为非盲复原和盲复原两类。早期的图像复原技术主要围绕模糊核已知的非盲复原展开, 然而在大多数实际工程应用中, 我们无法获得模糊核的准确信息, 因此非盲复原方法在实际应用中受到极大的限制, 而盲复原得到了研究者们越来越多的关注。本文对图像盲复原进行研究, 复原过程中同时对模糊核和清晰图像进行估计。

1.1 研究现状

现有的图像盲复原研究成果主要集中于传统的迭代优化框架, 通过利用各类不同的图像先验和模糊核先验来对迭代估计过程进行约束。尤其是稀疏先验约束模型, 在近年来受到专家学者们的广泛关注和研究, 相关成果也证明了稀疏先验在图像盲复原问题上的优越性^[1-10]。

图像梯度是常用的稀疏先验之一, 其主要利用自然图像梯度分布的稀疏性。最早由 Weiss 等人^[1-2]发现并提出自然图像的梯度分布具有重尾特性, 基于这一发现, Fergus 等人^[3]提出可以采用高斯混合模型来拟合图像梯度分布, 然后通过变分贝叶斯方法进行模糊核估计, 最后采用 Richardson-Lucy(RL)非盲复原方法

来恢复清晰图像。但是, RL 算法的引入导致复原图像产生明显的振铃效应。随后, Shan 等人^[4]提出采用连续分段函数来拟合图像梯度的重尾分布, 同时采用图像边缘信息来估计模糊核, 并在图像的平滑区域施加平滑约束来进一步抑制振铃效应的产生。Cho 等人^[5]进行了进一步的改进, 他们提出在每次迭代过程中引入双边滤波来抑制图像噪声, 然后采用 Shock 滤波进行图像增强, 再基于阈值法对图像中的有效边缘进行选择。但是, 受图像边缘细节的影响, 该算法复原性能不稳定。

Levin 等人^[6]采用超拉普拉斯分布来对图像梯度分布进行拟合, 然后通过最大后验概率(maximum a posteriori, MAP)模型对运动模糊下的退化图像进行复原, 实现了较好的效果。Xu 等人^[7]提出采用 L_0 稀疏表示来描述图像显著边缘分布, 实现了快速收敛和较好的图像复原效果。Wang 等人^[8]提出了一种 L_0-L_1 范数相结合的稀疏表示方法, 通过对图像及其梯度分别采用 L_0 和 L_1 范数来构造先验约束模型, 交替复原出图像模糊核和显著边缘, 最后由非盲复原方法恢复出清晰图像。

除了基于迭代优化的图像盲复原方法, 在过去十年间, 基于深度学习的盲复原方法也得到了广泛关注和快速发展, 许多基于深度神经网络的方法相继被提出^[11-16]。Zhang 等人^[14]提出了一种卷积神经网络(convolutional neural network, CNN)和递归神经网络(recurrent neural network, RNN)相结合的网络结构。Tao 等人^[12]提出了一种基于编码器-解码器结构的网络。Li 等人^[16]提出将神经网络与传统的总变分正则化手段相结合, 使得算法兼具这两类盲复原算法的优势。综合来看, 学习类的方法在图像复原效果上普遍优于传统迭代优化的方法, 但也普遍存在对训练数据集具有依赖性的缺点。由于实际应用场景中图像退化形态的复杂性, 基于学习训练的方法在训练数据集的充分性方面必然存在局限性。同时, 相关研究^[16]指出, 神经网络的结构通常是凭经验确定的, 其实际功能性很难得到解释。

1.2 本文研究内容

本文的研究主要受两方面的启发。一方面, 尽管在图像盲复原领域已经积累了大量的研究成果, 现有算法的图像复原能力仍然有限, 对清晰图像和模糊核进行更为准确的估计仍然是面临挑战的问题。另一方面, 当前图像盲复原研究呈现出采用多种先验进行组合约束的趋势, 这种组合策略可以有效提升图像复原效果。因此, 对图像的先验表示进行深入研究, 以发掘更有效的先验约束模型十分必要。

在本文的研究中, 提出了一种具有自适应特性的图像混合梯度稀疏先验约束模型。具体而言, 我们提出可以将自然图像高阶梯度分布的稀疏性用于图像盲复原研究, 通过高阶梯度和低阶梯度的结合来建立混合稀疏先验约束。同时, 引入基于模糊测度的比例因子来自适应地调节两类梯度先验在正则项中的比例。该方法的主要贡献有以下两点:

- 1) 通过研究图像高阶梯度的稀疏性, 提出了一种低阶梯度和高阶梯度相结合的稀疏先验约束策略, 并通过实验验证了该策略可以有效提升图像复原效果。
- 2) 介绍了一种基于自适应的迭代优化手段。通过构造基于图像熵的比例因子来对图像迭代求解过程进行调节, 使得算法具有更好的收敛性。

2 理论推导

2.1 混合梯度稀疏先验模型的建立

图像高阶梯度主要应用于图像去噪领域, 其本质是利用了高阶微分算子的图像平滑能力。目前, 高阶梯度已成功应用于基于总变分先验约束的图像复原方

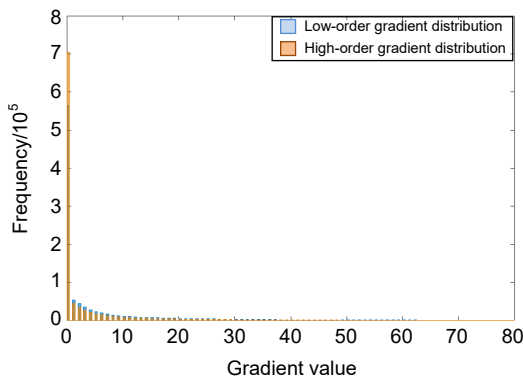


图 1 自然图像高阶梯度分布和低阶梯度分布。由水平梯度和垂直梯度可得到相似结论, 图中仅对水平梯度分布进行展示

Fig. 1 The distributions of the low-order and high-order gradient maps of clear natural images. This regularity exists in both horizontal and vertical directions and only the horizontal gradient distribution is presented for example

法中^[17-18], 实验表明它可以有效改善由 TV 范数造成的阶梯效应。然而, 在对图像高阶梯度分布进行统计分析的过程中, 发现自然图像的高阶梯度比低阶梯度具有更明显的重尾分布特性。如图 1 所示, 黄色柱状图描述的高阶梯度分布比蓝色柱状图描述的低阶梯度分布具有更多零值成分, 以及更明显的拖尾效应。这表明图像高阶梯度具有显著稀疏性, 可用于构造稀疏先验正则项。由此开展将高阶梯度应用于稀疏正则化的研究。

基于迭代优化的图像盲复原方法可描述为如下目标函数优化问题:

$$(f^*, h^*) = \min_{f, h} \frac{\gamma}{2} \|f * h - g\|^2 + \alpha_f R(f) + \alpha_h R(h) \quad (2)$$

其中: f 表示目标图像, g 表示退化图像, h 表示模糊核, $*$ 表示卷积符号。 $R(f)$ 和 $R(h)$ 分别表示图像正则项和模糊核正则项, 它们对目标函数施加正则化约束, 使得求解过程正确收敛。而正则项是通过选择合适的图像和模糊核先验来进行构造的, 因此, 先验的选择是图像盲复原研究的关键。

Kotera 等人^[9]通过研究证明了采用稀疏先验来描述一阶梯度的重尾分布有助于恢复图像显著边缘, 同时能有效抑制噪声和振铃效应。基于这一结论, 在研究初期考虑同时利用图像高阶梯度和低阶梯度的稀疏性, 将两类梯度相结合得到稀疏正则项:

$$R(f) = \Phi(D_x f, D_y f, D_{xx} f, D_{xy} f, D_{yx} f, D_{yy} f) = \|\nabla f\|^p + \|\nabla^2 f\|^p \quad (3)$$

其中: D_x 和 D_y 分别是沿水平方向和垂直方向的一阶微分算子, D_{xx} , D_{xy} , D_{yx} 和 D_{yy} 是二阶微分算子。 ∇f 表示图像一阶梯度的分布, $\nabla^2 f$ 表示二阶梯度分布, 它们分别表示为

$$\nabla f = \sqrt{D_x f^2 + D_y f^2} \quad (4)$$

$$\nabla^2 f = \sqrt{D_{xx} f^2 + D_{xy} f^2 + D_{yx} f^2 + D_{yy} f^2} \quad (5)$$

然而, 实验结果表明, 由这种先验约束模型无法得到理想的图像复原结果, 而是倾向于产生模糊解。为了解决这一问题, 引入一项可控参数 ω 来调整两类图像梯度在正则项中的比例, 并通过实验来观察图像复原结果与 ω 间的关系。在实验过程中发现, 采用不同模糊程度的样本图像时, 使得复原效果最优化的参数 ω 值不同。具体而言, 对模糊相对严重的图像, 需要更高比例的 $\nabla^2 f$ 先验约束, 而对于模糊相对较轻的图像, 则需要更高比例的 ∇f 先验约束。不同梯度比情况下的图像复原效果如图 2 所示。



图 2 不同比例梯度约束下的图像复原效果。

(a), (b) 为模糊图像; (c), (d) 为图(a)复原图像; (e), (f) 为图(b)复原图像。

Fig. 2 The restoration performance over different ratios of gradient regularizations.

(a), (b) Blur images; (c), (d) Restoration results of (a); (e), (f) Restoration results of (b)

考虑到迭代优化过程的中间图像会逐渐趋于清晰(模糊程度逐渐降低), 由此提出一种辅助迭代优化策略, 来对迭代优化进程中的参数 ω 进行自适应调节, 具体的参数模型建立过程见 3.1.1 小节。在本文中, ω 定义为如下形式:

$$\omega = 1 + \frac{E^2(f)}{E^3(f) + 1}, \quad (6)$$

其中: E 表示图像熵(Entropy)。然后通过式(2)进行代换, 获得本文方法的最终目标函数:

$$(f^*, h^*) = \min_{f, h} \frac{\gamma}{2} \|f * h - g\|^2 + \alpha_f \left(\|\nabla f\|^p + \omega \|\nabla^2 f\|^p \right) + \alpha_h R(h). \quad (7)$$

上式所描述的是一个高度非凸问题, 为了对其进行优化求解, 对 f 和 h 进行交替迭代更新。下面对具体的求解过程进行论述。

2.2 目标函数求解

2.2.1 h 子问题

在对图像模糊核 h 进行更新的过程中, 将上一次迭代得到的 f 固定不变, 同时引入辅助变量 $v_h = h$, 则 h 子问题可以转化为如下最小化问题:

$$\min_{h, v_h} \frac{\gamma}{2} \|Fh - g\|^2 + \alpha_h R(v_h) \quad \text{s.t. } v_h = h, \quad (8)$$

其中: F 是上一次迭代估计得到的清晰图像的频域表示。基于半二次惩罚技术^[19], 引入辅助变量 b_h 来对多变量的最小化问题进行高效求解。则目标函数可进一步改写为

$$\min_{h, v_h, b_h} \frac{\gamma}{2} \|Fh - g\|^2 + \alpha_h R(v_h) + \frac{\beta_h}{2} \|h - v_h - b_h\|^2. \quad (9)$$

将上式对 h 取微分并将导数设为零, 可以在频域中求得模糊核的闭式解, 对变量 v_h 和 b_h 采用同样的原理进行求解。关于 h 子问题的求解过程总结为算法 1, 具体算法流程如下:

算法 1 h 迭代求解

输入和初始值: $v_h^0 = b_h^0 = 0$, 循环终止条件 T_{tol} , 最大循环数 N 。

Loop

$$h^{i+1} = \mathcal{F}^{-1} \left(\frac{\overline{\mathcal{F}(f^i)} \mathcal{F}(g) + \frac{\beta_h}{\gamma} \mathcal{F}(v_h^i + b_h^i)}{\overline{\mathcal{F}(f^i)} \mathcal{F}(f^i) + \frac{\beta_h}{\gamma} I} \right),$$

$$v_h^{i+1} = \max \left(h^{i+1} - b_h^i - \frac{\alpha_h}{\beta_h}, 0 \right),$$

$$b_h^{i+1} = b_h^i - h^{i+1} + v_h^{i+1},$$

$i = i + 1,$
 Until $\frac{\|h^{i+1} - h^i\|}{\|h^{i+1}\|} \leq T_{\text{tol}}$ or $i > N,$

Return h^i .

在迭代更新结束后, 对估计所得的模糊核施加归一化约束和非负约束, 该先验约束模型可描述为如下形式:

$$\begin{cases} h(x, y) = \begin{cases} h, & h \geq 0 \\ 0, & h < 0 \end{cases} \\ \sum_x \sum_y h(x, y) = 1 \end{cases} \quad (10)$$

2.2.2 f 子问题

与 h 子问题的求解过程相似, 引入辅助变量:

$$\begin{aligned} v_x &= D_x f, \quad v_y = D_y f, \quad v_{xx} = D_{xx} f, \\ v_{xy} &= D_{xy} f, \quad v_{yx} = D_{yx} f, \quad v_{yy} = D_{yy} f, \end{aligned}$$

将目标函数转化为如下最小化问题:

$$\begin{aligned} \min_f \frac{\gamma}{2} \|fH - g\|^2 + \alpha_f \Phi(v_x, v_y, v_{xx}, v_{xy}, v_{yx}, v_{yy}) \\ \text{s.t. } v_x = D_x f, \quad v_y = D_y f, \quad v_{xx} = D_{xx} f, \\ v_{xy} = D_{xy} f, \quad v_{yx} = D_{yx} f, \quad v_{yy} = D_{yy} f, \end{aligned} \quad (11)$$

其中: H 是上一次迭代估计得到的图像模糊核的频域表示。同样地, 引入半二次惩罚项后目标函数转化为如下表达式:

$$\begin{aligned} \min_{f, a} \frac{\gamma}{2} \|fH - g\|^2 + \frac{\beta_f}{2} \|D_x f - v_x - a_x\|^2 \\ + \frac{\beta_f}{2} \|D_y f - v_y - a_y\|^2 + \frac{\beta_f}{2} \|D_{xx} f - v_{xx} - a_{xx}\|^2 \\ + \frac{\beta_f}{2} \|D_{xy} f - v_{xy} - a_{xy}\|^2 + \frac{\beta_f}{2} \|D_{yx} f - v_{yx} - a_{yx}\|^2 \\ + \frac{\beta_f}{2} \|D_{yy} f - v_{yy} - a_{yy}\|^2. \end{aligned} \quad (12)$$

通过控制变量法对上式在频域进行求解, 得到变量(f, a)的频域闭式解。关于 f 子问题的求解过程总结为算法 2, 具体算法流程如下:

算法 2 f 迭代求解

输入和初始值:

$$\begin{aligned} v_x^0 &= v_y^0 = v_{xx}^0 = v_{xy}^0 = v_{yx}^0 = v_{yy}^0 = a_x^0 \\ &= a_y^0 = a_{xx}^0 = a_{xy}^0 = a_{yx}^0 = a_{yy}^0 = 0, \end{aligned}$$

循环终止条件 T_{tol} , 最大循环数 N 。

为了书写简单, 令:

$$\begin{aligned} \mathcal{F}_1 &= \overline{\mathcal{F}(D_x)F(v_x^i + a_x^i)} + \overline{\mathcal{F}(D_y)F(v_y^i + a_y^i)} \\ &+ \overline{\mathcal{F}(D_{xx})F(v_{xx}^i + a_{xx}^i)} + \overline{\mathcal{F}(D_{xy})F(v_{xy}^i + a_{xy}^i)} \\ &+ \overline{\mathcal{F}(D_{yx})F(v_{yx}^i + a_{yx}^i)} + \overline{\mathcal{F}(D_{yy})F(v_{yy}^i + a_{yy}^i)}, \end{aligned}$$

$$\begin{aligned} \mathcal{F}_2 &= \overline{\mathcal{F}(D_x)F(D_x)} + \overline{\mathcal{F}(D_y)F(D_y)} \\ &+ \overline{\mathcal{F}(D_{xx})F(D_{xx})} + \overline{\mathcal{F}(D_{xy})F(D_{xy})} \\ &+ \overline{\mathcal{F}(D_{yx})F(D_{yx})} + \overline{\mathcal{F}(D_{yy})F(D_{yy})}. \end{aligned}$$

Loop

$$f^{i+1} = \mathcal{F}^{-1} \left(\frac{\overline{\mathcal{F}(h^i)\mathcal{F}(g)} + \frac{\beta_f}{\gamma} \mathcal{F}_1}{\overline{\mathcal{F}(h^i)\mathcal{F}(h^i)} + \frac{\beta_f}{\gamma} \mathcal{F}_2} \right),$$

$$\begin{aligned} a_x^{i+1} &= a_x^i - D_x f^{i+1} + d_x^{i+1}, \\ a_y^{i+1} &= a_y^i - D_y f^{i+1} + d_y^{i+1}, \\ a_{xx}^{i+1} &= a_{xx}^i - D_{xx} f^{i+1} + d_{xx}^{i+1}, \\ a_{xy}^{i+1} &= a_{xy}^i - D_{xy} f^{i+1} + d_{xy}^{i+1}, \\ a_{yx}^{i+1} &= a_{yx}^i - D_{yx} f^{i+1} + d_{yx}^{i+1}, \\ a_{yy}^{i+1} &= a_{yy}^i - D_{yy} f^{i+1} + d_{yy}^{i+1}, \end{aligned}$$

$i = i + 1,$

Until $\frac{\|f^{i+1} - f^i\|}{\|f^{i+1}\|} \leq T_{\text{tol}}$ or $i > N,$

Return f^i .

2.2.3 v 子问题

在式(12)所描述的最小化问题中, 关于变量 v 的求解是一个 L_p 范数下的非凸问题, 目标函数表示为 $(v_x^*, v_y^*, v_{xx}^*, v_{xy}^*, v_{yx}^*, v_{yy}^*)$

$$\begin{aligned} &= \arg \min_v \alpha_f \|v_x\|^p + \alpha_f \|v_y\|^p + \alpha_f \omega \|v_{xx}\|^p \\ &+ \alpha_f \omega \|v_{xy}\|^p + \alpha_f \omega \|v_{yx}\|^p + \alpha_f \omega \|v_{yy}\|^p \\ &+ \frac{\beta_f}{2} \|D_x f - v_x - a_x\|^2 + \frac{\beta_f}{2} \|D_y f - v_y - a_y\|^2 \\ &+ \frac{\beta_f}{2} \|D_{xx} f - v_{xx} - a_{xx}\|^2 + \frac{\beta_f}{2} \|D_{xy} f - v_{xy} - a_{xy}\|^2 \\ &+ \frac{\beta_f}{2} \|D_{yx} f - v_{yx} - a_{yx}\|^2 + \frac{\beta_f}{2} \|D_{yy} f - v_{yy} - a_{yy}\|^2. \end{aligned} \quad (13)$$

对上式的求解可简化为最小化问题:

$$x^* = \arg \min_w \|x\|^p + \frac{\alpha}{2} \|x - w\|^p$$

的求解。在 $0 < p < 1$ 的情况下, x 不存在闭式解, 可以通过查找表^[20]方法来快速得到 x 的近似解。

3 实验结果与分析

3.1 实验参数设计

3.1.1 自适应因子

在 2.1 小节介绍了有关图像低阶梯度和高阶梯度在不同实验样本下需要不同比例的组合这一发现, 同

时, 提出引入自适应因子来调整迭代更新过程中这两类先验约束的比例。考虑到采用数学表示对这一现象进行精确建模的困难性, 采用数据拟合的方式对参数 ω 进行建模。

为了实现自适应目的, 首先需要对迭代优化过程的中间图像进行实时模糊度量。图像熵(Entropy)是常用的图像模糊度指标之一, 其计算过程简单且快速, 本文将其选为图像模糊度量指标。由此, 对参数 ω 的建模过程即为对图像熵 E 和 ω 之间的相关关系进行建模的过程。我们采用 Levin 数据集^[6]中共计 32 幅模糊图像开展建模实验(参考图像已知), 在实验全过程中我们保持其他模型参数固定不变, 仅对 ω 进行调整。对于每一个模糊图像样本, ω 初始值设为 1, 调参标准为选择使得复原图像与参考图像间的结构相似性(SSIM)度量值更高的 ω 参数值。最终通过实验获得 32 组(E, ω)相关的数据点用于模型拟合(拟合过程详见附录), 得到模型如式(6)所示。

通过对该模型进行分析, 我们提出了关于参数 ω 如何对迭代优化过程产生影响的一种可能性解释。如图 3 所示, 随着图像模糊程度的增加, 图像高阶梯度的重尾分布特性减弱, 而低阶梯度受到的影响较小。在这种情况下, L_p 范数下的稀疏先验约束模型需要提高对图像高阶梯度的约束程度, 以增强高阶梯度先验的表达。而通过文中提出的自适应辅助策略, 灵活调节了图像高阶梯度先验强度, 进而提升了高阶梯度先验有效性, 从而保护了算法的图像复原性能。需要特别强调的是, 通过手动调参和数据拟合来确定数学模型的方式必然存在一定的误差, 其准确性有待提升。但是, 本文所介绍的参数自适应调节策略的主要意义在于通过实验验证了它能有效对图像复原效果进行改善, 能更好地满足实际应用中图像质量指标的要求。




图 3 清晰图像和退化图像的高阶梯度分布和低阶梯度分布对比

Fig. 3 An example of the variations of image gradients from clear to blurry (Please zoom in for a better view)

在未来的研究中, 会针对这一问题进行更加深入的分析 and 验证。

3.1.2 其他参数

算法的迭代优化基于多尺度框架展开^[9], 这样做的目的是避免迭代陷入局部最优解。同时, 在每轮迭代结束后将保真项的权重 γ 乘以 1.5, 即逐渐释放正则化所施加的约束, 这有利于减弱复原图像中的阶梯效应^[21]。其他模型参数分别设置为: $\gamma=1, \alpha_f=0.01, \alpha_h=10, \beta_f=1, \beta_h=10^4, p=0.3, T_{\text{tol}}=0.001, N=10$ 。

3.2 实验结果及数据分析

实验使用 BSDS^[16]和 GOPRO^[11]两个图像数据集, 对盲复原算法的复原能力进行实验分析和验证。BSDS 数据集是一个合成图像数据集, 它采用 BSDS500 数据集^[22]测试部分中的 200 幅参考图像和 4 个仿真模糊核来生成 800 幅模糊图像, 并对每幅图像添加标准差为 0.01 的高斯噪声。GOPRO 数据集是一个拍摄得到的真实图像数据集, 主要包括运动模糊和高斯模糊退化。

实验采用两项通用指标来对图像复原性能进行评价, 分别为结构相似性(SSIM)指标和峰值信噪比(PSNR)指标。采用六种现有的图像盲复原算法与本文方法进行对比实验, 包括 Krishnan^[23], Xu&Jia^[7], Kotera^[9], Hosseini^[24], Li^[16]和 Nah^[11]。其中, 前四种是基于迭代优化框架的方法, 后两种是基于深度学习框架的方法。

3.2.1 算法有效性分析

为了验证提出的盲复原方法的有效性, 对正则项中不同先验约束类型进行消融实验, 分为低阶梯度稀疏先验、混合梯度稀疏先验和混合梯度自适应稀疏先验三种方案。实验在 BSDS 数据集的后 50%子集上展开, 得到 SSIM 和 PSNR 指标的平均结果如表 1 所示, 实验示例如图 4 所示。

表 1 消融实验算法性能比较

Table 1 The average performance of ablation study. The best performed ones are marked in bold

Measure	Blurred	$\ \nabla f\ ^p$	$\ \nabla f\ ^p + \ \nabla^2 f\ ^p$	$\ \nabla f\ ^p + \omega \ \nabla^2 f\ ^p$
SSIM	0.5436	0.7110	0.7407	0.8280
PSNR	25.1436	26.0087	26.6255	26.7176

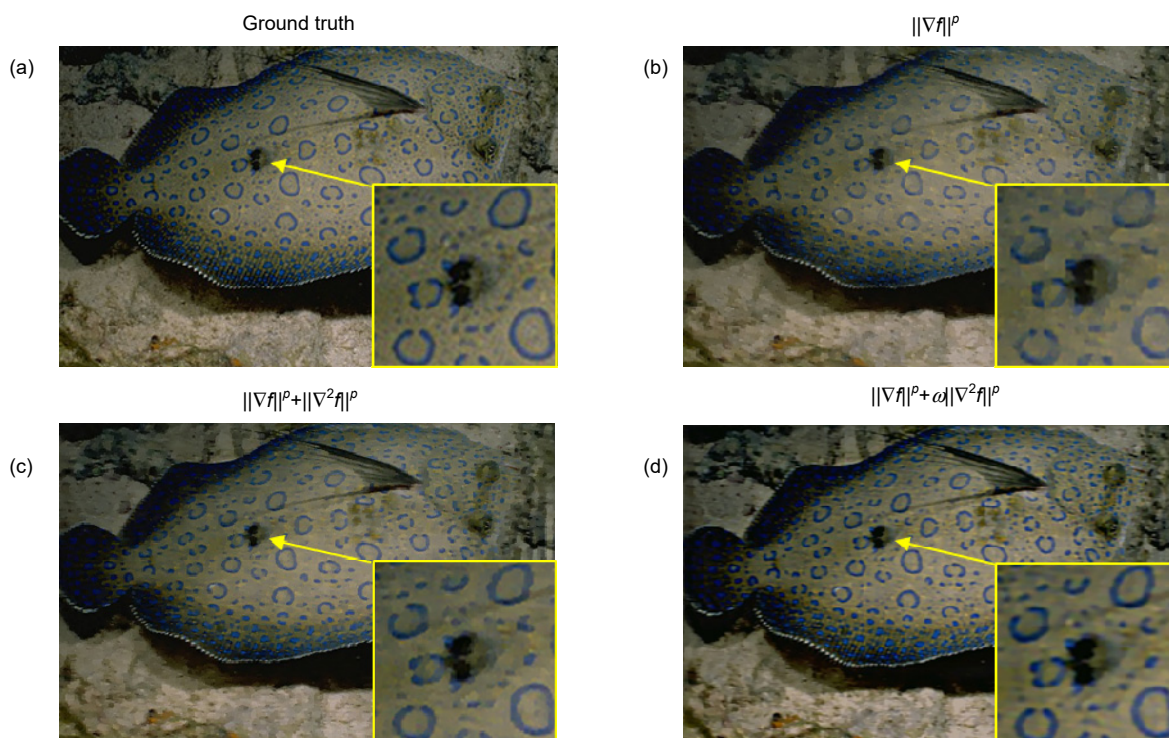


图 4 消融实验复原效果

Fig. 4 An example of ablation experiment of the proposed regularization scheme

从实验结果可以得出, 本文所介绍的混合梯度先验约束以及参数自适应策略可以有效提升图像复原能力。

由表 1 可知, 本文所采用的正则化方案在性能指标综合评价上明显优于其他方案。由图 4 可以得出, 在保证显著边缘的情况下, 本文方法可以更好地恢复图像色彩、纹理等细节, 使得复原图像具有更好的视觉效果。

3.2.2 仿真数据集实验分析

在 BSDS 合成数据集上对本文方法开展对比实验,

以此来评估本文方法相对于现有盲复原方法的复原性能。实验同样采用 SSIM 和 PSNR 两项指标来进行评价, 最终的实验结果和复原图像示例分别如表 2 和图 5 所示, 最佳指标值采用加粗进行强调。

从对比结果看出, 本文方法在复原性能上优于对比实验中采用的其他方法。文献[11]、[23]和[24]所提出方法的复原结果中仍存在大尺度的图像模糊, 而相比于文献[7]、[16]中的方法, 本文方法不仅能很好的恢复图像细节, 使得复原图像边缘更为锐利, 还能有效保持图像的整体平滑度, 使得图像视觉效果更佳。

表 2 不同方法在合成数据集上的实验结果

Table 2 Average deconvolution performance on dataset^[22]. The best performed ones are marked in bold

Metrics	Li ^[16]	Nah ^[11]	Krishnan ^[23]	Xu&Jia ^[7]	Hosseini ^[24]	Ours
SSIM	0.8303	0.8257	0.7270	0.7841	0.5404	0.8403
PSNR	20.8716	25.3978	22.8246	24.4006	20.7021	25.9269

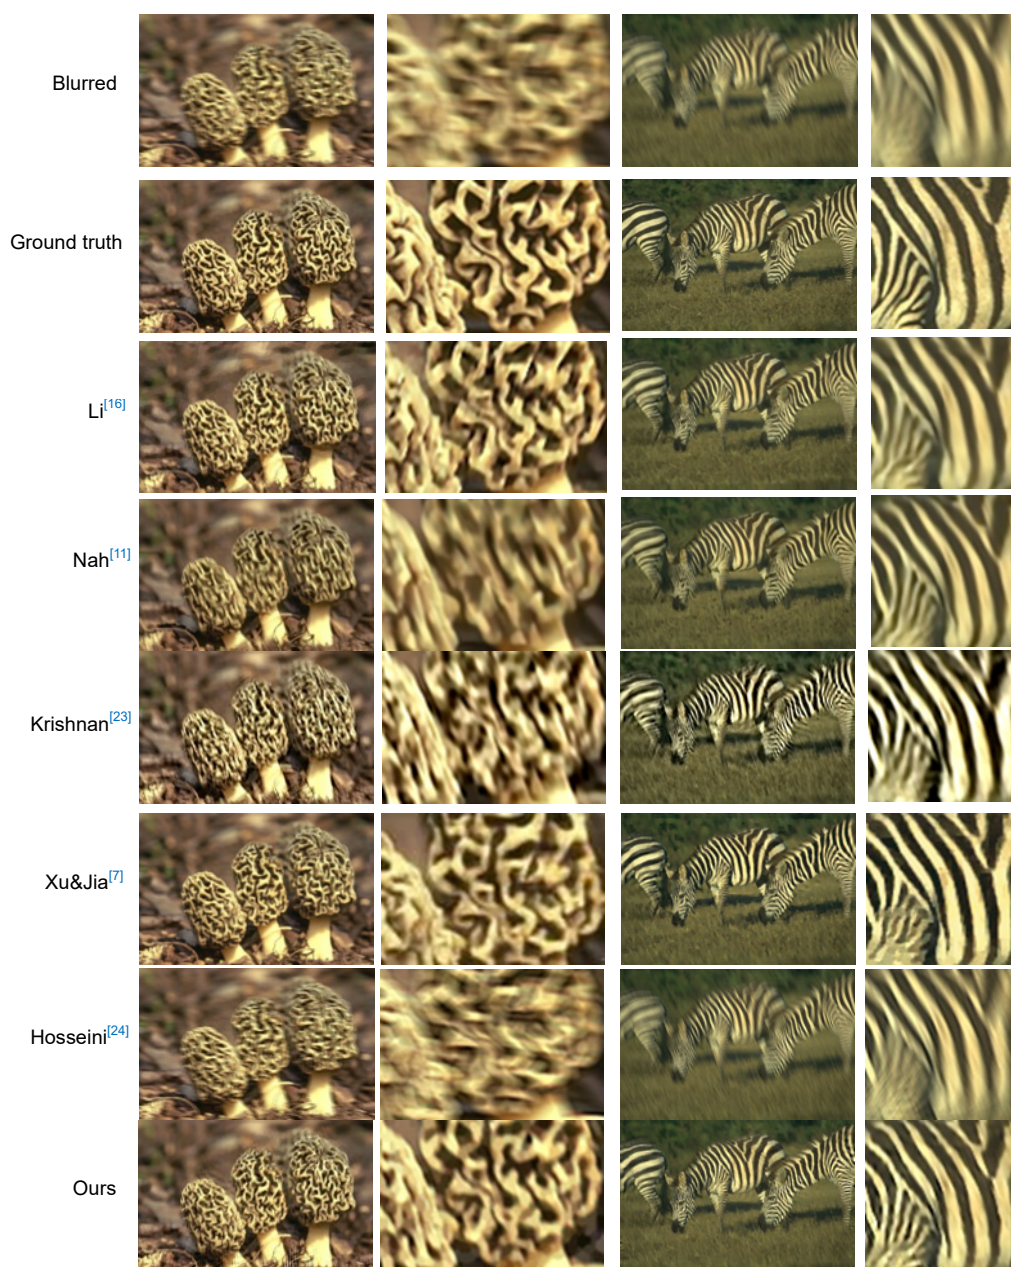


图 5 不同方法在合成数据集上的复原结果

Fig. 5 Examples of qualitative comparisons on the BSDS dataset^[22].

Columns from top to bottom: blurry image, Li, Nah, Krishnan, Xu and Jia, Hosseini, and ours

3.2.3 真实数据集实验分析

为了进一步验证本文算法在实际应用中的有效性,在真实退化的图像数据集上进行性能评估。图 6 展示了真实图像数据的盲复原结果,各方法的性能评估结果如表 3 所示,最佳指标值采用加粗进行强调。

由表 3 可知,本文得到的平均 PSNR 指标优于其他方法,平均 SSIM 指标略小于 Nah 等人的方法,但明显优于其他相关方法。由图 6 可以得到与图 5 类似的结论,本文方法可以恢复出更锐利的边缘和更平滑

的细节信息。综合来看,本文所提出的图像盲复原方法在主观视觉效果和性能评价指标上均处于相对领先水平。

需要特别指出,从图 5 和图 6 的复原结果中可以观察到仍存在一定程度的振铃效应,在进一步的研究工作中对这一现象进行抑制。

4 结 论

本文提出了一种具有自适应特性的混合梯度稀疏

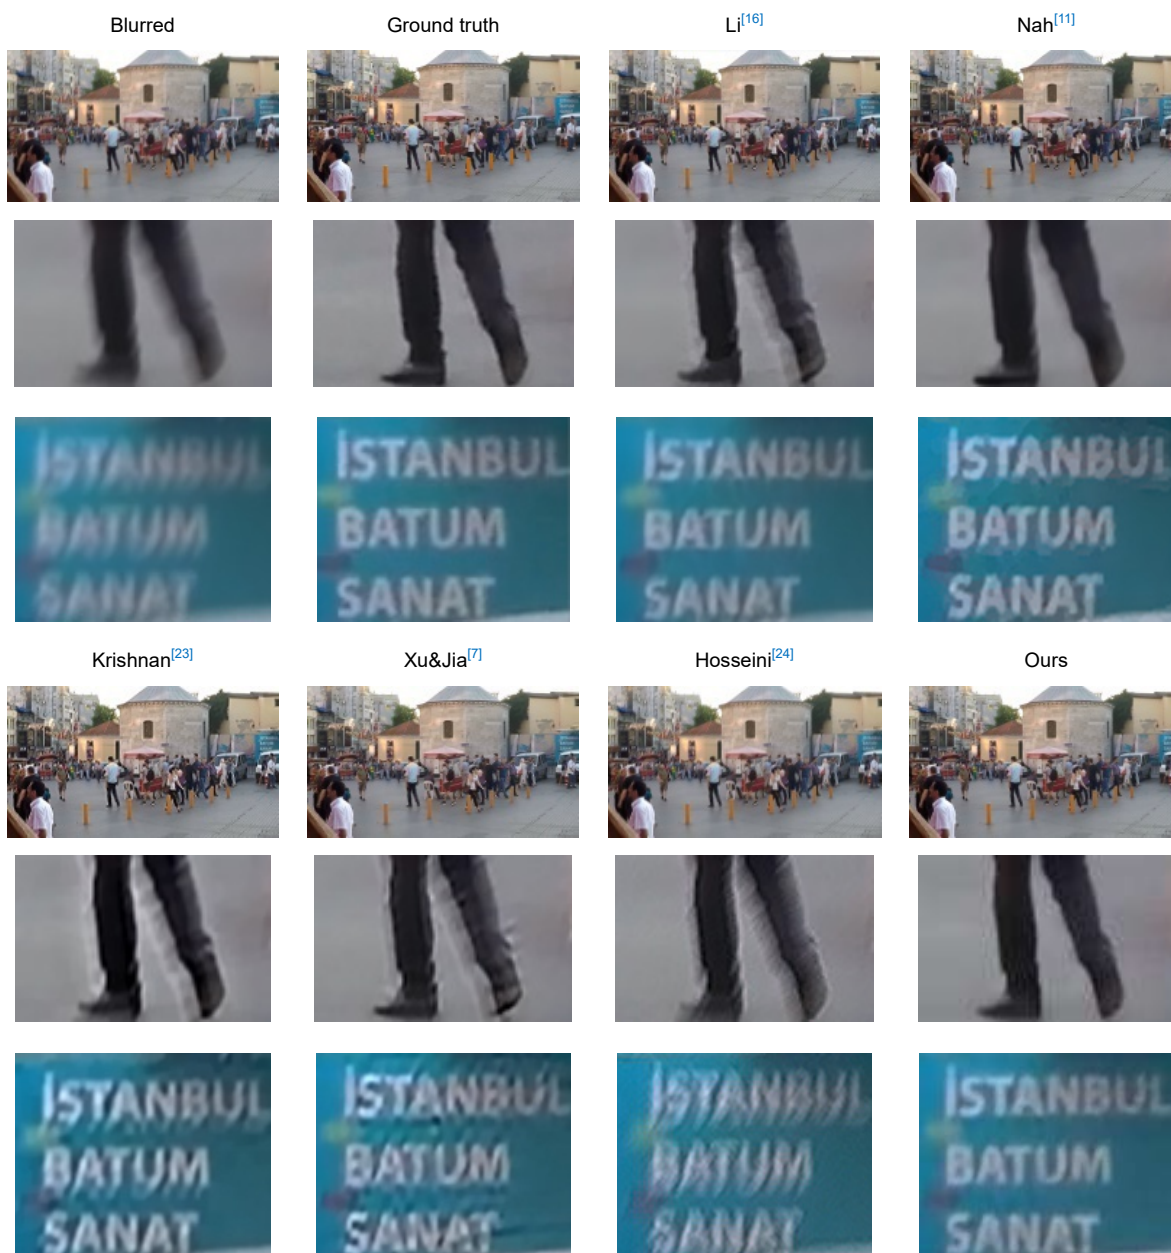


图 6 不同方法在真实数据集上的实验结果

Fig. 6 An example of real-life blurry image from the GOPRO dataset^[11]. Columns from left to right: blurry image, Li, Nah, Krishnan, Xu&Jia, Hosseini and ours

表 3 不同方法在真实数据集上的实验结果

Table 3 Average deconvolution performance on dataset^[9]. The best performed ones are marked in bold

Metrics	Li ^[16]	Nah ^[11]	Krishnan ^[23]	Xu&Jia ^[7]	Hosseini ^[24]	Ours
SSIM	0.8419	0.8752	0.7901	0.8147	0.8152	0.8723
PSNR	27.5433	28.2621	25.0031	26.6808	27.5458	30.4183

先验约束模型。通过利用图像高阶梯度和低阶梯度分布的稀疏特性，构造了一种基于稀疏先验的混合梯度正则项，并引入自适应因子来对两类梯度先验的比例进行实时调节，以保证迭代优化求解更好地收敛。实

验结果表明，本文方法在合成图像数据集和真实图像数据集上均表现出较好的图像复原性能，可以很好地平衡复原图像细节的锐度和平滑度，使得图像主观视觉效果更佳。在多方面的算法性能评价中，本文方法的

有效性也得到了对比和验证。

根据本文的研究结论, 图像高阶梯度的稀疏性可以很好地用于稀疏先验正则化研究中。下一步的研究将针对高阶梯度先验约束模型的构造以及振铃效应的抑制两方面展开。

附录

模型拟合通过 SPSS 统计分析工具的回归分析功能实现。根据待拟合数据点的空间分布规律, 选择线性模型、对数模型和倒数模型作为候选模型, 分别进行回归曲线估计, 得到回归分析结果如表 4 所示, 回归曲线估计结果如图 7 所示。

由表 4 可知, 倒数模型的确定系数 R^2 最大, 且取值为 1。因此, 结合模型参数评估结果, 可初步判定 ω 的表达式形如:

$$\omega_0 = 1 + \frac{1}{E} \quad (14)$$

在该模型基础上对 ω 分别进行如下定义:

$$\omega_1 = 1 + \frac{E}{E^2 + 1} \quad (15)$$

$$\omega_2 = 1 + \frac{E^2}{E^3 + 1} \quad (16)$$

$$\omega_3 = 1 + \frac{E^3}{E^4 + 1} \quad (17)$$

然后, 对不同 ω 定义下的盲复原算法性能进行分析。由 Levin 图像库^[6]得到各情况下复原图像与参考图像间的平均 SSIM 值, 如表 5 所示。

由表 5 可知, ω_2 的情况下复原算法可取得最佳性能, 因此, 本文的研究中将 ω 定义为

$$\omega = 1 + \frac{E^2}{E^3 + 1}$$

表 4 模型总计及参数评估

Table 4 Model overview and parameter estimation

方程式	模型摘要					参数评估	
	R^2	F	df1	df2	显著性	常数	b1
线性	0.937	10925.397	1	30	0.000	1.266	-0.018
对数	0.969	43365.874	1	30	0.000	1.400	-0.133
倒数模式	1.000	41328226.327	1	30	0.000	1.001	0.990

因变量: ω 自变量: $E(\text{Entropy})$




图 7 回归曲线估计图

Fig. 7 Estimations of regression curves

表 5 不同配置下算法在 Levin 图像库^[6]上复原结果的平均 SSIM 值

Table 5 Average SSIM performance on Levin dataset^[6] over different ω

Metrics	ω_0	ω_1	ω_2	ω_3
SSIM	0.7391	0.7616	0.7673	0.7467

参考文献

- [1] Weiss Y, Freeman W T. What makes a good model of natural images?[C]//*Proceedings of 2007 IEEE Conference on Computer Vision and Pattern Recognition*, 2007: 1–8.
- [2] Levin A, Weiss Y, Durand F, et al. Understanding and evaluating blind deconvolution algorithms[C]//*Proceedings of 2009 IEEE Conference on Computer Vision and Pattern Recognition*, 2009: 1964–1971.
- [3] Fergus R, Singh B, Hertzmann A, et al. Removing camera shake from a single photograph[J]. *ACM Trans Graph*, 2006, 25(3): 787–794.
- [4] Shan Q, Jia J Y, Agarwala A. High-quality motion deblurring from a single image[J]. *ACM Trans Graph*, 2008, 27(3): 1–10.
- [5] Cho S, Lee S. Fast motion deblurring[J]. *ACM Trans Graph*, 2009, 28(5): 1–8.
- [6] Levin A, Weiss Y, Durand F, et al. Efficient marginal likelihood optimization in blind deconvolution[C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2011: 20–25.
- [7] Xu L, Zheng S C, Jia J Y. Unnatural L_0 sparse representation for natural image deblurring[C]//*Proceedings of 2013 IEEE Conference on Computer Vision and Pattern Recognition*, 2013: 1107–1114.
- [8] Wang K, Shen Y, Xiao L, et al. Blind motion deblurring based on fused ℓ_0 - ℓ_1 regularization[C]//*Proceedings of the 8th International Conference on Image and Graphics*, 2015: 1–10.
- [9] Kotera J, Šroubek F, Milanfar P. Blind deconvolution using alternating maximum a posteriori estimation with heavy-tailed priors[C]//*Proceedings of the 15th International Conference on Computer Analysis of Images and Patterns*, 2013: 59–66.
- [10] Zhou H R, Tian Y, Rao C H. Blind restoration of atmospheric turbulence degraded images by sparse prior model[J]. *Opto-Electron Eng*, 2020, 47(7): 190040.
周海蓉, 田雨, 饶长辉. 稀疏先验型的大气湍流退化图像盲复原[J]. *光电工程*, 2020, 47(7): 190040.
- [11] Nah S, Kim T H, Lee K M. Deep multi-scale convolutional neural network for dynamic scene deblurring[C]//*Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition*, 2017: 257–265.
- [12] Tao X, Gao H Y, Shen X Y, et al. Scale-recurrent network for deep image deblurring[C]//*Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2018: 8174–8182.
- [13] Yan R M, Shao L. Blind image blur estimation via deep learning[J]. *IEEE Trans Image Process*, 2016, 25(4): 1910–1921.
- [14] Zhang J W, Pan J S, Ren J, et al. Dynamic scene deblurring using spatially variant recurrent neural networks [C]//*Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2018: 2521–2529.
- [15] Xu X Y, Pan J S, Zhang Y J, et al. Motion blur kernel estimation via deep learning[J]. *IEEE Trans Image Process*, 2018, 27(1): 194–205.
- [16] Li Y L, Tofighi M, Geng J Y, et al. Efficient and interpretable deep blind image deblurring via algorithm unrolling[J]. *IEEE Trans Comput Imaging*, 2020, 6: 666–681.
- [17] Lv X G, Song Y Z, Wang S X, et al. Image restoration with a high-order total variation minimization method[J]. *Appl Math Mod*, 2013, 37(16–17): 8210–8224.
- [18] Mu S S, Zhang J F. An anisotropic edge total generalized variation energy super-resolution based on fast l_1 -norm dictionary edge representations[J]. *Opto-Electron Eng*, 2019, 46(11): 180499.
穆绍硕, 张解放. 基于快速 l_1 -范数稀疏表示和 TGV 的超分辨算法研究[J]. *光电工程*, 2019, 46(11): 180499.
- [19] Goldstein T, Osher S. The split Bregman method for ℓ_1 -regularized problems[J]. *SIAM J Imaging Sci*, 2009, 2(2): 323–343.
- [20] Krishnan D, Fergus R. Fast image deconvolution using hyper-laplacian priors[C]//*Proceedings of the 22nd International Conference on Neural Information Processing Systems*, 2009: 1033–1041.
- [21] Perrone D, Favaro P. Total variation blind deconvolution: the devil is in the details[C]//*Proceedings of 2014 IEEE Conference on Computer Vision and Pattern Recognition*, 2014: 2909–2916.
- [22] Martin D, Fowlkes C, Tal D, et al. A database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics[C]//*Proceedings of the Eighth IEEE International Conference on Computer Vision. ICCV 2001*, 2001: 416–423.
- [23] Krishnan D, Tay T, Fergus R. Blind deconvolution using a normalized sparsity measure[C]//*Proceedings of the 2011 IEEE Conference on Computer Vision and Pattern Recognition*, 2011: 233–240.
- [24] Hosseini M S, Plataniotis K N. Convolutional deblurring for natural imaging[J]. *IEEE Trans Image Process*, 2019, 29: 250–264.


Blind image restoration method regularized by hybrid gradient sparse prior

Xu Ningshan^{1,2}, Wang Chen³, Ren Guoqiang^{1*}, Huang Yongmei¹

¹Institute of Optics and Electronics, Chinese Academy of Sciences, Chengdu, Sichuan 610209, China;

²University of Chinese Academy of Sciences, Beijing 100049, China;

³Chengdu Office of Military Representative Bureau of Equipment Department of Aerospace System Department, Chengdu, Sichuan 610041, China



Blind image restoration performance of the proposed method

Overview: Blind image restoration is widely used to improve the quality of degraded images with no-reference. Its main purpose is to accurately estimate the blur kernel and the wanted clear image. In the blind restoration research based on high-order image gradient priors, most of the existing works employ the total variation to model the gradient prior constraints. This class of method can effectively suppress the blocking artifact in the restored image. On the basis of experimental observation and research, this paper proposes to use the sparse prior constraint model to regularize the blind restoration process to obtain a better image restoration performance. On the one hand, by looking into the histogram of high-order and low-order gradients of a natural image, it can be found that the sparsity of high-order gradients is even more salient than that of low-order gradients. On the other hand, the existing researches show that the use of sparse priors to describe a heavy-tailed distribution of low-order gradients helps to restore the significant edges of the have image while effectively suppressing noise and ringing effects. Therefore, this work proposes to combine the low-order and high-order gradient priors into a new sparse regularization term so as to benefit from both types of gradient priors. In the meantime, an interesting experimental finding is introduced in this work that different degrees of image blur favor different ratios of the two types of gradient priors which are beneficial to obtain the optimal solution. Therefore, to obtain better iteration convergence, an adaptive factor ω based on image entropy is introduced to adjust the ratio of the two types of gradient priors in the iterative optimization process. Since it is hard to model the parameter ω mathematically, the expression of ω is determined by manually parameter adjustment and statistically data fitting in this work. The overall iterative optimization process is developed in a coarse-to-fine manner, and the split Bergman method is employed to deal with the non-convex problem of each minimization subtask. Finally, to analyze the performance of the proposed blind image restoration method, the ablation study was firstly conducted to demonstrate the efficiency of the employed strategies. Then, on the BSDS image dataset (simulated dataset) and the GOPRO image dataset (real blurred dataset), the proposed method was compared with the existing state-of-the-art image restoration methods. Experimental results show that our method can recover sharper edges and smoother details as well as introduce less unwanted artifacts, and our method is at a relatively leading level not only in subjective visual effects but also in performance evaluation indicators. All the above advantages demonstrate that the proposed method has superior image restoration performance.

Xu N S, Wang C, Ren G Q, *et al.* Blind image restoration method regularized by hybrid gradient sparse prior[J]. *Opto-Electron Eng*, 2021, 48(6): 210040; DOI: 10.12086/oe.2021.210040

Foundation item: National Key Research and Development Project (2016YFB0500201)

* E-mail: renguoqiang@ioe.ac.cn