

非局部学习字典的图像修复

李 民^{*①③} 程 建^{①②} 李小文^① 乐 翔^②

^①(电子科技大学地表空间信息技术研究所 成都 611731)

^②(电子科技大学电子工程学院 成都 611731)

^③(桂林空军学院科研部 桂林 541003)

摘 要: 该文提出一种新的基于学习的图像修复算法。与经典的稀疏表示模型不同, 该文将非局部自相似图像块统一进行联合稀疏表示, 训练高效的学习字典, 并使自相似块间保持相同的稀疏模式。该方法既确保自相似块投影到稀疏空间后也具有相似性, 也较好地保留了自相似块间的相关性信息, 更有效地建立了它们的联合稀疏关联, 并将这种关联作为先验知识来指导图像的修复。该算法使用大量自然图像样本来训练初始的过完备字典, 既利用了样本图像的先验知识, 又充分考虑了待处理图像本身的相关信息, 自适应性强。通过对自然图像进行大、小范围图像修复和文字去除实验, 该文方法均取得不错的修复效果。

关键词: 图像修复; 学习字典; 稀疏表示; 联合稀疏近似; 非局部

中图分类号: TP391

文献标识码: A

文章编号: 1009-5896(2011)11-2672-07

DOI: 10.3724/SP.J.1146.2010.01426

Image Inpainting Based on Non-local Learned Dictionary

Li Min^{①③} Cheng Jian^{①②} Li Xiao-wen^① Le Xiang^②

^①(*Institute of Geo-Spatial Information Science and Technology,*

University of Electronic Science and Technology of China, Chengdu 611731, China)

^②(*School of Electronic Engineering, University of Electronic Science and Technology of China, Chengdu 611731, China*)

^③(*Department of Scientific Research, Guilin Airforce Academy, Guilin 541003, China*)

Abstract: A novel learning-based image inpainting method is presented. As a further development of classical sparse representation model, the non-local self-similar patches are unified for joint sparse representation and learning dictionary, in which each element of the self-similar patches has the same sparse pattern. The method assures the self-similar patches possess similarity when projected on the sparse space, and efficiently builds the sparse association among them. This association is next taken as a priori knowledge for image inpainting. The paper uses numerous samples and non-local patches of input image to train overcomplete dictionary. The method not only takes into account the priori knowledge of samples, but also considers the non-local self-similar information of input image. Large and small region inpainting experiments and text removing experiments on natural images show the good performance of the method.

Key words: Image inpainting; Learning dictionary; Sparse representation; Simultaneous sparse approximation; Non-local

1 引言

图像修复是图像处理领域一个重要分支, 也是当前计算机视觉方面的一个研究热点。目前主要有 3 类方法: 偏微分方程(Partial Differential Equation, PDE)、纹理合成(Texture Synthesis)方法及混合方法。基于 PDE 方法的基本思路是利用待修复区域的

边缘信息估计等值线的方向, 并采用传播机制将信息扩散到待修复区域内。因 PDE 和变分法可以通过变分原理相互等价推导, 所以这一类方法一般统称为基于变分 PDE 的图像修复方法^[1]。较典型的算法有: 基于整体变分的方法(Total Variation, TV)^[2], 基于曲率的扩散模型(Curvature Driven Diffusion, CDD)^[3], Mumford-Shah 模型^[4], Mumford-Shah-Euler 模型^[5], 非局部整体变分方法(Non-local TV, NLTV)^[6]等。然而此类算法视图像为平滑函数, 考虑的是图像的几何结构信息, 本质上是一种扩散过程, 一旦修复区域较大, 修复效果会明显变差。另

2010-12-27 收到, 2011-07-28 改回

国家 973 计划项目(2007CB714406), 中国博士后基金特别资助项目(200902609)及电子科技大学青年科技基金重点项目(JX0804)资助课题

*通信作者: 李民 gllm126@163.com

一类基于纹理合成的方法基本思路是从待修复区域边界开始, 根据图像的纹理特征, 选取合适大小的图像块, 然后在图像的有效数据区域找与之最近似的匹配图像块来替代。代表性成果有图像块匹配替换算法^[7-9], 基于分形的修复算法^[10]等。此类方法可用于大块区域的修复, 对自相似性较好的纹理图像修复效果较好, 但对纹理特性不明显(自相似特性较弱)的自然图像效果并不理想, 而且计算效率较低。也有学者结合以上两种方法的优点, 将原始图像分解为几何结构与纹理分量, 再分别对这两个分量进行修补和合成。如基于 TV 的图像分解方法^[11]; Elad 等人^[12]以压缩理论为基础, 采用形态成分分析(Morphological Component Analysis, MCA)的图像分解方法。但这类方法也避免不了在扩散过程中产生的模糊问题。

鉴于稀疏表示理论在图像处理领域的优势, 近年来, 有关稀疏表示的图像修复方法得到更多的重视。目前主要有两种思路, 一是基于固定基字典(如: 曲线波、轮廓波等), 但这种字典结构一般是固定的, 对不同类型的数据自适应能力较差。另一种是基于学习字典(Learned Dictionary, LD)的方法, 这也是本文方法的基础。这种字典是从一些样本中通过机器学习推理而来, 具有更好的性能应用, 自适应能力更强。如: Fadili 等人^[13]将稀疏表示方法应用于图像的修复和插值。Mairal 等人^[14]将学习字典应用于彩色图像的复原, 并提出在线字典学习算法^[15]。Shen 等人^[16]将信号字典应用于图像修复, 无需字典的训练, 提高计算效率。Xu 等人^[17]提出结构稀疏的图像修复方法, 同时考虑了图像的几何结构和纹理信息。Peyre^[18]提出基于学习字典的纹理合成方法, 对纹理图像的修复效果较好。然而, 上述方法只是应用待处理图像内的有效信息进行稀疏编码, 先验知识有限, 并没充分考虑其它相关样本图像的相关信息, 自适应性也较差; 并未充分考虑非局部自相似图像块间的联合稀疏特性, 对先验信息的表达能力有限。

为突破上述方法的局限, 本文提出一种非局部学习字典的图像修复方法(Non-Local Learned Dictionary, NLLD)。通过对自然图像进行大、小范围图像修复和文字去除实验, 本文方法均取得不错的修复效果。本文主要贡献:

(1) 建立了一种基于联合稀疏近似(Simultaneous Sparse Approximation, SSA)的学习字典的图像修复框架。将非局部相似图像块统一进行联合稀疏编码, 训练高效的学习字典, 建立它们的联合稀疏关联, 并将这种关联作为先验知识来指导图像的修复;

(2) 根据大量的自然图像样本训练初始的过完备字典, 既利用了样本图像的先验知识, 又充分考虑了待处理图像本身的相关信息, 自适应性强。

2 稀疏表示

稀疏表示的基本思想是假设自然信号能被压缩表示, 或者可由预定义的原子线性组合表示。设信号 $\mathbf{x} \in \mathbf{R}^N$, 其稀疏表示问题可以表述为^[19]

$$\min \|\mathbf{a}\|_p, \quad \text{s.t.} \|\mathbf{x} - \mathbf{D}\mathbf{a}\|_2^2 \leq \varepsilon \quad (1)$$

其中 \mathbf{a} 为 \mathbf{x} 的稀疏表示, $\mathbf{D} = [\mathbf{d}_1, \mathbf{d}_2, \dots, \mathbf{d}_L] \in \mathbf{R}^{N \times L}$ ($L > N$) 称为过完备字典, \mathbf{d}^i 称为 \mathbf{D} 的原子, $\|\cdot\|_p$ 表示 l_p 范数, $p \in \{0, 1\}$ 。

近几年, 作为稀疏表示问题的进一步发展, 有关多信号的联合稀疏表示问题得到更多关注, 称为联合稀疏近似(也称联合稀疏编码), 在传感器网络信号处理、源定位、图像复原和分布式压缩传感等领域已有较好的发展。其基本思想是: 设同一个现象有多个观测信号, 而每个信号都有一定的污染噪声, 计算每个信号的线性最稀疏近似, 并保证各信号的稀疏性模式(sparsity patterns)是相同的(采用相同的初等函数集), 即: 稀疏表示系数中非零元素的位置相同, 使相似的信号投影到稀疏空间后也具有相似性^[20]。目标函数可表示为^[21]

$$\min \|\mathbf{A}\|_{p,q}, \quad \|\mathbf{X} - \mathbf{D}\mathbf{A}\|_2^2 \leq \varepsilon \quad (2)$$

其中 $l_{p,q}$ 矩阵范数的定义: $\|\mathbf{A}\|_{p,q} \triangleq \left(\sum_{i=1, \dots, k} \|\mathbf{a}^i\|_q^p \right)^{1/p}$,

其中 \mathbf{a}^i 表示 \mathbf{A} 的第 i 行向量, k 为 \mathbf{A} 的行数, 参数对 (p, q) 一般选择 $(1, 2)$ 或 $(0, \infty)$ 。有关 SSA 细节参考文献[20, 22]。

上述两种模型中最根本的问题是字典 \mathbf{D} 的选择, 一般有两种方法: 基于分析的方法与基于学习的方法(也称基于合成的方法)。基于分析的方法中, 字典是隐式的, 它通过一定的数据模型来表示, 结构性较好, 并有快速数值计算方法, 如: Gabor 小波, 曲线波(Curvelet), 轮廓波(Contourlet)等, 但这种字典结构一般是固定的, 对不同类型的数据自适应能力较差。基于学习的方法是近几年的研究热点, 其字典是从一些样本中通过机器学习推理而来, 通常由一显式矩阵表示, 也称学习字典。这种方法自适应能力更强, 能得到更精细的字典表示, 具有更好的性能应用, 本文也采用了这种字典。有关字典的细节内容请参考文献[23]。

3 非局部联合稀疏近似的修复算法

本文根据大量样本图像块及待处理图像内有效数据的稀疏先验知识来指导图像修复。主要步骤: 将样本图像块参与稀疏编码, 建立初始的过完备字典; 计算输入图像内有效区域图像块的非局部相似

块集,并将其作为样本进一步训练字典;计算输入图像块的有效区域的稀疏编码;估计输入图像块的待处理区域。本文中,我们采用 Ω 表示待修复区域; $\setminus\Omega$ 表示有效数据区域。

3.1 联合字典学习

根据输入图像有效区域 I^Ω ,逐个计算图像块的相似集 Y^i ,本节的目的就是将 Y^i 作为样本来训练字典。根据式(1),目标函数可定义为

$$D = \arg \min_{D, A^i, Y^i \in I^\Omega} \|A^i\|_p, \|Y^i - DA^i\|_2^2 \leq \varepsilon \quad (3)$$

式(3)是典型的单观测向量的稀疏表示问题,将 Y^i 中每个相似块单独进行稀疏编码。为保证各相似块具有相同的稀疏性模式,根据式(2),式(3)可转换为多观测向量的联合稀疏近似问题,用 $l_{p,q}$ 范数代替式(3)的 l_p 范数:

$$D = \arg \min_{D, A^i, Y^i \in I^\Omega} \|A^i\|_{p,q}, \|Y^i - DA^i\|_2^2 \leq \varepsilon \quad (4)$$

式(4)可转换为正则化表示方式:

$$D = \arg \min_{D, A^i, Y^i \in I^\Omega} \frac{1}{2} \|Y^i - DA^i\|_2^2 + \lambda \|A^i\|_{p,q} \quad (5)$$

式(5)的估计方法可采用简单改进的在线字典学习算法^[15,24,25],改进之处:在稀疏编码过程中,采用 $l_{1,2}$ 范数,而非 l_1 范数,保证自相似块具有相同的稀疏性模式,而字典更新过程与在线字典学习算法一致,并保持 A_k 和 B_k 计算方法不变,详见文献[15],具体计算流程如表1所示,并选择正则化参数 $\lambda=0.01$ 。

表1 联合稀疏近似的在线字典学习算法

(1)输入: 训练样本 X , 正则化参数 λ , 初始字典 $D_0 \in \mathbf{R}^{m \times n}$, 迭代次数 K , 残差阈值 ε
(2)初始化: $A_0 \in \mathbf{R}^{n \times n} \leftarrow 0$, $B_0 \in \mathbf{R}^{m \times n} \leftarrow 0$
(3)输出: 学习字典 D_k
(4)For $k=1$ to K do
(5)Foreach X_i in X
计算残差 $R_k = \ X_k - D_{k-1}Z\ _2^2$, if $R_k \leq \varepsilon$, continue.
(a)稀疏编码, 采用稀疏正则化模型:
$Z_k = \arg \min_Z \frac{1}{2} \ X_k - D_{k-1}Z\ _2^2 + \lambda \ Z\ _{1,2}$
(b)字典更新, 固定 D_{k-1} , 采用文献[24]的算法2计算 D_k :
$A_k = A_{k-1} + Z_k Z_k^T, B_k = B_{k-1} + X_k Z_k^T$
$D_k = \arg \min_D \frac{1}{k} (\text{Tr}(D^T D A_k) - \text{Tr}(D^T B_k))$
(6) End foreach
(7) End for

3.2 图像修复

从输入图像 I 的待修复区域边缘开始,逐步向内取块,并与图像的有效数据区域保留一定像素的重叠。给定学习字典 D ,待修复图像块 y^i 的稀疏表

示问题可定义为

$$\alpha^i = \arg \min_{\alpha^i} \|\alpha^i\|_p, \|Py^i - PD\alpha^i\|_2^2 \leq \varepsilon \quad (6)$$

其中 P 为用于提取图像块内有效区域数据。式(6)中, y^i 的稀疏表示问题并未考虑其与自相似块间的关系。计算 y^i 有效区域的相似块集 Y^i ,并估计 y^i 和 Y^i 的联合稀疏近似。定义输入信息: $\tilde{Y}^i = [y^i, Y^i]$,根据式(2),其对应的稀疏表示 $\tilde{A}^i = [\alpha^i, A^i]$ 的估计问题可表示为

$$\tilde{A}^i = \arg \min_{\tilde{A}^i} \|\tilde{A}^i\|_{p,q}, \|P\tilde{Y}^i - PD\tilde{A}^i\|_2^2 \leq \varepsilon \quad (7)$$

式(7)同时考虑了输入图像块与其相似块的信息,相对式(6),鲁棒性更强。则 y^i 的待修复区域可通过式(8)估计:

$$\bar{P}y^i = \bar{P}D\alpha^i \quad (8)$$

其中 \bar{P} 用于提取输入图像块的待修复区域。本节相当于将待处理图像块分解为有效区域数据和待修复

区域数据两部分: $y^i = \begin{bmatrix} Py^i \\ \bar{P}y^i \end{bmatrix}$ 。式(7)和式(8)隐含了

一条重要的假设: Py^i 和 $\bar{P}y^i$ 共享同一个稀疏表示 α^i 。由于在字典训练阶段,每个图像块样本作为一个向量,相对字典 D ,具有相同的稀疏表示。即:样本图像块内所有像素共享同一个稀疏表示。同理,输入图像块内所有元素在字典 D 基础上也具有相同的稀疏表示,上述假设是成立的。

3.3 算法优化

字典初始化 从样本图像中随机提取大量图像块作为样本 Y 训练初始的过完备字典 D_0 。充分考虑样本的先验信息,增强算法的鲁棒性。由于式(1)的 l_0 范数是非凸的,是NP-hard问题,可以转换为 l_1 范数的凸优化问题^[15]:

$$D_0 = \arg \min_{D_0, A} \|Y - D_0 A\|_2^2 + \lambda \|A\|_1 \quad (9)$$

其中正则化参数 λ 用来平衡 Y 的稀疏表示精度和稀疏特性,本文选择其大小为0.01。图1显示 10^6 个样本训练的字典。




图1 采用 10^6 个样本训练的字典

稀疏表示误差参数 ε 的选择 文献[14,25]分析了 ε 的统计意义: 假定 $\mathbf{x} - \mathbf{D}\mathbf{a}$ 满足零均值高斯分布, 则 $\|\mathbf{x} - \mathbf{D}\mathbf{a}\|_2^2 / \sigma^2$ 满足卡方分布 χ_m^2 。定义 χ_m^2 的概率分布函数 F_m , $F_m^{-1}(\tau)$ 为 F_m 的反函数, 则选择 $\varepsilon = \sigma^2 F_m^{-1}(\tau)$ 。本文选择 $\tau=0.95$ 。

图像块标准化 为提高稀疏编码数值算法的稳定性, 在处理之前, 对每个图像块进行平均化、归一化处理, 之后再还原。

修复顺序 本文算法对每个图像块修复过程中, 对待修复区域的修复顺序对结果有一定的影响。为充分考虑几何结构信息的影响, 修复初始位置首先从待修复区域周围几何结构信息较丰富的位置开始, 并沿边界线逐步进行修复。详见图 2, 其中 Ω 是输入图像的待修复区域, z_i 是待修复图像块, A 为 z_i 的待修复区域, C 为 z_i 的有效区域, P_1 和 P_2 为 Ω 边界处几何结构信息较丰富位置。




图 2 图像块 z_i 的修复示意图

自相似集 在待修复图像块周围搜索、匹配与图像块的有效区域数据较相近的图像块, 常用的方法是计算图像块间的欧式距离来判断图像块间的相似性。本文采用非局部平均(Non-Local Means, NLM)^[26]的方法, 计算图像块间的相似度:

$$w_{i,j} = \frac{1}{Z(i)} e^{-\frac{\|P\mathbf{y}^i - P\mathbf{y}^j\|_2^2}{h^2}}, \quad Z(i) = \sum_j e^{-\frac{\|P\mathbf{y}^i - P\mathbf{y}^j\|_2^2}{h^2}} \quad (10)$$

其中 $Z(i)$ 是归一化系数, h 用来控制自相似度的衰减速度, 本文选择其为 1。选择搜索区域大小为 (40×40) , 定义 $w_{i,j}$ 大于 0.05 的所有图像块为当前图像块的自相似块, 自相似集 \mathbf{Y}^i 定义:

$$\mathbf{Y}^i = \{\mathbf{y}^j\}, \quad \text{s.t. } w_{i,j} \geq 0.05 \quad (11)$$

4 实验

本节将在大、小区域目标剔除、移除文字方面进行图像修复实验, 并与 Exemplar-based^[7], TV^[27], FoE^[28], MCA^[12]方法的效果进行对比。论证有关参数如图像块重叠区域大小对修复结果的影响。主要参数设置详见表 2。式(1)的经典稀疏编码模型中, 通

常在字典学习阶段一般选择 l_1 范数, 稀疏表示计算阶段选择 l_0 范数^[14,29]。同理, 本文在估计学习字典阶段采用 $l_{1,2}$ 范数, $l_{0,\infty}$ 范数应用于图像修复。式(5)的联合字典学习算法采用 Matlab 实现。式(7)的联合稀疏编码算法选用 S-OMP(Simultaneous Orthogonal Matching Pursuit)方法^[22]。式(9)的初始字典估计算法选用 Mairal 等人^[24]的在线字典学习算法, 理论上可实现无限多样本的训练, 可减少计算资源, 提高计算速度。根据 3.3 节分析, 式(7)的误差阈值 ε , 相对彩色图像, 取 0.09; 对灰度图像, 取 0.03。训练图像采用 Berkeley 图像库中的 300 幅图像, 从中随机提取 10^6 个图像块作为彩色图像的学习字典的训练样本, 对灰度图像的学习字典而言, 只需将采样的图像块转为灰度后再次进行训练即可。Berkeley 图像库主要包含风景、人物、建筑、动植物等自然图像, 类型全面, 较适合本文算法对初始学习字典的训练。

表 2 参数设置

图像块大小	灰度图像字典大小	彩色图像字典大小	迭代次数	重叠区域宽
7×7	256	640	50	4 像素宽

4.1 修复效果

本节采用 Lena 彩色图像(256×256)进行修复实验。图 3 显示本文方法与其它几种算法的修复效果, 括号中的数字为修复时间。如图所示, 本文方法(NLLD)和 Exemplar-based 方法^[7]在纹理区域, 如帽子和肩部区域, 修复效果相对较好。在非纹理区域, 如嘴唇和眼睛部位, 本文方法的修复效果也有较好表现, 而 TV^[27]和 MCA^[12]的方法将各通道数据单独处理后再合成, 有一定的颜色失真。MCA 方法是一种混合图像修复算法, 将图像分解为几何结构和纹理分量后再处理, 但结果受经验参数的影响较大, 计算效率较低, 自适应性较差。理论上分析, 本文的学习字典有效地建立了待修复图像块与其非局部相似块间的联合稀疏关联, 并充分考虑了大量样本图像的先验知识, 能更有效地表示待修复区域与其周围有效区域的关系。更多的修复效果见图 4。

4.2 重叠区域大小的影响

本文算法是根据图像块内的有效数据来估计待修复数据, 则有效数据的多少(待修复图像块与修复图像有效数据的重叠区域的像素宽度 r)将直接影响修复效果, 本节将对此问题进行实验论证。根据上节的学习字典, 对 Barbara 图像(256×256)的多个正方形区域(27×27)进行修复实验。图 5 显示了重叠区



图 3 各修复方法效果及时间对比



图 4 图像修复效果

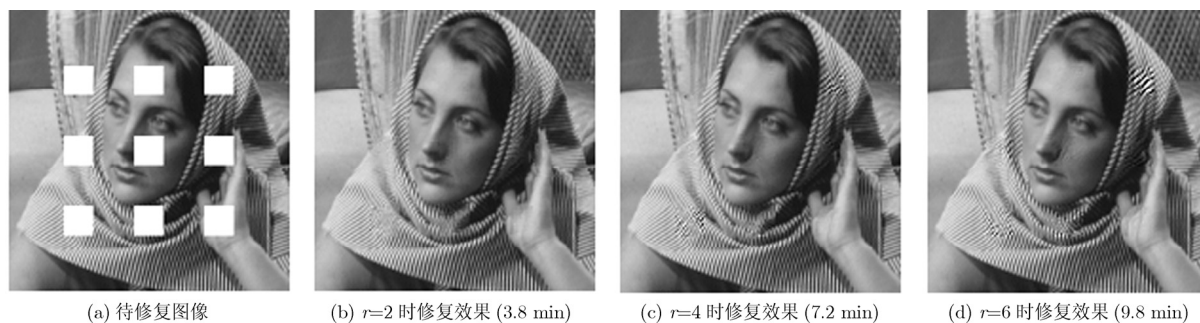


图 5 重叠区域大小的影响

域像素宽度 r 分别为 2, 4, 6 时的修复效果, 括号中的数字为修复时间。如图 5 所示, r 较小时, 会产生平滑效果, 但每次迭代修复的区域较多, 计算效率

较高; r 较大时, 对比度增强, 出现锯齿, 但每次迭代修复的区域较少, 计算效率较低。为平衡修复效果和计算效率, 本文选择 r 为 4。

5 结束语

本文提出基于非局部学习字典的图像修复方法, 将输入图像非局部自相似块统一进行稀疏编码, 训练学习字典, 使其具有相同的稀疏模式, 建立它们之间的稀疏关联, 并将这种关联作为先验知识来指导图像修复。主要步骤主要包括: 将样本图像块参与稀疏编码, 建立初始的过完备字典; 计算输入图像内有效区域图像块的非局部相似块集, 并将其作为样本进一步训练字典; 计算输入图像块的有效区域的联合稀疏编码; 估计输入图像块的待修复区域。该方法既利用了样本图像的先验知识, 又充分考虑到了待修复图像本身的相关信息, 将这两种信息统一用于字典的训练, 提高了修复质量, 增强了算法的自适应性。通过对自然图像进行大、小区域修复和文字去除实验, 并与其它几种常用算法相比, 修复可视化效果较好。尽管如此, 本文方法仍有可改进之处, 如: 增强样本间的不相关性以训练更有效的字典; 如何减小字典大小、稀疏性等经验参数对重建结果的影响等。如何将本文方法应用到彩色图像的修复以及如何将非局部的概念与学习字典结合起来改善修复质量将是我们的下一步的研究重点。

参 考 文 献

- [1] Bertalmio M, Sapiro G, Caselles V, *et al.* Image inpainting[C]. Proceedings of SIGGRAPH 2000, New Orleans, USA, 2000: 417-424.
- [2] Chan T F and Shen J. Mathematical models for local nontexture inpaintings[J]. *SIAM Journal on Applied Mathematics*, 2002, 62(3): 1019-1043.
- [3] Chan T F and Shen J. Non-texture inpainting by Curvature-Driven Diffusions (CDD)[J]. *Journal of Visual Communication and Image Representation*, 2001, 12(4): 436-449.
- [4] Tsai A, Yezzi A, and Willsky A S. Curve evolution implementation of the Mumford-Shah functional for image segmentation, denoising, interpolation, and magnification[J]. *IEEE Transactions on Image Processing*, 2001, 10(8): 1169-1186.
- [5] Esedoglu S and Shen J. Digital inpainting based on the Mumford-Shah-Euler image model[J]. *European Journal of Applied Mathematics*, 2002, 13(4): 353-370.
- [6] Zhang X T and Chan F. Wavelet inpainting by nonlocal total variation[R]. Technical Report, Los Angeles: University of California, 2009.
- [7] Criminisi A, Perez P, and Toyama K. Region filling and object removal by exemplar-based image inpainting[J]. *IEEE Transactions on Image Processing*, 2004, 13(9): 1200-1212.
- [8] Tang F, Ying Y, Wang J, *et al.* A novel texture synthesis based algorithm for object removal in photographs[C]. The 9th Asian Computing Science Conference, Chiang Mai, Thailand, 2004: 248-254.
- [9] 付绍春, 楼顺天. 基于区域纹理合成的图像修补算法[J]. *电子与信息学报*, 2009, 31(6): 1319-1322.
- Fu Shao-chun and Luo Shun-tian. Region texture synthesis based on image inpainting[J]. *Journal of Electronics & Information Technology*, 2009, 31(6): 1319-1322.
- [10] Drori I, Cohen-Or D, and Yeshurun H. Fragment-based image completion[J]. *ACM Transactions on Graphics*, 2003, 22(3): 303-312.
- [11] Bertalmio M, Vese L, Sapiro G, *et al.* Simultaneous structure and texture image inpainting[J]. *IEEE Transactions on Image Processing*, 2003, 12(8): 882-889.
- [12] Elad M, Starck J-L, Querre P, *et al.* Simultaneous cartoon and texture image inpainting using morphological component analysis (MCA)[J]. *Applied and Computational Harmonic Analysis*, 2005, 19(3): 340-358.
- [13] Fadili M J, Starck J-L, and Murtagh F. Inpainting and zooming using sparse representations[J]. *The Computer Journal*, 2007, 52(1): 64-79.
- [14] Mairal J, Elad M, and Sapiro G. Sparse representation for color image restoration[J]. *IEEE Transactions on Image Processing*, 2008, 17(1): 53-69.
- [15] Mairal J, Bach F, Ponce J, *et al.* Online learning for matrix factorization and sparse coding[J]. *Journal of Machine Learning Research*, 2010, 11(3): 19-60.
- [16] Shen B, Hu W, Zhang Y, *et al.* Image inpainting via sparse representation[C]. IEEE International Conference on Acoustics, Speech and Signal Processing, Taipei, 2009: 697-700.
- [17] Xu Z and Sun J. Image inpainting by patch propagation using patch sparsity[J]. *IEEE Transactions on Image Processing*, 2010, 19(5): 1153-1165.
- [18] Peyre G. Sparse modeling of textures[J]. *Journal of Mathematical Imaging and Vision*, 2009, 34(1): 17-31.
- [19] Tropp J A and Wright S J. Computational methods for sparse solution of linear inverse problems[J]. *Proceedings of the IEEE, Special Issue on Applications of Sparse Representation and Compressive Sensing*, 2010, 98(6): 948-958.
- [20] Rakotomamonjy A. Surveying and comparing simultaneous sparse approximation (or group-lasso) algorithms[R]. Technical Report, University of Rouen, 2010.
- [21] Chen J and Huo X. Sparse representations for multiple measurement vectors (MMV) in an over-complete dictionary[C]. IEEE International Conference on Acoustics, Speech, and Signal Processing (ICASSP'05), Philadelphia, 2005, 4: 257-260.

- [22] Tropp J A, Gilbert A C, and Strauss M J. Algorithms for simultaneous sparse approximation. Part I: greedy pursuit[J]. *Signal Processing, Special Issue Sparse Approximations in Signal and Image Processing*, 2006, 86(3): 572-588.
- [23] Rubinstein R, Bruckstein A M, and Elad M. Dictionaries for sparse representation modeling[J]. *Proceedings of the IEEE, Special Issue on Applications of Sparse Representation and Compressive Sensing*, 2010, 98(6): 1045-1057.
- [24] Mairal J, Bach F, Ponce J, *et al.* Online dictionary learning for sparse coding[C]. International Conference on Machine Learning (ICML), Montreal, Quebec, Canada, 2009: 689-696.
- [25] Mairal J, Bach F, Ponce J, *et al.* Non-local sparse models for image restoration[C]. IEEE International Conference on Computer Vision (ICCV), Kyoto, Japan, 2009: 2272-2279.
- [26] Buades A, Coll B, and Morel J M. A non-local algorithm for image denoising[C]. IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR), San Diego, California, 2006, 2: 60-65.
- [27] Dahl J, Hansen P C, Jensen S H, *et al.* Algorithms and software for total variation image reconstruction via first-order methods[J]. *Numerical Algorithms*, 2010, 53(1): 67-92.
- [28] Roth S and Black M J. Fields of experts[J]. *International Journal of Computer Vision*, 2009, 82(2): 205-229.
- [29] Lee H, Battle A, Raina R, *et al.* Efficient sparse coding algorithms[C]. Advances in Neural Information Processing Systems (NIPS), Vancouver, B.C., Canada, 2007: 801-808.
- 李 民: 男, 1974 年生, 博士, 副教授, 研究方向为图像处理、计算机视觉和模式识别。
- 程 建: 男, 1978 年生, 博士, 副教授, 研究方向为图像处理、模式识别、计算机视觉、多源遥感信息智能挖掘。
- 李小文: 男, 1947 年生, 中国科学院院士, 博士, 教授, 研究方向为定量遥感。
- 乐 翔: 男, 1984 年生, 硕士, 研究方向为图像处理、计算机视觉。