

文章编号 2097-1842(2022)05-0954-19

非盲图像复原综述

杨 航*

(中国科学院长春光学精密机械与物理研究所, 吉林长春 130033)

摘要: 非盲图像复原在数学上是一种典型的病态问题, 也是计算机视觉领域的重要研究内容之一, 其目标是在点扩散函数已知的情况下, 由模糊图像估计出清晰图像, 其研究重点是在改善图像清晰度和抑制噪声之间做出适当的折衷。近 50 年来, 非盲图像复原取得了长足的发展, 从早期的维纳滤波到当前的深度学习, 学者们提出了数以百计的非盲图像复原算法, 并应用在各个领域。本文首先介绍非盲图像复原的基本概念和研究意义, 然后依据算法的属性对非盲图像复原算法进行分类概括, 从总体上将其分为传统方法和深度学习方法, 又进一步将传统方法细分为直接法和迭代法, 并依据不同算法的模型特征, 分析不同类别中主要算法的优缺点, 同时结合多种典型实验, 比较分析了一些代表性算法的复原性能, 最后展望了非盲图像复原算法的发展趋势, 归纳了重点研究方向。

关 键 词: 非盲图像复原; 图像先验; 直接法; 迭代法; 深度学习

中图分类号: TP391 文献标志码: A doi: 10.37188/CO.2022-0099

Survey of non-blind image restoration

YANG Hang*

(Changchun Institute of Optics, Fine Mechanics and Physics, Chinese Academy of Sciences,
Changchun 130033, China)

* Corresponding author, E-mail: yanghang@ciomp.ac.cn

Abstract: Non-blind image restoration is one of the most important research topics in the field of computer vision. It is also a typical ill-posed problem in mathematics. Its goal is to estimate a clear image from a blurred image when the point spread function is known. Its research focuses on how to make an appropriate compromise between improving clarity and suppressing noise. In the past 50 years, non-blind image restoration has made great progress. From the Wiener filtering to deep learning based methods, scholars have proposed hundreds of non-blind image restoration algorithms and applied them in various academic fields. This paper first introduces the basic concept and research significance of non-blind image restoration, then classifies and summarizes the main non-blind image restoration algorithms according to the algorithm attributes, which are generally divided into traditional methods and deep learning based methods. The traditional methods are divided into the direct method and iterative method, then are analyzed for their advantages and disadvantages. The performance of representative restoration algorithms is compared in a variety of typical experiments. Finally, the development trend and important research directions of non-blind image restoration al-

收稿日期: 2022-05-16; 修定日期: 2022-06-20

基金项目: 中国科学院青年创新促进会(No. 2020220)

Supported by Youth Innovation Promotion Association, CAS (No. 2020220)

gorithms are proposed.

Key words: non blind image restoration; image priors; direct method; iterative scheme; deep learning

1 引言

在图像的获取和传输过程中,受各种因素影响,如大气的湍流效应、摄像设备中光学系统的衍射、光学系统的像差、成像设备与物体之间的相对运动、离焦等问题,都难免会造成图像的失真,由这些因素引起的质量下降通常称为图像退化。由于图像的退化,观测到的图像会丢失很多有价值的信息,同时对比度会变差,其典型表现是图像出现模糊失真以及附加噪声。为此,必须对退化的图像进行处理,估计出真实的原始图像,这一过程就称为图像复原。

在数字图像处理领域,图像复原算法的研究是一个重要但又难以解决的问题。近半个世纪以来,图像复原问题始终是相关领域研究的热点之一,不仅具有理论挑战性也具有重要的实际应用价值。图像复原作为一种改善图像质量的技术,从失真和降质的观测量来估计原始图像,尽量降低和消除图像的失真和噪声。这对于图像的进一步研究和应用,诸如特征提取、自动识别和图像分析等都是极具价值的。近50年来,图像复原的应用范围已经涵盖了诸如天文观测^[1]、医学影像^[2]、空间探索^[3]、军事科学^[3]、遥感遥测^[4]、生物科学^[5]及工业视觉^[6]等众多科学和技术领域。

在实际问题中,点扩散函数是一个低通滤波器,其会使输入图像的高频成分受到抑制甚至丢失,图像复原是一个数学反问题,其目的是要“找回”丢失的成分。在图像复原过程中,观测图像中的噪声往往会被放大,这意味着图像复原的结果可能偏离真实的解。为了尽可能获得真实的解,图像复原要考虑对噪声的抑制,这就需要在清晰度和噪声放大之间做出适当的平衡。

图像复原问题根据已知条件的不同可以分为两类:非盲图像复原(点扩散函数已知)和盲图像复原(点扩散函数未知)。非盲图像复原,也称之为反卷积(deconvolution),是在点扩散函数已知的情况下,由观测图像(模糊图像),通过数学运

算,估计出清晰图像的方法,非盲复原更关注的是如何在噪声干扰的情况下,能够有效地恢复出清晰图像。与非盲图像复原不同的是,盲图像复原是在点扩散函数未知的情况下,关注如何能够快速有效地估计出点扩散函数和清晰图像。

生活中常见的模糊图像都是点扩散函数未知的情况,大多采用盲复原方法进行处理。从问题表面上看,盲复原的难度更大,因为清晰图像未知,点扩散函数也未知,但是因此断言非盲图像复原的研究价值没有盲复原的高是片面的,恰恰相反,这更能说明非盲复原的重要性,因为非盲复原才是盲复原的核心内容。绝大多数的盲复原方法是交替求解点扩散函数和图像,从而逐步恢复原始图像,即先固定点扩散函数估计图像(非盲图像复原问题),然后固定图像求解点扩散函数。由此可以看出,非盲复原算法是盲图像复原方法中不可或缺的步骤。当然随着深度学习的发展,也出现了一些由端到端网络直接获取清晰图像的盲图像复原方法,但若能估计出来点扩散函数,采用非盲图像复原的方法则要优于端到端、由模糊图像直接生成清晰图像的深度学习方法。另外,在很多研究领域,图像的降质过程有较好的理论模型支撑(例如光学稀疏孔径成像^[7]等),即在这种情况下,点扩散函数可以通过理论分析和计算得到,因此就省略了盲复原中点扩散函数估计过程,使得这些问题直接简化为一个非盲图像复原问题。

综上可知,研究非盲图像复原方法在实际应用和理论研究中都具有很高价值和意义。

本文将非盲图像复原方法分为传统方法和深度学习方法进行阐述。在传统方法中,又将其分为两大类:直接反卷积法和迭代法,最后,探讨了图像复原中的一些其他问题。

2 非盲图像复原中的传统方法

如果不考虑非线性退化的影响,由模糊造成的图像降质是一个线性时不变系统,其数学模型为:

$$B = k * L + \gamma , \quad (1)$$

其中 B 为观测图像(模糊图像), k 为点扩散函数(又称为模糊核), L 为清晰图像, γ 为加性噪声, “ $*$ ”表示循环卷积, 图像模糊的基本过程如图 1 所示:

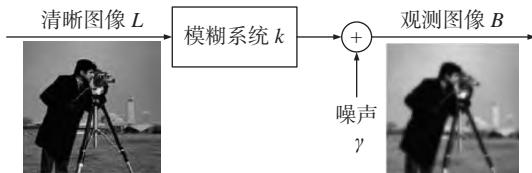


图 1 线性时不变系统示意图

Fig. 1 Diagram of linear time invariant system

2.1 直接法

根据卷积定理, 式(1)可以在傅立叶(Fourier)域写成一种更加适合计算的形式:

$$\mathcal{F}(B) = \mathcal{F}(k)\mathcal{F}(L) + \mathcal{F}(\gamma) , \quad (2)$$

其中 \mathcal{F} 表示傅立叶变换算子。式(2)将式(1)中空间域的卷积运算转换成了傅立叶域中的乘积运算。在点扩散函数 k 已知的情况下, 形式上通过式(3)即可获得一个对真实清晰图像 L 的估计:

$$\hat{L} = \mathcal{F}^{-1} \left(\frac{\mathcal{F}(B)}{\mathcal{F}(k)} \right) , \quad (3)$$

其中 \hat{L} 表示由算法估计出的清晰图像, \mathcal{F}^{-1} 表示傅立叶逆变换。但是该方法忽略了噪声以及点扩散函数高频能量衰减的影响, 因此式(3)会导致 \hat{L} 包含严重的噪声和振铃^[8]。针对这种病态的反问题, 数十年来, 学者们提出了大量的方法。在传统方法中, 直接法是最先应用到实际问题当中的。这类方法的主要特点是采用频域截断、滤波等手段来抑制式(3)中的噪声, 提升复原效果。

吉洪诺夫(Tikhonov)正则化^[9]采用频域截断的方式, 抑制点扩散函数在高频处的能量衰减造成的噪声能量放大, 其复原公式为:

$$\begin{aligned} \hat{L} &= \mathcal{F}^{-1} \left(\frac{\overline{\mathcal{F}(k)}\mathcal{F}(B)}{|\mathcal{F}(k)|^2 + \lambda} \right) = \\ &= \mathcal{F}^{-1} \left(\frac{|\mathcal{F}(k)|^2 \mathcal{F}(L)}{|\mathcal{F}(k)|^2 + \lambda} \right) + \mathcal{F}^{-1} \left(\frac{\overline{\mathcal{F}(k)}\mathcal{F}(\gamma)}{|\mathcal{F}(k)|^2 + \lambda} \right) , \end{aligned} \quad (4)$$

其中 $\lambda > 0$ 为正则化参数, $\overline{\mathcal{F}(k)}$ 表示 $\mathcal{F}(k)$ 的复共轭, 其中 $\mathcal{F}^{-1} \left(\frac{\overline{\mathcal{F}(k)}\mathcal{F}(\gamma)}{|\mathcal{F}(k)|^2 + \lambda} \right)$, 称之为遗漏噪声(或有色噪声)。

吉洪诺夫正则化也可以从最优化角度去理解, 即 \hat{L} 为最优化问题的解, 如式(5)所示:

$$\hat{L} = \arg \min_L \|B - k * L\|^2 + \lambda \|L\|^2 . \quad (5)$$

吉洪诺夫正则化将图像平滑的性质作为约束, 会导致复原图像的边缘不清晰, 当正则化参数选取不当时, 会产生较严重的振铃效应。但是因其计算效率较高, 在噪声水平不高的情况下, 应用广泛。

维纳(Wiener)滤波^[9]是基于最小均方误差准则的一种线性滤波方法, 其表达式为:

$$\hat{L} = \mathcal{F}^{-1} \left(\frac{\overline{\mathcal{F}(k)}\mathcal{F}(B)}{|\mathcal{F}(k)|^2 + \frac{S_L}{S_\gamma}} \right) , \quad (6)$$

其中 S_L 和 S_γ 分别为清晰图像和噪声的功率谱, 显然这在实际问题中是无法得到的, 因此在具体应用时常用额外的手段去获取 $\frac{S_L}{S_\gamma}$ 的近似值。维纳滤波依然不能有效处理噪声放大问题。

随着多尺度分析, 特别是小波分析的发展, 采用小波分解进行非盲图像复原成为热点^[10-13], 例如, Donoho 等人^[13]提出一种小波涟漪卷积方法, 通过引入一个与尺度相关的涟漪函数来参与解卷积, Kalifa 等人^[14]提出了一种匹配卷积核频域性质的镜像小波, 进而通过阈值收缩来达到抑制噪声的目的。这些方法都是通过将小波技术融合到解卷积的过程中, 没有达到去卷积和抑制噪声两者之间的平衡, 噪声去除效果不佳, 而且算法的步骤较为复杂, 数学推导繁琐, 在实践中不易执行。

在 2004 年, Neelamani 等人^[15]提出了一种将去卷积和去噪分离的方法, 其思想较直接: 首先采用吉洪诺夫正则化进行解卷积, 此时选择一个较小的正则化参数, 目的是保留绝大部分图像信息, 但是遗留下的噪声也较多, 然后, 再使用小波分析对解卷积之后的图像进行去噪, 得到最终的复原图像, 这个方法称之为 ForWaRD, 其流程图如图 2 所示。值得注意的是: 其小波去噪方法不是通过简单的小波系数阈值收缩实现的, 而是采用两步法。首先, 对解卷积图像进行小波系数硬阈值收缩, 得到预估计图像, 然后, 再依靠预估计图像构造小波域维纳收缩因子, 接着, 再对解卷积图像的小波系数进行维纳滤波, 最后, 通过逆小波变换

得到复原后的图像。ForWaRD 方法不仅在当时取得了较好的处理效果,更重要的是其引领了非盲图像复原的一次重要革新,其后绝大多数直接法都采用了类似的思路,即先解卷积,然后再去噪。



图 2 ForWaRD 算法流程图
Fig. 2 Flow chart of ForWaRD algorithm

虽然 ForWaRD 算法在非盲图像复原思路转变上起到了很大的作用,但是由于二维张量小波只能有效地处理图像中各向同性的奇异对象,对于不规则边缘和纹理等各项异性特征没有较好的非线性拟合能力,因此,学者们用更加有效的图像分析工具来替代小波变换,由此产生了很多新的方法。

随着小波热潮发展起来的多尺度几何分析,逐步成为了图像处理的有效工具,例如曲波^[16](curvelet)、轮廓波^[17](contourlet),剪切波^[18](shearlet)和波原子^[19](wave atom)等,这些变换本质上和小波变换一样,是一种人为构造出来的固定基底,用以对二维图像进行稀疏化表示,他们的优势在于可以对图像的边缘/纹理有较强的非线性逼近能力,因此,在各类图像问题中得到了广泛应用。在非盲图像复原领域,也得到了较 ForWaRD 更有效的扩展算法^[20-22]。每种多尺度方法都在某一方面具备较好的图像信息表达能力,但也有各自的局限,例如曲波^[20]能够对图像中的边缘有效的稀疏表示,而对纹理等信息不能很好处理,反之,波原子^[22]虽然对模式化的纹理有最有效的非线性逼近能力,但是对普通曲线的处理要弱于其他多尺度变换。

基于多尺度变换域的高斯混合模型(Gaussian Scale Mixtures, GSM)^[23-24]在图像复原方面也取得了不错的效果,基本思想是先对模糊图像进行解卷积,然后对解卷积图像进行多尺度分解,最后在多尺度金字塔和完备(或超完备)基底系数中应用高斯混合模型,对变换系数进行滤波,进而达到抑制噪声的效果。这类方法的代表: SV-GSM^[24](Space Variant GSM)方法是当时最好的图像复原方法之一。Xue 等人^[25]提出了一种基于正则化的 Stein 无偏风险估计(SURE)的最小化方法,称

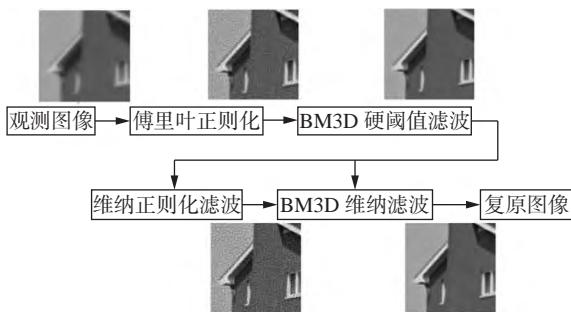
之为 SURE-LET 方法。该方法首先使用多个维纳滤波器作为基本函数,然后,使用非抽取的 Haar 小波阈值,线性地参数化复原过程,利用 SURE 的二次性和线性参数化,将复原问题最终归结为求解一个线性方程组,而这个线性方程组的解即为真实图像的最优无偏估计。SURE-LET 方法有着独特的滤波手段,因此在小波类方法中取得了最佳结果,类似的思想也可以推广到其他多尺度分析方法中。

与固定基底不同,文献 [26-27] 提出了依据图像内容自适应构造基底的方法,例如基于形状自适应离散余弦变换的 SA-DCT 方法^[27]。在图像局部使用非参数局部多项式来逼近图像,虽然处理效果受限于表示工具,但是也为图像分析的自适应基底提供了思路。遗漏噪声与普通的高斯加性白噪声不同,其随机变量的概率分布不具备相同的方差,因此普通的去噪方法无法直接应用到非盲图像复原中,而非局部均值滤波^[28](Non Local Means Filter, NLMF)因为具有较强的纹理保护能力和滤波能力,获得了学者的重视,并将其用于解决图像复原问题^[29],有效恢复模糊图像中的纹理信息。

在图像处理领域,自适应基底和非局部特征被广泛关注,一种将二者有机结合的图像处理技术应运而生——三维块匹配滤波^[30](Block Matching 3D filtering, BM3D)。该方法是传统方法中去噪效果最好的算法之一。该算法的思想与 NL-Means 类似,也是在图像中寻找相似块进行滤波,不同的是,在得到足够多的相似块之后,将其堆成一个三维数据(一个组),并对这个三维数据进行三维(3D)滤波,之后将滤波后的数据返回到各自的图像位置并融合(因为一个像素点可以多次被匹配到不同的组中)。

BM3D 算法在图像去噪领域均取得了巨大的成功,因此将 BM3D 方法用于遗漏噪声的滤除也成为了很自然的做法。学者们提出了 BM3DDEB^[31]用于图像反卷积,该算法至今也是图像复原问题首选方法之一,其流程图如图 3 所示。

直接图像复原法,其重点在于遗漏噪声的去除,但并不是所有去噪的方法都是固定模式,每种方法都有自己独特的去噪技巧,从而才能获得最佳的复原效果。

图3 基于BM3D的图像复原方法流程图^[31]Fig. 3 Flow chart of image restoration method based on BM3D^[31]

为了对直接法的复原效果进行更好地总结,采用6组标准实验设置,对8种代表性直接法进行实验对比,8种算法分别为:ForWaRD^[15]、ShearDec^[21]、GSM^[23]、SV-GSM^[24]、LPA-ICI^[26]、SA-DCT^[27]、SURE-LET^[25]以及BM3DDEB^[31]。采用改进的信噪比^[32](Improvement in Signal-to-Noise Ratio, ISNR)作为算法的评价标准,单位是分贝(dB)。ISNR的计算公式为:

$$ISNR = 10 \lg \frac{\|L - B\|_2^2}{\|L - \hat{L}\|_2^2} . \quad (7)$$

由式(7)可看出,相对于峰值信噪比(PSNR)的计算公式,ISNR的计算增加了模糊图像 B 信息,这样更能反映复原图像对模糊图像的改善程度。

表1给出了每组实验的参数设置,其中BSNR(Blurred Signal-to-Noise Ratio)表示模糊信噪比,其计算公式为:

$$BSNR = 10 \lg Var(B)/(HW\sigma^2) , \quad (8)$$

其中,Var(B)表示模糊图像 B 的方差, H 和 W 分别表示图像的高和宽, σ 表示噪声的标准差。

表1 实验设置

Tab. 1 Experimental settings

序号	点扩散函数	噪声水平	图像
1	9×9 boxcar	$BSNR = 40$ dB	Cameraman
2	$k(x,y) = 1/(x^2 + y^2), x,y = -7, \dots, 7$	$\sigma^2 = 2$	Cameraman
3	$k(x,y) = 1/(x^2 + y^2), x,y = -7, \dots, 7$	$\sigma^2 = 8$	Cameraman
4	$k = [1, 4, 6, 4, 1]^T [1, 4, 6, 4, 1]/256$	$\sigma^2 = 49$	Lena
5	Gaussian型点扩散函数, 方差为1.6	$\sigma^2 = 2$	Barbara
6	Gaussian型点扩散函数, 方差为0.4	$\sigma^2 = 64$	House

表2显示了8种算法的复原结果,其中标下划线数值表示该组实验中最优的结果,加粗数值表述次最优的结果,从表2可以明显看出,BM3DDEB^[31]具有最大的优势。表2中的数据来源于文献[21,25,31,33]。

表2 8种直接法输出ISNR的对比

Tab. 2 Comparison of ISNR output by eight methods

实验方法	1	2	3	4	5	6
ForWaRD ^[15]	7.40	6.75	5.07	2.98	0.98	5.52
ShearDec ^[21]	7.89	7.55	5.56	—	—	—
GSM ^[23]	-1.61	6.84	5.29	—	0.95	5.98
SV-GSM ^[24]	7.33	7.45	5.55	—	<u>1.36</u>	6.02
LPA-ICI ^[26]	8.29	7.82	5.98	3.90	—	—
SA-DCT ^[27]	<u>8.55</u>	8.11	6.33	4.49	1.02	5.96
SURE-LET ^[25]	7.84	7.54	5.22	4.42	1.06	4.38
BM3DDEB ^[31]	8.34	<u>8.19</u>	<u>6.40</u>	<u>4.81</u>	1.28	<u>7.21</u>

直接法的优点在于其思想简洁,计算复杂度较低,便于应用;缺点是由于遗漏噪声不同于高斯白噪声。因此,单独去噪无法达到满意的效果,常常伴有振铃效应或者噪声滤波不完全的情况。因此,很多学者把提升非盲图像复原效果的重点放在了迭代法上。

2.2 迭代法

非盲图像复原的迭代求解法的核心思想是将清晰图像的估计视作一个优化问题的最优解,通过设计一种迭代格式来求解该最优化问题,进而达到图像复原的目的^[34-38]。

Lucy-Richardson(LR)法^[39]是迭代法的早期代表之一,其假设图像服从泊松(Poisson)分布,采用最大似然估计,得到如下一种迭代格式:

$$L^{n+1} = L^n \left(\frac{B}{k * L^n} \circ k \right) , \quad (9)$$

其中“ \circ ”表示相关运算。LR方法容易受到噪声的影响,同时复原图像往往会进一步放大噪声,不适用于低信噪比的情况。Whyte等人^[40]针对部分饱和的模糊图像,引入一个响应函数用来辨识饱和与非饱和像素点,进而提出了一种改进型的LR迭代法。

全变差(Total Variation, TV)正则化是另一种

重要的图像处理模型^[41], 在图像去噪^[42], 图像复原^[43], 图像分割^[44], 图像超分辨^[45]等领域都有着广泛的应用。全变差模型本质上是一种对图像的梯度进行约束(或者也可以称为将图像的梯度信息作为先验)的一种最优化问题, 在图像复原问题上的数学表达式为:

$$\hat{L} = \arg \min_L \|B - k * L\|_2^2 + \lambda \|\nabla L\|_{\text{def}} , \quad (10)$$

其中 ∇ 表示梯度算子, $\nabla L = (\partial_x L, \partial_y L)$, ∂_x 和 ∂_y 分别表示 x 和 y 方向的偏导算子, $\|\cdot\|_{\text{def}}$ 表示自定义的范数, $\lambda > 0$ 称为正则化参数, 而 $\|\nabla L\|_{\text{def}}$ 亦称作正则项, $\|B - k * L\|_2^2$ 称为保真项。

1994 年, Osher 团队^[46] 提出了求解图像复原问题的 ROF (Rudin-Osher-Fatemi) 模型, 即基于全变差范数的最优化模型。为了求解这种全变差图像复原模型, 早期的求解方法采用了偏微分方程的求解模式, 将优化问题转化为 Euler Lagrange 方程, 进行求解^[47]。这类方法计算复杂度高, 迭代收敛慢。随着压缩感知带来的热潮, 学者们提出了大量的最优化方法来求解这类模型, 进而也推动了全变差模型在图像复原领域的发展。以美国学者 Osher 团队为首, 率先提出了分离变量的思想^[48], 使用 Bregman 迭代方法, 开创了一种快速求解全变差优化模型的理论, 大大推动了迭代法的发展。这类算法包括 Split Bregman 法^[49], 阈值收缩法^[42,50-51], Landweber 法^[52], ADMM^[53](Alternating Direction Method of Multipliers) 法等。分离变量的核心思想是通过引入一组中间变量, 将不易直接求解的问题转化为交替迭代求解多个易求解的子问题, 例如在文献 [34] 中, 作者提出了一种快速求解全变差图像复原模型方法(FTVd), 通过引入一组中间变量, 将式(10)改写为:

$$\min_{L, w} \|B - k * L\|_2^2 + \alpha \|w - \nabla L\|_2^2 + \lambda \|w\|_2 . \quad (11)$$

之后采用交替迭代法, 得到两个子优化问题:

$$w^{n+1} = \arg \min_w \|w - \nabla L^n\|_2^2 + \frac{\lambda}{\alpha} \|w\|_2 , \quad (12)$$

$$L^{n+1} = \arg \min_L \|B - k * L\|_2^2 + \alpha \|w^{n+1} - \nabla L\|_2^2 . \quad (13)$$

这两个子问题在数学上都有解析解(closed form 解), 即:

$$w^{n+1} = \max \left\{ \|\nabla L^n\| - \frac{\alpha}{2\lambda}, 0 \right\} \frac{\nabla L^n}{\|\nabla L^n\|} , \quad (14)$$

$$L^{n+1} = \mathcal{F}^{-1} \left(\frac{\mathcal{F}(k)\mathcal{F}(B) + \alpha(\overline{\mathcal{F}(\partial_x)}\mathcal{F}(w^{n+1}) + \overline{\mathcal{F}(\partial_y)}\mathcal{F}(w^{n+1}))}{|\mathcal{F}(k)|^2 + \alpha(|\mathcal{F}(\partial_x)|^2 + |\mathcal{F}(\partial_y)|^2)} \right) . \quad (15)$$

通过式(14)~式(15)的交替迭代, 就可以较容易得到最后的复原结果。

对于式(10)中的正则项, 可以根据需要定义不同的范数, 例如 l_1 范数^[49](各向异性全变差), l_2 范数^[34,54](各向同性全变差), 也可以是非凸正则项^[55]: $\|\nabla L\|_a = |\partial_x L|^\alpha + |\partial_y L|^\alpha$, 甚至可以是 “ l_0 ” 范数^[56-57]。这种分离变量的优化技巧大大提高了全变差模型的求解速度和收敛性, 受到了学者们的持续关注, 但是全变差最优化模型的本质问题没有得到改变, 即该模型期望问题的最优解具有最小的梯度能量。这就会导致图像中细节信息丢失、纹理信息损失、图像过于平滑等问题。

从理论上分析, 基于全变差的图像约束利用了图像中大部分是平滑区域的性质, 对梯度进行约束, 可以使获取的图像尽可能的平滑, 进而抑制噪声。同理, 如果期望获取的图像具有某一方面特殊的性质, 那么就可以提出相应的正则项(图像先验)。

随着压缩感知^[56] 的提出, 图像稀疏性的研究进入了一个高峰期。压缩感知理论表明, 如果一个信号(图像)是稀疏的(非零元素较少), 那么该信号(图像)就是可以压缩采样的, 即通过压缩采样后是可以精确复原的。虽然图像本身并不稀疏, 但是在一些特定的变换下, 其变换系数可以是稀疏的。这一理论对图像复原问题提供了新的思路, 同时基于稀疏性的各种优化模型和迭代格式不断提出, 大大丰富了图像复原的研究。

因此, 在全变差模型取得成功的同时, 用于图像稀疏性表达的多尺度分析方法, 例如小波、曲波等, 也被应用到迭代法中, 即作为对图像的特征约束, 构造相应的最优化问题, 例如: 在文献 [58] 中提出一种基于小波正则化的快速迭代阈值方法, 其最优化问题表达式为:

$$\min_L \|B - k * L\| + \lambda \|\mathbf{W}L\|_1 , \quad (16)$$

其中 \mathbf{W} 表示正交小波变换。类似的方法还有很

多,可以参考文献[59-63]。同时,也有将小波、曲波和全变差组合在一起构造的新方法^[64-65],其基本思想是将图像分成多个部分,每个部分用特定的先验进行约束,例如可以将图像分成纹理部分和平滑部分,纹理部分可以采用波原子先验,而平滑部分可以采用全变差先验。

从迭代法的迭代格式可以发现,大多数迭代法的核心主要包含两个步骤:一个是对卷积的处理(式(15)),一个是滤波处理(式(14)),这和直接法相似,其本质的不同在于迭代法将前一次滤波的结果,反馈到下一次的解卷积中,让解卷积的结果不仅仅取决于模糊图像,也更加贴近前一次滤波(去噪)的结果。经过反复多次迭代,最终收敛到的结果能够在解卷积和去噪之间达到平衡。

经此分析,很多对噪声具有较好滤除性能的方法均可能在迭代法中得到应用,这些滤波或者去噪方法的引入也提升了非盲图像复原的效果。

字典学习^[66-67](dictionary learning)是一种针对单幅图像构造自适应基底的方法,即字典为一组通过当前图像自适应学习出来的基底,最早用于图像的稀疏表示,其求解字典的模型为:

$$\min_c \|c\|_0, \text{ s.t. } L = \Phi c \quad (17)$$

其中 Φ 表示需要求解的字典,其需要通过图像 L 和求解最优化问题得到, c 是图像 L 相对于字典表示的系数,目的是要求 c 是稀疏的(元素尽可能为 0 或者接近 0)。图 4 显示了图像复原算法中学到的字典^[68]。Elad 等人^[67]采用 KSVD(K-means Singular Value Decomposition)的方法获得了较好的冗余字典,并在图像去噪、图像修补、图像复原等领域都受到了关注。在非盲图像复原中, CSR^[69]、NCSR^[70]、GSR^[71]等为最具代表性的

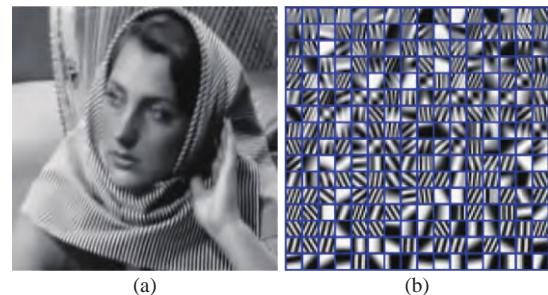


图 4 非盲图像复原算法中学习到的字典^[68]。(a)Barbara 图像复原局部图;(b)学习到的字典。

Fig. 4 Learned dictionary from non-blind image restoration algorithm^[68]. (a) Partial restoration image for Barbara image; (b) the learned dictionary

字典学习类方法,其一般最优化模型为:

$$\hat{c} = \arg \min_c \|B - k * H \Phi c\|_2^2 + \lambda \|c\|_1 \quad . \quad (18)$$

对于不同的字典学习类算法,主要是对正则项进行改进,例如中心稀疏表示^[69](Centralized Sparse Representation, CSR)模型在式(18)的基础上添加了中心约束项:

$$\hat{c} = \arg \min_c \|B - k * H \Phi c\|_2^2 + \lambda \|c\|_1 + \gamma \|c - \beta\|_p \quad , \quad (19)$$

其中 p 为 1 或者 2, β 为 c 的较好估计^[69],新增加的约束项可以在有噪声干扰的情况下,使学习到的字典更鲁棒。在 CSR 的基础上进一步改善正则项,得到 NCSR^[70]:

$$\hat{c} = \arg \min_c \|B - k * H \Phi c\|_2^2 + \gamma \|c - \beta\|_p \quad . \quad (20)$$

NCSR 算法虽然删除了系数稀疏约束项,但是在字典学习方法上通过 K 均值(K -means)聚类和主成分分析(PCA)对学习到的字典进行聚类,并采用非局部思想对 β 进行更新,能够取得更优的复原效果。GSR^[71]算法提出了一种新的约束,将块相似和自适应字典学习相结合,构建相似组(图 5(彩图见期刊电子版)给出了相似组构建的

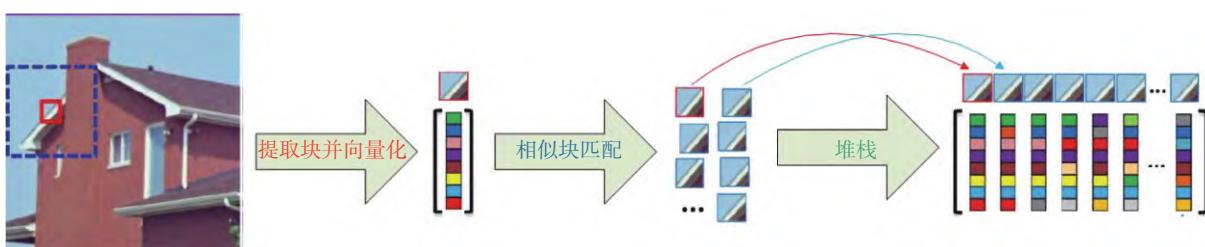


图 5 组建构的图解^[71]

Fig. 5 Illustration of group construction^[71]

图示), 对图像进行稀疏编码, 进而提升图像的表示能力, 并取得了当时最优的复原效果。

块相似的方法也很自然地应用到了图像复原中^[72-73], 特别是基于 BM3D 的 IDDBM3D^[73] 算法, 更是取得了当时最高水平的结果(目前也是传统方法中最好的方法之一)。该方法将 BM3D 滤波融入到一个两步迭代格式中, 一个子问题用于去噪, 一个子问题用于解卷积, 将解卷积和去噪解耦, 交替迭代。文献 [73] 证明了该迭代格式是收敛的。IDDBM3D 对各类点扩散函数和各种噪声水平都有着很强的适应性, 同时计算复杂度不高, 能够广泛应用于各种实际问题中。

低秩(low rank)方法是在块匹配的基础上发展起来的, 其思想是将匹配到的相似块转换成一维向量(与图 5 中堆栈部分类似), 然后进行奇异值分解, 并对奇异值进行抑制(软阈值或者硬阈值), 进而达到滤波的效果。这种方法虽然与 BM3D 在某种程度上相似, 但是基于 SVD 的方法比 3D 滤波更能发挥图像块之间的相似性作用, 因此取得了更好的处理效果^[74]。低秩方法可以认为是核范数^[75](nuclear norm)约束的一种形式(一个矩阵的核范数定义为该矩阵的所有奇异值的和)。将低秩方法用于图像复原的数学模型可以写为:

$$(\hat{\mathbf{U}}, \hat{\Sigma}, \hat{\mathbf{V}}) = \arg \min_{\mathbf{U}, \Sigma, \mathbf{V}} \|\mathbf{B} - k * (\mathbf{U} \Sigma \mathbf{V})\|_2^2 + \lambda \|\Sigma\|_1 . \quad (21)$$

其中 \mathbf{U} 和 \mathbf{V} 是正交矩阵, Σ 为奇异值矩阵。基于低秩的复原方法(Low Rank based Deconvolution, LRD)^[76] 通过设计一种交替迭代法, 将低秩滤波有效地整合到图像复原问题中, 并在正则化参数的选取上采用自适应方法, 取得了与 GSR^[71] 算法同等效果。

无论是字典学习还是块匹配(包括低秩)等, 都需要较大的计算量, 再加上迭代法需要这些过程多次反复, 所以要花费大量的计算时间。为了降低计算复杂度, 同时又能够使其达到可接受的复原效果, 一些快速滤波方法被引入到图像复原中。边缘保持滤波器一直是计算机图形图像领域最受重视的研究之一, 其目的是对图像进行平滑并且要保持边缘不模糊。双边滤波^[77]、非局部均值滤波^[28]、引导滤波等^[78]都是这类滤波器的典型代表。但是由于快速边缘保

持滤波器去除遗漏噪声的能力相对较弱, 因此不适于用直接法进行图像复原, 而迭代法则能够通过循环反馈, 层层递进的方式, 让快速边缘保持滤波器在图像复原中发挥作用^[33,79]。基于边缘保持滤波器的非盲图像复原模型一般可以写为:

$$\hat{\mathbf{L}} = \arg \min_L \|\mathbf{B} - k * \mathbf{L}\|_2^2 + \lambda \|\mathbf{L} - EWF(\mathbf{L})\|_2^2 , \quad (22)$$

其中 EWF(Edge Ware Filter) 表示边缘保持滤波器。

该模型可转化为如下迭代格式进行求解:

$$\mathbf{L}^{n+1} = \arg \min_L \|\mathbf{B} - k * \mathbf{L}\|_2^2 + \lambda \|\mathbf{L} - \mathbf{w}^n\|_2^2 , \quad (23)$$

$$\mathbf{w}^{n+1} = EWF(\mathbf{L}^{n+1}) . \quad (24)$$

当然, 迭代方式也可以采用其他分离变量的迭代格式, 如 Landweber^[52]、ADMM^[52] 等。

在传统方法中, 机器学习的方法^[80-81]也占有席之地。不同于深度学习技术, 这类方法主要使用传统的机器学习技术, 例如高斯混合模型^[82]、随机场^[83] 等。Roth 和 Black^[83] 最先通过学习表达性强的高阶马尔科夫随机场(Markov Random Field, MRF)先验对图像建模, 提出了专家场(Fields of Experts, FoE)框架。该框架下 MRF 中所有的滤波器参数均由训练数据得到, 但该方法由于目标函数的难解性, 学习过程中使用了对比散度, 导致该模型学习非常困难。Zoran 和 Weiss 等人^[82] 提出了期望块对数似然(Expected Patch Log Likelihood, EPLL)模型。该模型首先使用高斯混合模型从大量自然图像块中学习到图像的先验, 并采用最大后验(Maximum A-Posteriori, MAP)估计来对图像进行滤波, 通过 EM 迭代来求解。EPLL 方法最大的特点是不对整幅图像进行全局对数似然近似, 而是对局部图像块(patch)进行建模, 不仅降低了学习难度同时也提升了复原效果。该方法也是比较常用的学习类方法之一。收缩场^[84](Shrinkage fields)方法将随机场与最优化方法相结合, 提出了级联收缩场模型, 学习出用于图像恢复的有效图像滤波器和收缩函数。Chen 等^[85] 通过参数化线性滤波器和训练非线性反应扩散模型来实现图像复原。虽然这些方法获得了不错的图像质量, 但这些学到的先验知识或惩罚函数通常

需要设计复杂的数值算法。

迭代法的复原效果主要取决于3个因素:(1)正则项(图像先验)的选取;(2)迭代格式的设计(关系到是否收敛、收敛精度和速度);(3)正则化参数的选取。其中正则化参数十分重要,首先迭代法的收敛性需要依靠正则化参数,在正则化参数超出某个范围时,迭代法是不收敛的或者说最优化问题本身将是不稳定的,其次,正则化参数直接关系到迭代法是否能收敛到最优结果,即能否获得与真实清晰图像最接近的结果。正则化参数选取方面的研究相对较少,虽然有一些论文给出了一些准则,例如NCSR^[70]、GFD^[33]等,但是到现今为止,并没有一种通用的理论或者方法能自适应计算出正则化参数。因为正则化参数涉及到清晰图像、噪声以及点扩散函数3方面综合影响,具有较高的复杂性。

与直接法类似,为了对迭代法的复原效果进行更好的总结,采用6组标准实验设置(见表3),分别对4幅标准图像:Cameraman、House、Lena和Barbara进行实验,对8种代表性迭代法进行实验对比:L0-Abs^[62]、CGMK^[36]、TVMM^[34]、GFD^[33]、NCSR^[70]、GSR^[71]、IDDBM3D^[73]、LRD^[76],另外,为了与直接法进行一定的比较,在对比中加入了BM3DDEB^[31]算法的结果,算法的评价标准依然采用ISNR。

表3 迭代法实验设置

Tab. 3 Experimental setup for iterative methods

序号	点扩散函数	噪声水平
1	$k(x,y) = 1/(x^2 + y^2)$, $x,y = -7, \dots, 7$	$\sigma^2 = 2$
2	$k(x,y) = 1/(x^2 + y^2)$, $x,y = -7, \dots, 7$	$\sigma^2 = 8$
3	9×9 boxcar	$BSNR = 40$ dB
4	$k = [1, 4, 6, 4, 1]^T [1, 4, 6, 4, 1] / 256$	$\sigma^2 = 49$
5	Gaussian型点扩散函数, 方差为1.6	$\sigma^2 = 2$
6	Gaussian型点扩散函数, 方差为0.4	$\sigma^2 = 64$

表4给出了以上9种算法的复原结果,其中标下划线数值表示该组实验中最优的结果,加粗数值表示次最优的结果,从中可以明显看出,GSR^[71]和LRD^[76]算法具有较大的优势。表4中的数据来源于文献[33,71,73,76]。

表4 迭代法实验对比ISNR

Tab. 4 Experimental comparison of ISNR (单位: dB)

方法	实验序号					
	1	2	3	4	5	6
Cameraman						
BM3DDEB ^[31]	8.19	6.40	8.34	3.34	3.73	4.70
L0-Abs ^[62]	7.70	5.55	9.10	2.93	3.49	1.77
CGMK ^[36]	7.80	5.49	9.15	2.80	3.54	3.33
TVMM ^[34]	7.41	5.17	8.54	2.57	3.36	1.30
GFD ^[33]	8.38	6.52	9.73	3.57	4.02	-
NCSR ^[70]	8.78	6.69	10.33	3.78	4.60	4.50
GSR ^[71]	8.39	6.39	10.08	3.33	3.94	4.76
IDDBM3D ^[73]	8.85	<u>7.12</u>	10.45	3.98	4.31	<u>4.89</u>
LRD ^[76]	<u>8.90</u>	7.05	<u>10.70</u>	<u>3.99</u>	<u>4.62</u>	4.62
House						
BM3DDEB ^[31]	9.32	8.14	10.85	5.13	4.56	<u>7.21</u>
L0-Abs ^[62]	8.40	7.12	11.06	4.55	4.80	2.15
CGMK ^[36]	8.31	6.97	10.75	4.48	4.97	4.59
TVMM ^[34]	7.98	6.57	10.39	4.12	4.54	2.44
GFD ^[33]	9.39	7.75	12.02	5.21	5.39	-
NCSR ^[70]	9.96	8.48	13.12	5.81	5.67	6.94
GSR ^[71]	10.02	8.56	13.44	6.00	5.95	7.18
IDDBM3D ^[73]	9.95	8.55	12.89	5.79	5.74	7.13
LRD ^[76]	<u>10.09</u>	<u>8.67</u>	<u>13.49</u>	<u>6.03</u>	<u>6.22</u>	6.74
Lena						
BM3DDEB ^[31]	7.95	6.53	7.97	4.81	4.37	6.40
L0-Abs ^[62]	<u>6.66</u>	5.71	7.79	4.09	4.22	1.93
CGMK ^[36]	6.76	5.37	7.86	3.49	3.93	4.46
TVMM ^[34]	6.36	4.98	7.47	3.52	3.61	2.79
GFD ^[33]	8.12	6.65	8.97	4.77	4.95	-
NCSR ^[70]	8.03	6.54	9.25	4.93	4.86	6.19
GSR ^[71]	8.24	6.76	<u>9.43</u>	<u>5.17</u>	4.96	<u>6.57</u>
IDDBM3D ^[73]	7.97	6.61	8.91	4.97	4.85	6.34
LRD ^[76]	<u>8.25</u>	<u>6.78</u>	9.31	5.13	<u>5.08</u>	6.13
Barbara						
BM3DDEB ^[31]	7.80	3.94	5.86	1.90	1.28	5.80
L0-Abs ^[62]	3.51	1.53	3.98	0.73	0.81	1.17
CGMK ^[36]	2.45	1.34	3.55	0.44	0.81	0.38
TVMM ^[34]	3.10	1.33	3.49	0.41	0.75	0.59
NCSR	7.76	3.64	5.92	2.06	1.43	5.50
GSR ^[71]	<u>8.98</u>	4.80	<u>7.15</u>	2.19	1.58	<u>6.20</u>
IDDBM3D ^[73]	7.64	3.96	6.05	1.88	1.16	5.45
LRD ^[76]	8.31	<u>5.17</u>	6.95	<u>2.34</u>	<u>1.70</u>	5.37

3 非盲图像复原中的深度学习方法

近年来,深度学习技术为计算机视觉各个领域带来了巨大的变革。深度学习能够使用高度非线性的复杂结构学习出需要的图像特征,大大提升了图像理解的能力。不同于依赖物理模型的传统方法,深度学习是一类由数据驱动的方法,其通过训练找到输入与输出之间的映射关系,解决了许多传统方法很难处理的问题,并在核心指标上带来了质的提升。因此用深度学习技术进行图像复原已经成为主流,越来越多的学者专注于研究利用深度网络模型来提升图像的复原效果^[86-88]。

多层感知机方法^[89](Multi-Layer Perceptron, MLP)是较早采用深度网络进行非盲图像复原的方法,但并不适用于图像处理的卷积网络,而是适用于带有多个隐层的全连接网络。该方法首先用吉洪诺夫正则化解卷积,然后对解卷积之后的图像利用MLP进行去噪。学习过程中,将解卷积之后的图像和清晰图像作为训练集,

取得了和IDDBM3D同等水平的效果。但是MLP方法存在一个问题:对于每一个点扩散函数和噪声水平,都要单独训练一个网络,这大大限制了其应用性,Xu等人^[90]也采用多层感知机的方法进行图像复原。与MLP方法不同的是,该方法中使用一个解卷积网络来代替吉洪诺夫正则化,并将解卷积的结果输入到一个去噪网络中。以上利用深度网络进行非盲图像复原的方法可以归类为直接法。

目前基于深度学习的非盲图像复原方法以迭代法^[91-93]为主。2017年,Kai Zhang团队^[93]和Jinshan Pan团队^[94]先后将卷积深度网络与传统迭代方法相结合,将深度网络作为去噪工具,构造非盲图像复原方法。这类方法与传统的迭代法属于同一种思路,优点是通过端到端的卷积网络的非线性拟合能力提升整体复原效果,去噪网络均采用全卷积结构,由卷积层,整流线性单元(Rectified Linear Unit, ReLU)层和批量标准化(Batch Normalization, BN)层组成,例如,在文献[93]中,作者使用一个端到端的残差卷积网络完成解卷之后的去噪,其去噪网络结构如图6所示。

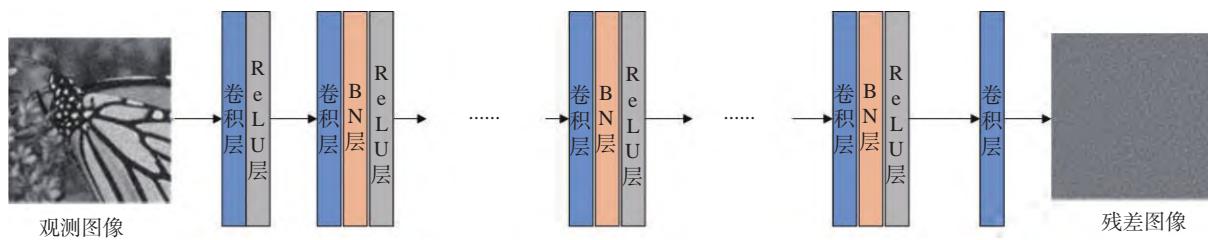


图6 文献[93]中使用的去噪网络结构

Fig. 6 Denoising Network structure^[93]

Weisheng Dong团队^[95]在2019年提出了采用Unet^[96]结构的滤波网络进行反卷积,核心思想是将Unet网络整合到一种迭代格式中,但每层迭代中的Unet网络单独训练参数,进而达到提升图像复原效果的目的。绝大多数的卷积网络参数都是实数,而Quan等人^[97]首次提出一种复值(Complex Value,CV)卷积网络作为去噪方法(CV-CNN)。结合逆滤波和最优化格式获得复原图像,是当前复原效果最好的算法之一,其算法流程如图7所示。

Chen等人^[98]提出一种处理夜景模糊图像的非盲复原方法,核心是提出一个深度卷积网络学

习置信度图(confidence map)。该置信图表示每个像素点对复原的影响程度,并利用共轭梯度法进行解卷积,然后再用一个深度卷积网络抑制解卷积后的噪声和振铃。另一个值得注意的是,这篇论文还提出了一种通过深度网络自适应学习正则化参数的方法,这为参数的自适应确定提供了一种研究思路。以上介绍的深度学习方法和传统迭代法本质上类似,都是将深度网络作为遗漏噪声滤波器来使用,运用卷积网络强大的非线性拟合能力,结合传统的迭代格式,在复原效果的提升上取得了长足的进步。

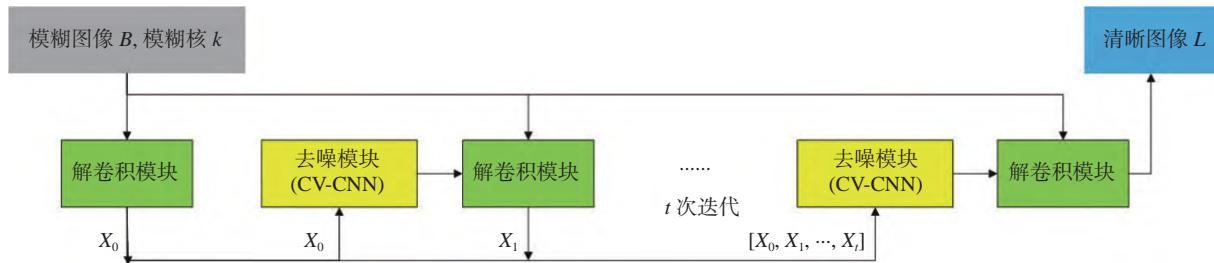


图 7 基于 CV-CNN 网络的图像复原框架^[97]

Fig. 7 The image restoration framework based on CV-CNN network^[97]

另外,很多非盲图像问题是在对噪声水平有一定认知的情况下进行的,而 VEM 方法^[99]提出了一种能处理噪声强度不确定(也称之为盲噪声)的深度学习方法。该方法基于变分期望最大化框架,将噪声强度估计与图像先验不确定性量化进行整合。而文献 [97,100] 中的方法同样适用于这种盲噪声的复原问题。DWDN^[101] 方法在深层特征空间中探索维纳(Wiener)反卷积,并根据模糊特征自适应估计噪声水平,确保训练单个模型能够处理不同级别的噪声。该方法首先从模糊图像中提取有用的特征信息,然后在(深层)特征空间中进行维纳反卷积,最后再使用一个多尺度的端到端网络进行图像的复原(非迭代法),DWDN 方法取得了非常好的复原效果。

深度图像先验^[102](deep image prior)是一种对深度网络本质的探索,认为图像的统计学信息是被卷积的图像产生的而不是被网络学习得到的,因此能够利用未被训练的卷积网络来处理图像复原问题^[103-105]。该模型不需要训练数据,只需要一张模糊图像和一个合适的网络即可,通过对目标函数的迭代来优化网络参数,最终达到复原目的。该类方法最大的问题是迭代次数多,速度慢,且何时迭代终止没有理论依据^[106-108]。

在传统方法中,利用机器学习方法的复原思想,例如 EPLL^[82]、CSF^[84]等,在深度学习领域也得到了进一步的延伸,如文献 [109-111] 等方法,通过深度神经网络学习一系列的滤波器、惩罚函数(正则项),以及保真项等来进一步降低图像的重构误差,提升图像复原效果。特别是 SV-MAP^[110]方法是当前图像复原领域中最好的方法之一。与现有的专注于改进保真项或正则化项的方法不同,SV-MAP 方法是在统一的 MAP 框架中联合学习这两个项。为了增强模型的性能,作者提出

了针对每一个图像像素的自适应保真网络 D^s 和自适应正则项网络 R^s :

$$D^s(B, L, k) = \sum_{i=1}^M \sum_p D_{i,p} (f_{i,p} * (B - k * L)_{(p)}) \quad , \quad (25)$$

$$R^s(L) = \sum_{j=1}^N \sum_p R_{j,p}(g_{i,p} * L_{(p)}) \quad . \quad (26)$$

通过实验表明,联合学习保真项和正则化项比单独学习其中一项更有效,特别是在具有挑战性的情况下,效果更加明显。

为了比较各种深度学习方法在非盲图像复原中的效果,进行了8组实验对比。利用3个被广泛采用的数据集作对比实验,分别是Levin数据集^[106]、Sun数据集^[107]和Martin数据集^[108]。这3个数据集包括多种类型的清晰图像和点扩散函数。与绝大多数文献的对比实验配准相同,设置加性噪声的标准差如下:针对Levin数据集^[106],标准差水平分别设置为1%、3%和5%,针对Sun数据集^[107]和Martin数据集^[108],标准差水平分别设置为1%和5%。

对比实验包括 11 种基于深度学习的图像复原方法,分别是:MLP^[89]、LDT^[109]、FCN^[94]、IRCNN^[93]、FDN^[87]、FNBD^[88]、RGDN^[92]、VEM^[99]、DWDN^[101]、CV-CNN^[97]以及 SV-MAP^[110],另外为了能够和传统方法进行比较,在对比实验中也加入了两种机器学习类的传统方法:EPPLL^[82]和CSF^[84]。

对比实验采用的评价指标是 PSNR 和 SSIM^[112], 表 5 中每一种方法实验结果的第一行是 PSNR 值, 单位是分贝(dB), 第二行是 SSIM 值(无单位)。依然将每组实验中最好的结果标记为下划线, 次最优的结果标记为加粗。(表 5 中的数据来源于文献 [97,101,110])。

表5 深度学习方法的实验对比
Tab. 5 Experimental comparison of deep learning of different methods

σ	Levin ^[106]			Sun ^[107]		Martin ^[108]	
	1%	3%	5%	1%	5%	1%	5%
EPLL ^[82]	34.06	29.09	26.54	32.48	26.78	29.81	24.66
	0.9310	0.8460	0.7785	0.8815	0.6975	0.8383	0.6276
CSF ^[84]	31.09	28.01	26.32	31.52	26.62	29.00	24.93
	0.9024	0.8013	0.7427	0.8622	0.6735	0.8230	0.6428
MLP ^[89]	32.08	27.00	25.38	31.47	24.65	28.47	24.01
	0.8884	0.7016	0.6330	0.8535	0.5198	0.7977	0.5619
LDT ^[109]	31.53	28.39	26.70	30.52	26.71	28.20	24.90
	0.8977	0.8052	0.7468	0.8399	0.6694	0.7922	0.6358
FCN ^[94]	33.22	29.49	27.72	32.36	27.67	29.51	25.45
	0.9267	0.8599	0.8142	0.8853	0.7340	0.8339	0.6771
IRCNN ^[95]	34.33	30.04	28.51	33.57	27.64	30.63	25.65
	0.9210	0.8156	0.7762	0.8977	0.6884	0.8645	0.6640
FDN ^[87]	34.05	29.77	27.94	32.63	27.75	29.93	25.93
	0.9335	0.8583	0.8139	0.8887	0.7319	0.8555	0.6943
FNBD ^[88]	34.81	30.63	27.93	31.22	27.63	30.92	25.49
	0.9398	0.8658	0.7759	0.8860	0.7010	0.8799	0.6589
RGDN ^[92]	33.96	29.71	27.45	31.25	26.93	29.51	25.33
	0.9395	0.8662	0.7889	0.8869	0.7161	0.8616	0.6688
VEM ^[99]	34.31	30.50	28.52	32.73	29.41	—	—
	0.9382	0.8798	0.8348	0.8952	0.8055	—	—
DWDN ^[101]	<u>36.90</u>	<u>32.77</u>	<u>30.77</u>	34.05	—	31.74	—
	<u>0.9614</u>	<u>0.9179</u>	<u>0.8857</u>	0.9225	—	0.8938	—
CV-CNN ^[97]	35.44	30.85	28.80	33.10	<u>29.54</u>	—	—
	0.9467	0.8829	0.8381	0.9022	<u>0.8094</u>	—	—
SVMAP ^[110]	—	—	—	<u>34.51</u>	29.20	<u>31.89</u>	<u>27.25</u>
	—	—	—	<u>0.9273</u>	0.7940	<u>0.8973</u>	<u>0.7550</u>

4 其他非盲图像复原方法

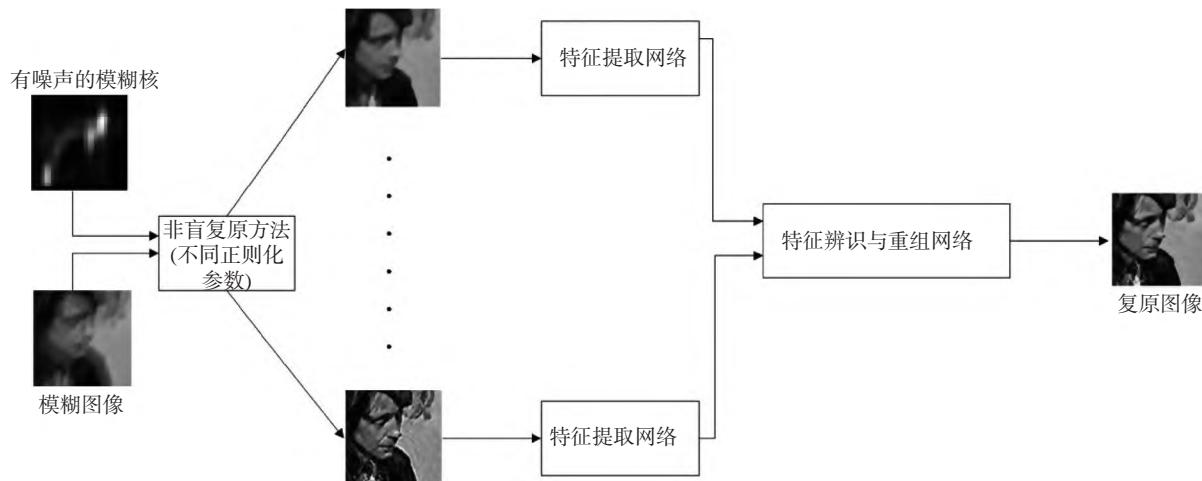
针对非盲图像复原的一些特殊问题,如点扩散函数不确定、点扩散函数全局不一致等问题,也产生了一些相应的非盲图像复原算法。

4.1 点扩散函数不确定问题

绝大多数非盲图像复原都是在点扩散函数准确获得的前提下进行的,但是在很多实际应用中,已知的点扩散函数与真实点扩散函数存在偏差,例如在盲复原过程中,估计出的点扩散函数与真实值是有误差的,因此在这种情况下如何能够更准确地估计清晰图像,是一个值得思考的问题。目前这方面的算法并不多,文献[113-116]是其中

具有代表性的论文。其中Ji等人^[114]利用传统迭代方法,利用框架波(framelet)和离散余弦变换(Discrete Cosine Transform, DCT)对图像和振铃分别进行稀疏表示,进而达到抑制点扩散函数误差的目的。但是受制于传统先验的局限性,该方法的适用性受到限制。Vasu等人^[115]首先使用多组正则化参数,利用全变差模型对模糊图像进行非盲图像复原,然后构建一个深度融合网络,将这些全变差模型复原后的图像作为输入,输出图像为清晰图像,其核心思想是利用不同正则化参数获取的初始图像在频域信息上具有互补性。该方法的流程图见图8。

Nan等人^[116],通过构造一个最优化模型,设置两个正则项,分别对应清晰图像的先验和由点

图 8 Vasu 等人提出的网络结构^[115]Fig. 8 The network structure proposed by Vasu^[115]

扩散函数误差引起的校正项先验(在思想上和文献[114]有一定的相似):

$$\min_{L,u} \|B - \hat{k} * L\|_2^2 + \phi(L) + \varphi(u|L) \quad , \quad (27)$$

其中 L 为清晰图像, u 为校正图像, \hat{k} 表示带有误差的点扩散函数, ϕ 和 φ 均采用了深度特征先验。该模型通过分离变量法, 构建多个子优化问题来求解, 特别是在求解校正图像时, 采用了双通道的 Unet^[96] 模型。

以上两种基于深度学习的方法各有优点, Vasu 等人^[115] 的方法简洁明确易懂, 但缺少足够的理论支撑, 而 Nan 等人^[116] 的方法通过迭代求解, 虽然效果较好, 但是复杂度相对较高。

4.2 全局非一致模糊问题

绝大多数非盲复原问题都是一致模糊问题, 即对于所有像素而言, 点扩散函数是相同的。而在一些实际问题中, 点扩散函数随着空间位置的不同而不同, 这种问题称之为全局非一致模糊问题。实际上很多全局一致模糊复原方法都可以扩展到全局非一致问题中, 特别是图像的迭代格式、图像的正则项(包括图像先验)等, 都具有可扩展性, 最大的差别在于解卷积时, 不再采用类似吉洪诺夫正则化或者维纳正则化这种基于傅立叶变换的快速计算模式, 而是需要较为复杂的一些矩阵运算^[117-119]。例如 Tai 等人^[118] 在传统的 LR 迭代基础上添加新的正则项, 并改进 LR 的迭代格式以适应这种空间变化点扩散函数的图像复原。这种非一致点扩散复原问题在盲图像复原中

讨论较多^[120-121], 特别是随着深度学习的发展, 采用生成对抗网络 (Generative Adversarial Net, GAN)^[121] 处理这类问题成为主流, 即不再需要估计点扩散函数, 而是直接由模糊图像生成清晰图像。对于 GAN 等相关的生成网络, 在非盲图像复原的实际应用中有着重要的价值, 当光学系统和观测场景较为稳定时, 点扩散函数形式较为固定, 因此可以通过针对性的端到端训练, 将点扩散函数的信息融合到网络中, 从而避免了传统方法中的反卷积运算, 降低运算量, 同时能够获得复原质量较高的图像。另外, 依靠生成网络的泛化能力, 也可以应对点扩散函数有限变化的情况, 这相对于其他依赖反卷积的方法具有很大的优势。

4.3 其他

值得注意的是, 在盲图像复原中也有一些新颖的先验, 例如暗通道先验^[122]、 L_0 先验^[57]、局部最大梯度先验^[123](Local Maximum Gradient Prior) 等, 虽然没有单独提出作为非盲图像复原算法, 但是也具有一定的参考价值。

5 总结与展望

本文依据非盲图像复原的发展脉络, 将主要的复原方法按照传统方法和深度学习方法分别进行概括总结。在传统方法中, 按照算法的特点分为直接法和迭代法, 描述并分析了主要算法的优缺点并给出实验对比。从中可以看出, 全变差模型、小波模型、自适应基底模型(包括字典学习模

型)、块相似模型和机器学习模型是学者们研究的重点,也能够代表主要的非盲图像复原方法。在深度学习方法中,主要总结了近年来具有代表性的一些网络结构和模型,并同样给出了实验对比。从深度学习算法总结中可以发现,一部分深度学习方法是传统方法在深度学习领域的延伸,例如 MLP 方法是直接法的延伸、FCN 和 IRCNN 是迭代法的延伸、SV-MAP 是机器学习方法的延伸,等。由此可以看出,基于深度学习的图像复原方法并不是独立于传统方法存在的,而是与传统方法有着千丝万缕的联系,掌握好传统方法的精髓,也可以在深度学习领域有较大的施展空间。

对于非盲图像复原而言,解卷积和抑制噪声是一对矛盾体,如何平衡好这两者,构造合适的算法结构是研究的重点。同时遗漏噪声的处理能力是一个算法能否取得较高评价指标的核心因素,正则化参数选取也是影响算法的重要因素,需要将一些注意力放在这几个方面。

现在绝大多数方法(包括一部分深度学习方

法)依赖于图像模糊的物理模型,而物理模型往往是实际问题的简化,具有一定的局限性,因此解决如何面向实际问题的应用是非盲图像复原算法研究的一个重要问题,即在物理模型存在一定误差的情况下,图像复原方法依然有效。

随着计算机视觉的迅猛发展,深度学习技术也发挥着越来越重要的作用,很多传统方法很难处理的问题,深度学习方法都能够给出一定的解答。从以上实验对比可以发现,在一些标准数据库上,深度学习方法在效果上已经大大领先传统方法,而其泛化性也在随着网络模型的更新,不断改善。这种由数据驱动的处理思想,已经成为非盲图像复原发展的主流,也给一些传统思路难以解决的问题带来了新的希望,例如基于传统图像复原思想进行深度学习“升级”的方法取得了高质量的复原效果,在天文、生物医药等需要高精度图像的领域可以获得较大的关注,基于生成对抗网络及其相关网络可以在视频监控等环境较为单一,但实时度需求较高的问题中得到广泛的应用。

参考文献:

- [1] STARCK J L, PANTIN E, MURTAGH F. Deconvolution in astronomy: a review[J]. *Publications of the Astronomical Society of the Pacific*, 2002, 114(800): 1051-1069.
- [2] JAIN A K. *Fundamentals of Digital Image Processing*[M]. Upper Saddle River: Prentice-Hall, 1989: 1420-1424.
- [3] 沈垣, 李舜酩, 毛建国, 等. 数字图像复原技术综述[J]. 中国图像图形学报, 2009, 14(9): 1764-1775.
- [4] SHEN H, LI SH M, MAO J G, et al.. Digital image restoration techniques: a review[J]. *Journal of Image and Graphics*, 2009, 14(9): 1764-1775. (in Chinese)
- [5] 闫敬文, 彭鸿, 刘蕾, 等. 基于L0正则化模糊核估计的遥感图像复原[J]. 光学精密工程, 2014, 22(9): 2572-2579.
- [6] YAN J W, PENG H, LIU L, et al.. Remote sensing image restoration based on zero-norm regularized kernel estimation[J]. *Optics and Precision Engineering*, 2014, 22(9): 2572-2579. (in Chinese)
- [7] 李东升, 陈春晓, 王章立, 等. 基于全局方差和噪声估计的维纳滤波图像的复原方法[J]. 生物医学工程研究, 2017, 36(4): 331-335.
- [8] LI D SH, CHEN CH X, WANG ZH L, et al.. Wiener filter image restoration based on global variance and noise estimation[J]. *Journal of Biomedical Engineering Research*, 2017, 36(4): 331-335. (in Chinese)
- [9] 朱非甲, 金鹏. 面向工业检测的图像快速去直线运动模糊方法[J]. 哈尔滨工业大学学报, 2018, 50(9): 123-129.
- [10] ZHU F J, JIN P. Fast moving line motion de-blurring for image detection of industrial inspection[J]. *Journal of Harbin Institute of Technology*, 2018, 50(9): 123-129. (in Chinese)
- [11] 陈灏. 光学稀疏孔径成像系统图像恢复算法研究[D]. 杭州: 浙江大学, 2017.
- [12] CHEN H. Image restoration algorithm for optical sparse aperture systems[D]. Hangzhou: Zhejiang University, 2017. (in Chinese)
- [13] 杨航. 图像反卷积算法研究[D]. 长春: 吉林大学, 2012: 3-7.
- [14] YANG H. The study on image deconvolution algorithm[D]. Changsha: Jilin University, 2012: 3-7. (in Chinese)
- [15] HANSEN P C. *Rank-Deficient and Discrete Ill-Posed Problems: Numerical Aspects of Linear Inversion*[M]. Philadelphia: SIAM, 1997.

- [10] FAN J Q, KOO J. Wavelet deconvolution[J]. *IEEE Transactions on Information Theory*, 2002, 48(3): 734-747.
- [11] JOHNSTONE I M, KERKYACHARIAN G, PICARD D, et al.. Wavelet deconvolution in a periodic setting[J]. *Journal of the Royal Statistical Society. Series B*, 2004, 66(3): 547-573.
- [12] PENSKY M, VIDAKOVIC B. Adaptive wavelet estimator for nonparametric density deconvolution[J]. *Annals of Statistics*, 1999, 27(6): 2033-2053.
- [13] DONOHO D L. Nonlinear solution of linear inverse problems by wavelet-vaguelette decomposition[J]. *Applied and Computational Harmonic Analysis*, 1995, 2(2): 101-126.
- [14] KALIFA J, MALLAT S, ROUGE B. Deconvolution by thresholding in mirror wavelet bases[J]. *IEEE Transactions on Image Processing*, 2003, 12(4): 446-457.
- [15] NEELAMANI R, CHOI H, BARANIUK R. ForWaRD: Fourier-wavelet regularized deconvolution for Ill-conditioned systems[J]. *IEEE Transactions on Signal Processing*, 2004, 52(2): 418-433.
- [16] CANDÈS E, DEMANET L, DONOHO D L, et al.. Fast discrete curvelet transforms[J]. *Multiscale Modeling & Simulation*, 2006, 5(3): 861-899.
- [17] DO M N, VETTERLI M. The contourlet transform: an efficient directional multiresolution image representation[J]. *IEEE Transactions on Image Processing*, 2005, 14(12): 2091-2106.
- [18] EASLEY G R, LABATE D, LIM W Q. Sparse directional image representations using the discrete shearlet transform[J]. *Applied and Computational Harmonic Analysis*, 2008, 25(1): 25-46.
- [19] DEMANET L, YING L X. Wave atoms and sparsity of oscillatory patterns[J]. *Applied and Computational Harmonic Analysis*, 2007, 23(3): 368-387.
- [20] NEELAMANI R N, DEFFENBAUGH M, BARANIUK R G. Texas two-step: a framework for optimal multi-input single-output deconvolution[J]. *IEEE Transactions on Image Processing*, 2007, 16(11): 2752-2765.
- [21] PATEL V M, EASLEY G R, HEALY D M. Shearlet-based deconvolution[J]. *IEEE Transactions on Image Processing*, 2009, 18(12): 2673-2685.
- [22] YANG H, ZHANG ZH B. Fusion of wave atom-based wiener shrinkage filter and joint non-local means filter for texture-preserving image deconvolution[J]. *Optical Engineering*, 2012, 51(6): 067009.
- [23] PORTILLA J, SIMONCELLI E. Image restoration using Gaussian scale mixtures in the wavelet domain[C]. *Proceedings 2003 International Conference on Image Processing, IEEE*, 2003: II -965.
- [24] GUERRERO-COLON J A, MANCERA L, PORTILLA J. Image restoration using space-variant Gaussian scale mixtures in overcomplete pyramids[J]. *IEEE Transactions on Image Processing*, 2008, 17(1): 27-41.
- [25] XUE F, LUISIER F, BLU T. Multi-wiener SURE-LET deconvolution[J]. *IEEE Transactions on Image Processing*, 2013, 22(5): 1954-1968.
- [26] KATKOVNIK V, EGIAZARIAN K O, ASTOLA J. A spatially adaptive nonparametric regression image deblurring[J]. *IEEE Transactions on Image Processing*, 2005, 14(10): 1469-1478.
- [27] FOI A, DABOV K, KATKOVNIK V, et al.. Shape-adaptive DCT for denoising and image reconstruction[J]. *Proceedings of SPIE*, 2006, 6064: 203-214.
- [28] BUADES A, COLL B, MOREL J. Nonlocal image and movie denoising[J]. *International Journal of Computer Vision*, 2008, 76(2): 123-139.
- [29] CHEN F, HUANG X J, CHEN W F. Texture-preserving image deblurring[J]. *IEEE Signal Processing Letters*, 2010, 17(12): 1018-1021.
- [30] DABOV K, FOI A, KATKOVNIK V, et al.. Image denoising by sparse 3-D transform-domain collaborative filtering[J]. *IEEE Transactions On Image Processing*, 2007, 16(8): 2080-2095.
- [31] DABOVE K, FOI A, KATKOVNIK V, et al.. Image restoration by sparse 3D transform-domain collaborative filtering[J]. *Proceedings of SPIE*, 2008, 6812: 681207.
- [32] BANHAM M R, KATSAGGELOS A K. Spatially adaptive wavelet-based multiscale image restoration[J]. *IEEE Transactions on Image Processing*, 1996, 5(4): 619-634.
- [33] YANG H, ZHANG ZH B, GUAN Y J. An adaptive parameter estimation for guided filter based image deconvolution[J]. *Signal Processing*, 2017, 138: 16-26.
- [34] WANG Y L, YANG J F, YIN W T, et al.. A new alternating minimization algorithm for total variation image reconstruction[J]. *SIAM Journal on Imaging Sciences*, 2008, 1(3): 248-272.

- [35] CHO S, WANG J, LEE S. Handling outliers in non-blind image deconvolution[C]. *Proceedings of 2011 International Conference on Computer Vision, IEEE*, 2011: 495-502.
- [36] CHANTAS G, GALATSANOS N P, MOLINA R, et al.. Variational Bayesian image restoration with a product of spatially weighted total variation image priors[J]. *IEEE Transactions on Image Processing*, 2010, 19(2): 351-362.
- [37] WEN Y W, NG M K, CHING W K. Iterative algorithms based on decoupling of deblurring and denoising for image restoration[J]. *SIAM Journal on Scientific Computing*, 2008, 30(5): 2655-2674.
- [38] TAKEDA H, FARSIU S, MILANFAR P. Deblurring using regularized locally adaptive kernel regression[J]. *IEEE Transactions on Image Processing*, 2008, 17(4): 550-563.
- [39] LUCY L B. An iterative technique for the rectification of observed distributions[J]. *Astronomical Journal*, 1974, 79: 745.
- [40] WHYTE O, SIVIC J, ZISSEMAN A. Deblurring shaken and partially saturated images[C]. *Proceedings of 2011 IEEE International Conference on Computer Vision Workshops, IEEE*, 2011: 745-752.
- [41] RUDIN L I, OSHER S, FATEMI E. Nonlinear total variation based noise removal algorithms[J]. *Physica D:Nonlinear Phenomena*, 1992, 60(1-4): 259-268.
- [42] BECK A, TEBOULLE M. Fast gradient-based algorithms for constrained total variation image denoising and deblurring problems[J]. *IEEE Transactions on Image Processing*, 2009, 18(11): 2419-2434.
- [43] CHAN T F, GOLUB G H, MULET P. A nonlinear primal-dual method for total variation-based image restoration[J]. *SIAM Journal on Scientific Computing*, 1999, 20(6): 1964-1977.
- [44] CHEN D Q, ZHANG H, CHENG L ZH. A fast fixed point algorithm for total variation deblurring and segmentation[J]. *Journal of Mathematical Imaging and Vision*, 2012, 43(3): 167-179.
- [45] SHI F, CHENG J, WANG L, et al.. LRTV: MR image super-resolution with low-rank and total variation regularizations[J]. *IEEE Transactions on Medical Imaging*, 2015, 34(12): 2459-2466.
- [46] RUDIN L I, OSHER S. Total variation based image restoration with free local constraints[C]. *Proceedings of 1st International Conference on Image Processing, IEEE*, 1994: 31-35.
- [47] 童蓓蕾. 基于变分法的图像复原算法研究[D]. 合肥: 中国科学技术大学, 2018.
- [48] TONG B L. Research of image restoration algorithm based on variational method[D]. Hefei: University of Science and Technology of China, 2018. (in Chinese)
- [49] OSHER S, BURGER M, GOLDFARB D, et al.. An iterative regularization method for total variation-based image restoration[J]. *SIAM Journal on Multiscale Model & Simulation*, 2005, 4(2): 460-489.
- [50] GOLDSTEIN T, OSHER S. The split Bregman method for L1-regularized problems[J]. *SIAM Journal on Imaging Sciences*, 2009, 2(2): 323-343.
- [51] BIOUCAS-DIAS J M, FIGUEIREDO M A T. A new TwIST: two-step iterative shrinkage/thresholding algorithms for image restoration[J]. *IEEE Transactions on Image Processing*, 2007, 16(12): 2992-3004.
- [52] MICHAILOVICH O V. An iterative shrinkage approach to total-variation image restoration[J]. *IEEE Transactions on Image Processing*, 2011, 20(5): 1281-1299.
- [53] VONESCH C, UNSER M. A fast thresholded landweber algorithm for wavelet-regularized multidimensional deconvolution[J]. *IEEE Transactions on Image Processing*, 2008, 17(4): 539-549.
- [54] NG M K, WEISS P, YUAN X M. Solving constrained total-variation image restoration and reconstruction problems via alternating direction methods[J]. *SIAM Journal on Scientific Computing*, 2010, 32(5): 2710-2736.
- [55] OLIVEIRA J P, BIOUCAS-DIAS J M, FIGUEIREDO M A T. Adaptive total variation image deblurring: a majorization-minimization approach[J]. *Signal Processing*, 2009, 89(9): 1683-1693.
- [56] KRISHNAN D, FERGUS R. Fast image deconvolution using hyper-Laplacian priors[C]. *Proceedings of the 22nd International Conference on Neural Information Processing Systems, Curran Associates Inc.*, 2009: 1033-1041.
- [57] DONOHO D L. Compressed sensing[J]. *IEEE Transactions on Information Theory*, 2006, 52(4): 1289-1306.
- [58] PAN J SH, HU ZH, SU ZH X, et al.. L_0 -regularized intensity and gradient prior for deblurring text images and beyond[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(2): 342-355.
- [59] FIGUEIREDO M A T, NOWAK R D. An EM algorithm for wavelet-based image restoration[J]. *IEEE Transactions on Image Processing*, 2007, 16(12): 6701-6710.

- on Image Processing, 2003, 12(8): 906-916.
- [60] DONG B, ZHANG Y. An efficient algorithm for ℓ_0 minimization in wavelet frame based image restoration[J]. *Journal of Scientific Computing*, 2013, 54(2): 350-368.
- [61] CAI J F, DONG B, SHEN Z W. Image restoration: a wavelet frame based model for piecewise smooth functions and beyond[J]. *Applied and Computational Harmonic Analysis*, 2016, 41(1): 94-138.
- [62] PORTILLA J. Image restoration through l0 analysis-based sparse optimization in tight frames[C]. *Proceedings of the 16th IEEE International Conference on Image Processing, IEEE*, 2009: 3909-3912.
- [63] CAI J F, OSHER S, SHEN Z W. Split Bregman methods and frame based image restoration[J]. *Multiscale Modeling & Simulation*, 2010, 8(2): 337-369.
- [64] STARCK J L, NGUYEN M K, MURTAGH F. Wavelets and curvelets for image deconvolution: a combined approach[J]. *Signal Processing*, 2003, 83(10): 2279-2283.
- [65] LV X G, SONG Y ZH, LI F. An efficient nonconvex regularization for wavelet frame and total variation based image restoration[J]. *Journal of Computational and Applied Mathematics*, 2015, 290: 553-566.
- [66] ELAD M, AHARON M. Image denoising via sparse and redundant representations over learned dictionaries[J]. *IEEE Transactions on Image Processing*, 2006, 15(12): 3736-3745.
- [67] AHARON M, ELAD M, BRUCKSTEIN A. K-SVD: an algorithm for designing overcomplete dictionaries for sparse representation[J]. *IEEE Transactions on Signal Processing*, 2006, 54(11): 4311-4322.
- [68] YANG H, ZHU M, WU X T, et al.. Dictionary learning approach for image deconvolution with variance estimation[J]. *Applied Optics*, 2014, 53(25): 5677-5684.
- [69] DONG W SH, ZHANG L, SHI G M. Centralized sparse representation for image restoration[C]. *Proceedings of 2011 International Conference on Computer Vision, IEEE*, 2011: 1259-1266.
- [70] DONG W SH, ZHANG L, SHI G M, et al.. Nonlocally centralized sparse representation for image restoration[J]. *IEEE Transactions on Image Processing*, 2013, 22(4): 1620-1630.
- [71] ZHANG J, ZHAO D B, GAO W. Group-based sparse representation for image restoration[J]. *IEEE Transactions on Image Processing*, 2014, 23(8): 3336-3351.
- [72] KHERADMAND A, MILANFAR P. A general framework for regularized, similarity-based image restoration[J]. *IEEE Transactions on Image Processing*, 2014, 23(12): 5136-5151.
- [73] DANIELYAN A, KATKOVNIK V, EGIAZARIAN K O. BM3D frames and variational image deblurring[J]. *IEEE Transactions on Image Processing*, 2012, 21(4): 1715-1728.
- [74] DONG W SH, SHI G M, LI X. Nonlocal image restoration with bilateral variance estimation: a low-rank approach[J]. *IEEE Transactions on Image Processing*, 2013, 22(2): 700-711.
- [75] GU SH H, ZHANG L, ZUO W M, et al. . Weighted nuclear norm minimization with application to image denoising[C]. *Proceedings of 2014 IEEE Conference on Computer Vision and Pattern Recognition, IEEE*, 2014: 2862-2869.
- [76] YANG H, HU G SH, WANG Y Q, et al.. Low-rank approach for image nonblind deconvolution with variance estimation[J]. *Journal of Electronic Imaging*, 2015, 24(6): 063013.
- [77] TOMASI C, MANDUCHI R. Bilateral filtering for gray and color images[C]. *Proceedings of the 6th International Conference on Computer Vision, IEEE*, 1998: 839-846.
- [78] HE K M, SUN J, TANG X O. Guided image filtering[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2013, 35(6): 1397-1409.
- [79] YANG H, ZHANG ZH B, ZHU M, et al.. Edge-preserving image deconvolution with nonlocal domain transform[J]. *Optics & Laser Technology*, 2013, 54: 128-136.
- [80] SUN L B, CHO S, WANG J, et al. . Good image priors for non-blind deconvolution[C]. *Proceedings of the 13th European Conference on Computer Vision, Springer*, 2014: 231-246.
- [81] SCHMIDT U, ROTHER C, NOWOZIN S, et al. . Discriminative non-blind deblurring[C]. *Proceedings of 2013 IEEE Conference on Computer Vision and Pattern Recognition, IEEE*, 2013: 604-611.
- [82] ZORAN D, WEISS Y. From learning models of natural image patches to whole image restoration[C]. *Proceedings of 2011 International Conference on Computer Vision, IEEE*, 2011: 479-486.
- [83] ROTH S, BLACK M J. Fields of experts: a framework for learning image priors[C]. *Proceedings of 2005 IEEE*

- Computer Society IEEE Conference on Computer Vision and Pattern Recognition, IEEE, 2005: 860-867.
- [84] SCHMIDT U, ROTH S. Shrinkage fields for effective image restoration[C]. Proceedings of 2014 IEEE Conference on Computer Vision and Pattern Recognition, IEEE, 2014: 2774-2781.
- [85] CHEN Y J, YU W, POCK T. On learning optimized reaction diffusion processes for effective image restoration[C]. Proceedings of 2015 IEEE Conference on Computer Vision and Pattern Recognition, IEEE, 2015: 5261-5269.
- [86] REN W Q, ZHANG J W, MA L, et al. Deep non-blind deconvolution via generalized low-rank approximation[C]. Proceedings of the 32nd International Conference on Neural Information Processing Systems, Curran Associates Inc., 2018: 295-305.
- [87] KRUSE J, ROTHER C, SCHMIDT U. Learning to push the limits of efficient FFT-based image deconvolution[C]. Proceedings of 2017 IEEE International Conference on Computer Vision, IEEE, 2017: 4596-4604.
- [88] SON H, LEE S. Fast non-blind deconvolution via regularized residual networks with long/short skip-connections[C]. Proceedings of 2017 IEEE International Conference on Computational Photography, IEEE, 2017: 1-10.
- [89] SCHULER C J, BURGER H C, HARMELING S, et al. A machine learning approach for non-blind image deconvolution[C]. Proceedings of 2013 IEEE Conference on Computer Vision and Pattern Recognition, IEEE, 2013: 1067-1074.
- [90] XU L, REN J S J, LIU C, et al. Deep convolutional neural network for image deconvolution[C]. Proceedings of the 27th International Conference on Neural Information Processing Systems, MIT Press, 2014: 1790-1798.
- [91] EBOLI T, SUN J, PONCE J. End-to-end interpretable learning of non-blind image deblurring[C]. Proceedings of the 16th European Conference on Computer Vision, Springer, 2020: 314-331.
- [92] GONG D, ZHANG ZH, SHI Q F, et al.. Learning deep gradient descent optimization for image deconvolution[J]. IEEE Transactions on Neural Networks and Learning Systems, 2020, 31(12): 5468-5482.
- [93] ZHANG K, ZUO W M, GU SH H, et al. Learning deep CNN denoiser prior for image restoration[C]. Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition, IEEE, 2017: 2808-2817.
- [94] ZHANG J W, PAN J SH, LAI W SH, et al. Learning fully convolutional networks for iterative non-blind deconvolution[C]. Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition, IEEE, 2017: 6969-6977.
- [95] DONG W SH, WANG P Y, YIN W T, et al.. Denoising prior driven deep neural network for image restoration[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2019, 41(10): 2305-2318.
- [96] RONNEBERGER O, FISCHER P, BROX T. U-Net: convolutional networks for biomedical image segmentation[C]. Proceedings of 18th International Conference on Medical Image Computing and Computer-Assisted Intervention, Springer, 2015: 234-241.
- [97] QUAN Y H, LIN P K, XU Y, et al. Nonblind image deblurring via deep learning in complex field[J/OL]. IEEE Transactions on Neural Networks and Learning Systems, 2021: 1-14 (2021-04-14). <https://ieeexplore.ieee.org/document/9404870/>.
- [98] CHEN L, ZHANG J W, PAN J SH, et al. Learning a non-blind deblurring network for night blurry images[C]. Proceedings of 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition, IEEE, 2021: 10537-10545.
- [99] NAN Y S, QUAN Y H, JI H. Variational-EM-based deep learning for noise-blind image deblurring[C]. Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition, IEEE, 2020: 3623-3632.
- [100] JIN M G, ROTH S, FAVARO P. Noise-blind image deblurring[C]. Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition, IEEE, 2017: 3834-3842.
- [101] DONG J X, ROTH S, SCHIELE B. DWDN: deep wiener deconvolution network for non-blind image deblurring[J/OL]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2021 (2021-12-28). <https://ieeexplore.ieee.org/document/9664009/>.
- [102] LEMPITSKY V, VEDALDI A, ULYANOV D. Deep image prior[C]. Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, IEEE, 2018: 9446-9454.
- [103] WANG ZH X, WANG Z P, LI Q Q, et al. Image deconvolution with deep image and kernel priors[C]. Proceedings of 2019 IEEE/CVF International Conference on Computer Vision Workshop, IEEE, 2019: 980-989.
- [104] ZUKERMAN J, TIRER T, GIRYES R. BP-DIP: a backprojection based deep image prior[C]. Proceedings of the 28th European Signal Processing Conference, IEEE, 2021: 675-679.

- [105] BIGDELI S A, JIN M G, FAVARO P, et al. Deep mean-shift priors for image restoration[C]. *Proceedings of the 31st International Conference on Neural Information Processing Systems, Curran Associates Inc.*, 2017: 763-772.
- [106] LEVIN A, WEISS Y, DURAND F. Understanding and evaluating blind deconvolution algorithms[C]. *Proceedings of 2009 IEEE Conference on Computer Vision and Pattern Recognition, IEEE*, 2009: 1964-1971.
- [107] SUN L B, CHO S, WANG J, et al. Edge-based blur kernel estimation using patch priors[C]. *Proceedings of IEEE International Conference on Computational Photography, IEEE*, 2013: 1-8.
- [108] 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, IEEE*, 2001: 416-423.
- [109] DONG J X, PAN J SH, SUN D Q, et al. Learning data terms for non-blind deblurring[C]. *Proceedings of the 15th European Conference on Computer Vision, Springer*, 2018: 777-792.
- [110] DONG J X, ROTH S, SCHIELE B. Learning spatially-variant MAP models for non-blind image deblurring[C]. *Proceedings of 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition, IEEE*, 2021: 4884-4893.
- [111] REN D W, ZUO W M, ZHANG D, et al.. Simultaneous fidelity and regularization learning for image restoration[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2021, 43(1): 284-299.
- [112] WANG ZH, BOVIK A C, SHEIKH H R, et al.. Image quality assessment: from error visibility to structural similarity[J]. *IEEE Transactions on Image Processing*, 2004, 13(4): 600-612.
- [113] REN D W, ZUO W M, ZHANG D, et al.. Partial deconvolution with inaccurate blur kernel[J]. *IEEE Transactions on Image Processing*, 2018, 27(1): 511-524.
- [114] JI H, WANG K. Robust image deblurring with an inaccurate blur kernel[J]. *IEEE Transactions on Image Processing*, 2012, 21(4): 1624-1634.
- [115] VASU S, MALIGIREDDY V R, RAJAGOPALAN A N. Non-blind deblurring: handling kernel uncertainty with CNNs[C]. *Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, IEEE*, 2018: 3272-3281.
- [116] NAN Y S, JI H. Deep learning for handling kernel/model uncertainty in image deconvolution[C]. *Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition, IEEE*, 2020: 2385-2394.
- [117] WHYTE O, SIVIC J, ZISSELMAN A, et al.. Non-uniform deblurring for shaken images[J]. *International Journal of Computer Vision*, 2012, 98(2): 168-186.
- [118] TAI Y W, TAN P, BROWN M S. Richardson-Lucy deblurring for scenes under a projective motion path[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2011, 33(8): 1603-1618.
- [119] HIRSCH M, SCHULER C J, HARMELING S, et al.. Fast removal of non-uniform camera shake[C]. *Proceedings of 2011 International Conference on Computer Vision, IEEE*, 2011: 463-470.
- [120] SUN J, CAO W F, XU Z B, et al. Learning a convolutional neural network for non-uniform motion blur removal[C]. *Proceedings of 2015 IEEE Conference on Computer Vision and Pattern Recognition, IEEE*, 2015: 769-777.
- [121] KUPYN O, BUDZAN V, MYKHAILYCH M, et al. DeblurGAN: blind motion deblurring using conditional adversarial networks[C]. *Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, IEEE*, 2018: 8183-8192.
- [122] PAN J SH, SUN D Q, PFISTER H, et al. Blind image deblurring using dark channel prior[C]. *Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition, IEEE*, 2016: 1628-1636.
- [123] CHEN L, FANG F M, WANG T T, et al. Blind image deblurring with local maximum gradient prior[C]. *Proceedings of 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition, IEEE*, 2019: 1742-1750.

作者简介:



杨航(1985—),男,吉林农安人,博士,副研究员。2012年于吉林大学获得理学博士学位,2016年至今为中国科学院长春光学精密机械与物理研究所副研究员。主要从事图像复原、图像增强和目标识别与跟踪方面的研究。E-mail: yanghang@ciomp.ac.cn