

多尺度压缩感知框架下的遥感图像超分辨率重建

陈伟业, 孙权森

(南京理工大学计算机科学与工程学院, 江苏 南京 210094)

[摘要] 传统的基于压缩感知的超分辨率重建算法将图像看作单尺度, 并没有考虑不同尺度的图像块可能包含不同的判别信息. 为了有效利用遥感图像的尺度特性, 提出了一种多尺度压缩感知框架下的遥感图像超分辨率重建算法. 首先通过图像块聚类构建多尺度训练样本集, 接着运用 Fisher 判别准则学习包含遥感图像类别信息的判别字典, 然后根据压缩感知中测量矩阵的构造方式估计低分辨率图像的获取过程, 最后结合判别字典依次重建多尺度模式下的各子区域图像. 实验结果证明了将多尺度压缩感知引入图像超分辨率重建的有效性, 提出的算法在视觉效果和评价指标上均优于现有的几种算法.

[关键词] 遥感图像, 超分辨率重建, 多尺度, 压缩感知

[中图分类号] TP391.4 [文献标志码] A [文章编号] 1001-4616(2017)01-0039-09

Remote Sensing Image Super-resolution Reconstruction in Multi-scale Compressed Sensing Framework

Chen Weiye, Sun Quansen

(School of Computer Science and Engineering, Nanjing University of Science and Technology, Nanjing 210094, China)

Abstract: The traditional compressed sensing based super-resolution reconstruction algorithm regards images as a single scale without considering that different scale image patches may have different discriminant information. To effectively utilize the scale characteristics of remote sensing images, a new remote sensing image super-resolution reconstruction algorithm in the multi-scale compressed sensing framework was proposed. First, image patches were clustered to construct multi-scale training sample sets. Next, the Fisher criterion was used to learn a discriminative dictionary containing the classification information of remote sensing images. Then, the acquisition process of the low-resolution image was estimated by the construction method of the measurement matrix in compressed sensing. Finally, the sub-region images in the multi-scale mode were reconstructed by using the discriminant dictionary. The experimental results demonstrate that it is effective to introduce multi-scale compressed sensing into image super-resolution reconstruction. The proposed algorithm outperforms other existing algorithms both in visual qualities and evaluation criteria.

Key words: remote sensing image, super-resolution reconstruction, multi-scale, compressed sensing

随着图像处理技术的发展, 数字成像的应用领域越来越广泛, 其中遥感成像可以说是最为重要的方向之一. 遥感成像具有隐匿性高、信息量大、拍摄时空自由等优势, 在工业、农业、军事等生产生活的各个方面有着巨大的应用价值. 遥感卫星研制技术的进步使得遥感图像的获取能力不断增强, 图像的空间分辨率越来越高. 高分辨率图像不仅可以给人们带来视觉上的享受, 而且能够提供丰富的图像细节信息, 更有利于遥感数据的后续处理.

然而, 随着遥感图像高空间分辨率的发展趋势, 依据香农采样定理设计的传感器必将导致海量化的采样数据, 其存储、传输及数据处理的矛盾日益突出. 如图 1(a) 所示, 传统的图像信号获取和处理过程主要包括采样、压缩、传输和解压缩 4 个部分. 为了避免信号失真, 采样过程必须满足香农采样定理, 即采样频率不得低于信号最高频率的 2 倍. 为突破香农采样定理对传统遥感技术发展的限制, 压缩感知带来了信

收稿日期: 2016-08-20.

基金项目: 国家自然科学基金项目(61273251)、民用航天技术“十二五”预先研究项目(D040201).

通讯联系人: 孙权森, 教授, 博士生导师, 研究方向: 模式识别、图像处理、遥感信息系统. E-mail: sunquansen@njut.edu.cn

号获取理论的变革. 如图 1(b) 所示, 压缩感知将压缩和采样合并进行, 采用非自适应线性投影来保持信号的原始结构, 通过数值最优化问题重建原始信号^[1-3].

压缩感知理论被考虑用来缓解星上数据处理、存储和传输的压力. 同样, 图像超分辨率重建也可以在不增加硬件成本的基础上, 充分利用地面信息处理端的计算资源, 提高遥感图像的分辨率. 图像超分辨率重建是指从一幅或者多幅低分辨率图像获得高分辨率图像的过程, 本质上属于

维数增加的问题, 具有不适定性. 在压缩感知理论中, 由测量值获得原始信号也是一个从低维到高维的维数增加问题, 与超分辨率重建类似. 图 1(b) 所示的压缩感知方式为图像超分辨率重建的研究提供了新思路. 压缩感知理论利用了信号可稀疏表示这一先验知识, 相关超分辨率算法将稀疏性作为对图像重建过程的一种约束, 利用稀疏字典提供重建所需的高频细节信息. Fan^[4]将特征提取和空间连续性先验信息融入到压缩感知的框架下; Yang 等^[5]提出了基于稀疏表示的图像超分辨率算法, 学习高低分辨率字典对, 使得高低分辨率图像块在对应的字典下有相同的稀疏表示系数; Yang S 等^[6]利用 K-奇异值分解(K-singular value decomposition, K-SVD)算法进行字典学习, 只用了较少的字典元素便获得了不错的重建效果; Kulkarni 等^[7]研究了将压缩感知理论运用于图像超分辨率重建的可行性, 为基于压缩感知的超分辨率算法提供了理论支持; Pan 等^[8]提出了一种结合压缩感知框架和结构自相似性的遥感图像超分辨率算法, 该算法利用图像结构自相似性所提供的附加信息, 通过压缩感知框架实现图像重建, 并在重建过程中仅使用了待处理低分辨率图像的插值图像作为 K-SVD 字典学习的样本; Dong 等^[9]提出了非局部集中稀疏表示算法, 该算法将降质图像的稀疏编码与未知原始图像的稀疏编码之差定义为稀疏编码噪声, 并利用图像的非局部信息来减小稀疏编码噪声, 从而提高图像的重建质量. Trinh 等^[10]提出了一种用于医学图像重建的非负稀疏线性表示模型; Ren 等^[11]通过多源图像的低秩融合, 验证了将低秩分解与压缩感知结合运用于图像超分辨率重建的有效性; Dong 等^[12]将深度卷积网络引入图像超分辨率重建, 取得了较好的重建效果.

目前, 遥感成像朝着高分辨率和大视场角的方向发展, 这意味着遥感图像的尺度越来越大, 观测精度越来越高, 从而可以获得更高的成像质量和更多的地物信息. 传统的压缩感知处理方法将图像看作单尺度, 图像的各子区域采用统一化方式进行重建, 这种操作虽然简单, 但未必有效, 因为不同尺度的图像块可能包含了不同的判别信息. 为了有效利用遥感图像的尺度特性, 将多尺度的思想引入压缩感知领域, 这刚好适合高分辨率和大视场角的遥感成像特点. 此外, 由于在同样分辨率和视场角的条件下, 小尺度子区域成像的综合成本远小于大尺度子区域成像的综合成本, 将多尺度成像方式与压缩感知理论相结合, 能够大幅度降低采样及重建环节的综合成本. 这使得多尺度方式不仅适合压缩感知遥感成像框架的基本需求, 而且在相关研究领域也具有很好的应用前景, 因此, 本文将多尺度压缩感知理论运用于遥感图像超分辨率重建.

1 多尺度压缩感知框架

压缩感知理论的基本框架包括采样和重建两部分. 在该框架中采样部分的代价远小于传统遥感数据采样方式, 同时其地面重建部分的代价则相应的高于传统方式. 虽然压缩感知重建算法的复杂度较高, 但对于地面处理系统而言却是可以接受的, 并且能够获得令人满意的重建效果.

设 $\mathbf{x} \in \mathbf{R}^N$ 是原始信号, 它在测量矩阵 $\Phi \in \mathbf{R}^{M \times N} (M \ll N)$ 下的测量值 $\mathbf{y} \in \mathbf{R}^M$ 可以表示为

$$\mathbf{y} = \Phi \mathbf{x}. \quad (1)$$

由于 \mathbf{y} 的维数远低于 \mathbf{x} 的维数, 式(1)无法精确求解. 然而, 如果 \mathbf{x} 满足稀疏性, 并且 Φ 满足约束等距性, 则 \mathbf{x} 可以通过以下的最优 l_0 范数问题精确求解:

$$\hat{\mathbf{x}} = \operatorname{argmin} \|\mathbf{x}\|_0 \quad \text{s.t.} \quad \Phi \mathbf{x} = \mathbf{y}. \quad (2)$$

但是, 在实际情况中, 信号 \mathbf{x} 通常不是稀疏的. 因此, 需要引入变换基 Ψ , 使得 \mathbf{x} 在 Ψ 变换域上可以稀

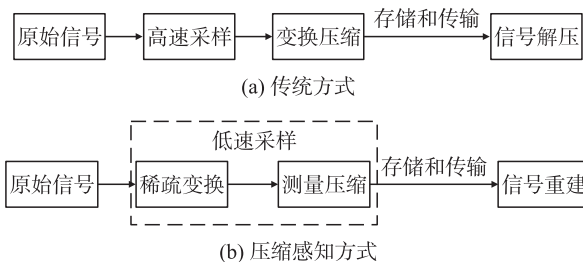


图 1 两种图像信号获取和处理的方式

Fig. 1 Two kinds of image signal acquisition and processing methods

疏表示,即 $x = \Psi\alpha$, 从而有

$$\hat{\alpha} = \operatorname{argmin} \|\alpha\|_0 \quad \text{s.t.} \quad \Phi\Psi\alpha = y, \quad (3)$$

式中, α 为 x 的稀疏表示系数. 式(3)是一个 NP-hard 问题, 实际求解中, 可以使用 l_1 范数代替 l_0 范数, 即

$$\hat{\alpha} = \operatorname{argmin} \|\alpha\|_1 \quad \text{s.t.} \quad \Phi\Psi\alpha = y, \quad (4)$$

式(4)是一个凸优化问题, 有很多方法可以求解^[13-15].

与传统的压缩感知框架类似, 多尺度压缩感知框架主要包括两个部分: 多尺度图像采样和多尺度子区域重建. 其中, 多尺度采样的思想来源于 Brady 和 Hagen^[16]提出的多尺度透镜组, 即通过组合不同尺度的光学系统来实现大视场角的高分辨率成像. 多尺度采样在压缩感知框架下的实现方式是在多尺度划分的基础上对图像的各子区域进行压缩感知欠定采样, 然后按照对应的顺序对采样数据进行后续处理.

多尺度子区域重建与传统压缩感知重建的主要区别在于重建过程中引入了图像块的类别先验信息. 具体实现流程是先使用外部图像库生成符合多尺度模式的训练样本集, 再根据训练样本集学习得到包含图像块类别信息的判别字典, 最后在压缩感知重建框架下求出各子区域图像在判别字典下的稀疏表示系数, 即解决一个如下的 l_1 范数优化问题:

$$\min \|\alpha\|_1 \quad \text{s.t.} \quad \Phi D^{(\text{class}(y))} \alpha = y, \quad (5)$$

式中, Φ 为测量矩阵, D 为判别字典, y 为采样值. 根据求得的稀疏表示系数 α 和判别字典 D 重建出多尺度模式下的各子区域图像, 将这些子区域图像按照最初的采样顺序进行排列即可得到最终的重建结果. 图 2 给出了整个多尺度压缩感知框架下的图像信号处理流程.

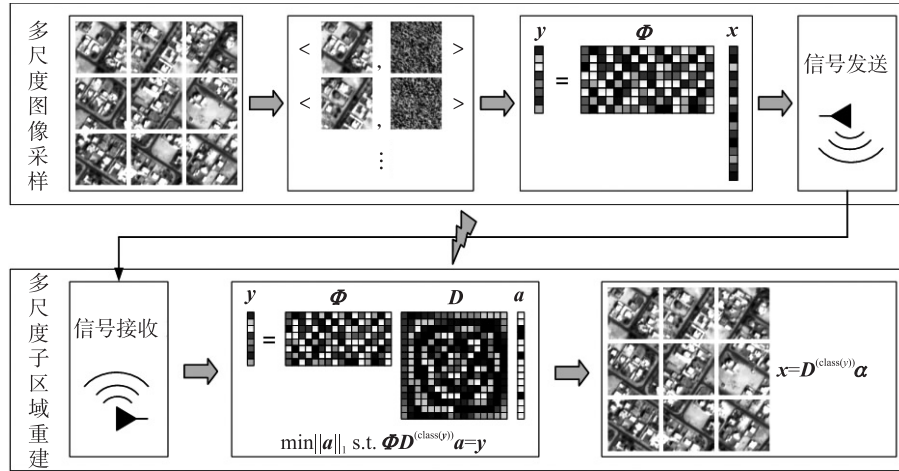


图 2 多尺度压缩感知框架下的图像信号处理流程

Fig. 2 Image signal processing flow in the multi-scale compressed sensing framework

2 基于多尺度压缩感知的遥感图像超分辨率重建

2.1 多尺度训练样本集的构建

本文使用的训练图像和测试图像均来自资源三号卫星拍摄的遥感图像. 首先, 选择一定数量的真实遥感图像作为外部图像库, 用于构建训练样本集. 接着, 选择另外一部分遥感图像作为测试样本, 保证外部图像库与测试图像各自独立.

传统的压缩感知方法学习字典时所用的训练样本集主要有两种获得途径, 包括根据外部图像库进行构建和根据低分辨率图像自身进行构建. 前者希望学习一个通用字典, 能够包含图像库提供的大量附加信息, 但其适用范围往往受限于测试图像的类型. 如果测试图像与训练图像结构特征相近, 则该字典可以表现出较优的性能, 否则, 可能会由于测试图像与训练图像差异过大, 导致重建结果的不稳定. 后者希望学习一个自适应字典, 根据低分辨率图像自身提供的先验信息训练字典, 其不受限于图像类型, 但由于获取的附加信息有限, 对于图像细节的恢复能力不及通用字典.

为了有效结合两种训练样本集构建方法的优势, 本节通过对图像块进行聚类生成符合多尺度模式的多个子训练样本集. 如图 3 所示, 首先, 将测试图像按照不同的尺度进行缩放, 形成金字塔结构, Y_0 代表待

重建的低分辨率图像,其下层图像的分辨率高于 Y_0 ,可以通过双三次插值获得,其上层图像的分辨率低于 Y_0 ,可以通过模糊和下采样获得.将金字塔中的各级图像分块后得到自适应训练样本集 Ω ,传统的自适应字典就是根据 Ω 进行学习,但本节需要根据 Ω ,利用外部图像库建立多尺度训练样本集,进而学习得到判别字典.

得到训练样本集 Ω 后,使用 K-means 算法对其中的图像块进行聚类并确定各类中心,得到 c 类子训练样本集.将外部图像库中的训练样本按照 Ω 中图像块的尺寸进行划分,通过计算图像块与各类中心的距离将其进行分类,得到 c 个类别的多尺度训练样本集.

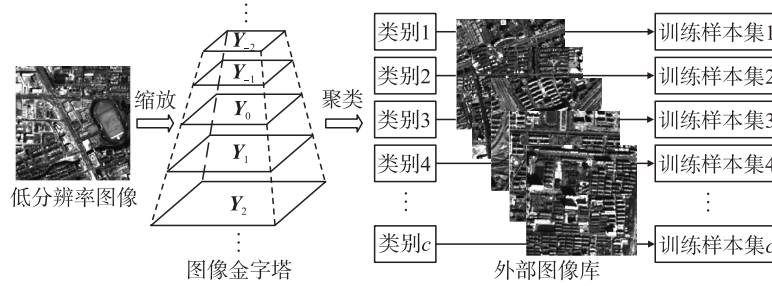


图 3 多尺度训练样本集的构建

Fig. 3 The construction of the multi-scale training sample sets

2.2 判别字典学习

为了实现多尺度压缩感知框架下的遥感图像超分辨率重建,需要根据 2.1 节构建的多尺度训练样本集学习稀疏字典,最简单的方式是为每个子训练样本集分别学习一个字典,保证对测试图像的各子区域使用相应类别的字典进行重建.然而,学习多个字典可能会造成信息冗余.为了使字典结构更加紧凑,可以更好地利用图像块级别的信息,本节根据多尺度训练样本集学习判别字典用于重建.

设训练样本集合为 P ,共有 c 类,与之对应的稀疏表示系数集合为 Z ,第 i 类训练样本集合为 P_i ,相应的稀疏表示系数集合为 Z_i , $p_{i,j}$ 和 $z_{i,j}$ 分别为 P_i 和 Z_i 中的一个样本, n_i 为该类的样本数.对于判别字典 D ,第 i 类子字典表示为 D_i ,其他类别字典表示为 \tilde{D}_i .由于图像块 $p_{i,j}$ 与子字典 D_i 具有相似的结构特征, D_i 中包含了有助于恢复图像细节的大部分信息,因此,希望 $p_{i,j}$ 能使用 D_i 进行稀疏表示,即稀疏表示系数应该满足 $\|p_{i,j} - D_i z_{i,j}\|_2^2$ 和 $\|\tilde{D}_i \tilde{z}_{i,j}\|_2^2$ 尽可能小,从而可以将重建保真项表示如下:

$$f(P, D, Z) = \sum_{i=1}^c \sum_{j=1}^{n_i} (\|p_{i,j} - D_i z_{i,j}\|_2^2 + \|p_{i,j} - \tilde{D}_i \tilde{z}_{i,j}\|_2^2). \quad (6)$$

为了使不同类别图像块的稀疏表示系数之间的可区分性得以增强,将 Fisher 判别准则^[17]运用于字典学习,通过最小化 Z 的类内散度 $S_w(Z)$,并最大化 Z 的类间散度 $S_b(Z)$ 来提高字典的判别能力. $S_w(Z)$ 和 $S_b(Z)$ 定义如下:

$$S_w(Z) = \sum_{i=1}^c \sum_{j=1}^{n_i} (z_{i,j} - m_i)(z_{i,j} - m_i)^T, \quad (7)$$

$$S_b(Z) = \sum_{i=1}^c n_i (m_i - m)(m_i - m)^T, \quad (8)$$

式中, m 为 Z 的均值向量, m_i 为第 i 类训练样本对应的稀疏表示系数集合 Z_i 的均值向量.

为了使类内样本尽可能地靠近,同时使类间样本尽可能地分离,只需最小化类内散度与类间散度之差,因此,将判别约束项定义如下:

$$g(Z) = \text{tr}(S_w(Z)) - \text{tr}(S_b(Z)). \quad (9)$$

结合式(6)和式(9),得到判别字典 D 的学习模型:

$$\{D, Z\} = \arg \min_{\{D, Z\}} \{f(P, D, Z) + \lambda_1 \|Z\|_1 + \lambda_2 g(Z)\}, \quad (10)$$

式中, $f(P, D, Z)$ 为重建保真项, $\|Z\|_1$ 为稀疏约束项, $g(Z)$ 为判别约束项, λ_1 和 λ_2 为正则化参数,用于平衡 3 个约束项之间的关系.对于式(10)采用迭代优化的方式求解,即固定 D ,更新 Z ;固定 Z ,更新 D .通过迭代计算得到最终的判别字典 D .

2.3 多尺度图像超分辨率重建

由式(1)可知,在压缩感知理论中,测量值 y 和测量矩阵 Φ 是已知的,原始信号 x 是待求解的.而在图像超分辨率重建中,只有低分辨率图像 Y 是已知的, Y 是通过何种方式退化而来的往往是未知的.考虑到超分辨率重建问题与压缩感知问题的相似性,如果将低分辨率图像看作是高分辨率图像在某种测量矩阵下的测量值,则超分辨率重建问题便转换为如何根据该测量矩阵的采样值精确重建原始信号.

本节利用测量矩阵的构造方式对低分辨率图像的获取过程进行估计.设图像超分辨率重建时的缩放因子为 2,即低分辨率图像中的 1 个像素对应于高分辨率图像中的 4 个像素.根据这种对应关系,可以对高分辨率图像中的每个像素赋予不同的权重.由给定的低分辨率图像 Y 先通过双三次插值算法进行超分辨率重建,得到插值图像 Q 作为初始高分辨率图像.然后,按照图 4 所示,建立低分辨率图像 Y 中每个像素与插值图像 Q 中 2×2 图像块间的对应关系.

设 y_i 是低分辨率图像 Y 中位置 i 的像素值, $q_{i,j}$ 为插值图像 Q 中对应的 2×2 图像块中相应位置的像素值, $j=1,2,3,4$,用 $q_{i,j}$ 的线性表示对 y_i 进行估计,即

$$\hat{y}_i = \hat{\omega}_{i,1}q_{i,1} + \hat{\omega}_{i,2}q_{i,2} + \hat{\omega}_{i,3}q_{i,3} + \hat{\omega}_{i,4}q_{i,4}, \quad (11)$$

式中, $\hat{\omega}_{i,j}$ 为权重, $j=1,2,3,4$. 本文设置的权重与 y_i 和 $q_{i,j}$ 的距离成反比:

$$\hat{\omega}_{i,j} = \frac{\exp(-|y_i - q_{i,j}|/h)}{\sum_{j=1}^4 \exp(-|y_i - q_{i,j}|/h)}, \quad (12)$$

式中, h 为控制常数. 为了使 y_i 与 \hat{y}_i 相等,调整 $\omega_{i,j}$ 如下:

$$\omega_{i,j} = (y_i / \hat{y}_i) \hat{\omega}_{i,j}. \quad (13)$$

求得插值图像 Q 中每个像素的权重,构成 1 个与 Q 尺寸相同的权重矩阵,并将其作为编码矩阵.然后,根据分块压缩感知^[18]的思想构造测量矩阵.设编码矩阵按照 8×8 分块,在缩放因子为 2 的情况,测量矩阵的尺寸为 16×64 .如图 5 所示,测量矩阵的每一行由编码矩阵中对应的 2×2 分块行向量量化而得到.

将插值图像 Q 按照 8×8 分块,低分辨率图像 Y 按照 4×4 分块,对每个分块进行列向量化,如图 6 所示,则 Y 可以看作是 Q 通过测量矩阵 Φ 采样而得的.由此,在压缩感知框架下对低分辨率图像的获取方式进行了估计,结合 3.2 节的判别字典,得到如下的多尺度图像超分辨率重建模型:

$$\hat{\alpha} = \arg \min_{\alpha} \{ \|Y - \Phi D \alpha\|_2^2 + \eta \|\alpha\|_1 \} \quad (14)$$

式中, η 为正则化参数, D 为判别字典, α 为稀疏表示系数.式(14)中的 α 可以使用迭代收缩算法^[13]求解.根据 $\hat{X} = D\hat{\alpha}$ 即可求得最终的高分辨率图像 \hat{X} .

3 实验结果与分析

3.1 模拟降质图像超分辨率重建

为了验证本文算法的有效性,使用资源三号卫星拍摄的遥感图像进行实验.大多数超分辨率算法认




图 4 低分辨率图像与插值图像像素间的对应关系
Fig. 4 The correspondence between pixels of the low-resolution image and the interpolation image




图 5 测量矩阵的构造方式
Fig. 5 The construction method of the measurement matrix




图 6 低分辨率图像的获取方式

Fig. 6 The acquisition process of the low-resolution image

为图像的降质因素包括模糊、下采样和噪声,因此可以将图像的降质过程表示如下

$$Y=SHX+v \tag{15}$$

式中, X 为原始高分辨率图像, Y 为对应的低分辨率图像, S 为下采样算子, H 为模糊算子, v 为噪声. 选取 10 幅图像作为测试样本,并根据式(15),通过对测试图像进行高斯模糊、下采样和添加噪声操作,获得待重建的低分辨率图像,高斯模糊核的尺寸为 7×7 ,标准差为 1.6,行和列方向上的下采样因子为 2,加性高斯噪声的标准差为 5. 外部图像库包含 10 幅遥感图像,用作字典学习,训练样本集的种类数设置为 20,图像块尺寸为 8×8 .

实验中,将本文算法与其他典型的图像超分辨率算法进行比较,包括双三次插值(Bicubic), Yang 等^[5]的稀疏编码超分辨率算法(Sparse coding super-resolution, SCSR), Pan 等^[8]的结合压缩感知框架和结构自相似性的超分辨率算法(Compressive sensing and structural self-similarity based method, CSSS)和 Dong 等^[9]的非局部集中稀疏表示算法(Nonlocally centralized sparse representation, NCSR).

图 7 给出了一幅遥感图像使用 5 种超分辨率算法重建的结果,每幅图像的左下角为局部细节图. 从图中可以看出,双三次插值算法重建的图像过于平滑,图像的边缘模糊严重;SCSR 算法恢复了部分细节,但是纹理保持能力较差,局部区域存在伪边缘;CSSS 算法重建的图像更加清晰,如细节图中的半圆形建筑;NCSR 算法恢复了许多细节,尤其是具有小尺度特征的目标. 然而由于这些算法将图像看作是单尺度的,重建效果具有一定的局限性. 与前几种算法相比,本文算法重建的图像得到了最佳的视觉效果,提高了边缘锐度,增强了纹理细节信息.




图 7 模拟降质图像的超分辨率重建结果

Fig. 7 Super-resolution reconstruction results of the simulated degradation image

为了客观评价各种算法的重建效果,本文使用峰值信噪比(Peak signal to noise ratio, PSNR)和结构相似性(Structural similarity, SSIM)作为评价指标. PSNR 和 SSIM 的取值越大表示重建图像的质量越高. 表 1 和表 2 分别给出了不同算法重建图像的 PSNR 和 SSIM 值. 从中可以看出,与 Bicubic、SCSR、CSSS 和 NCSR 算法相比,本文算法在两个评价指标下均取得了最佳的超分辨率重建效果,且平均 PSNR 的提高程度分别为 2.19、0.95、0.76 和 0.27,平均 SSIM 的提高程度分别为 0.054、0.025、0.020 和 0.005.

3.2 真实遥感图像超分辨率重建

在 3.1 节中,根据式(15)模拟了图像的降质过程,并对降质图像进行超分辨率重建. 然而,真实遥感图像的获取过程往往更加复杂,因此,本节直接对资源三号卫星拍摄的遥感图像进行超分辨率重建,从而验证本文算法的实用性.

表 1 不同算法重建图像的 PSNR 值

Table 1 PSNR results of the reconstructed images by different methods

图像	Bicubic	SCSR	CSSS	NCSR	本文算法
样本 1	27.1932	28.2742	28.5806	28.9494	29.1647
样本 2	27.1554	28.3250	28.4992	28.9831	29.1988
样本 3	31.3046	32.7237	33.1376	33.4099	33.6343
样本 4	27.8221	29.4249	29.7583	30.2380	30.2894
样本 5	27.5785	28.6525	28.7487	29.3639	29.7253
样本 6	31.3565	32.9047	33.1626	33.5102	33.8096
样本 7	27.0262	28.1229	28.3707	28.9145	29.1173
样本 8	29.6291	30.7739	30.7760	31.4789	31.8521
样本 9	30.1527	31.2008	31.2161	31.8711	32.2963
样本 10	28.0129	29.1882	29.2794	29.7484	30.0435

表 2 不同算法重建图像的 SSIM 值

Table 2 SSIM results of the reconstructed images by different methods

图像	Bicubic	SCSR	CSSS	NCSR	本文算法
样本 1	0.8739	0.9019	0.9093	0.9258	0.9303
样本 2	0.8754	0.9127	0.9146	0.9297	0.9350
样本 3	0.8915	0.9210	0.9221	0.9331	0.9368
样本 4	0.8968	0.9314	0.9347	0.9467	0.9505
样本 5	0.8641	0.8972	0.9043	0.9244	0.9321
样本 6	0.9127	0.9428	0.9456	0.9568	0.9613
样本 7	0.8692	0.8953	0.8984	0.9172	0.9243
样本 8	0.8865	0.9127	0.9212	0.9349	0.9419
样本 9	0.8920	0.9175	0.9257	0.9405	0.9470
样本 10	0.8816	0.9042	0.9079	0.9231	0.9274

图 8 给出了 1 幅遥感图像的超分辨率重建结果. 从整幅图像来看,双三次插值和 SCSR 算法重建图像的质量明显低于另外 3 种算法. 从局部细节图来看,本文算法对纹理信息的恢复能力要强于 CSSS 和 NCSR 算法,图像中地物的可辨识度明显提高. 对于真实遥感图像而言,本文算法依旧可以取得更加突出的重建效果,这将有利于遥感图像的后续处理,例如目标识别、地物精细分类等.




图 8 真实遥感图像的超分辨率重建结果

Fig. 8 Super-resolution reconstruction results of the real remote sensing image

由于 PSNR 和 SSIM 只适用于原始图像已知的情况,而本节实验中没有高分辨率参考图像. 因此,本节使用无参考评价指标信息熵(Entropy)和平均梯度(Average gradient, AG)对超分辨率算法的重建效果进行定量分析. 其中,信息熵可以反映图像信息量的多少,熵值越大,则信息量越多;平均梯度可以反映图像的清晰程度,平均梯度越大,则图像越清晰. 表 3 和表 4 分别给出了不同算法重建图像的信息熵和平均梯度. 从中可以看出,与 Bicubic、SCSR、CSSS 和 NCSR 算法相比,本文算法重建图像的信息熵分别提高了 0.078、0.070、0.037 和 0.012,平均梯度分别提高了 1.87、1.35、0.79 和 0.28,从而进一步体现出本文算法的优越性.

表 3 不同算法重建图像的信息熵
Table 3 Entropy results of the reconstructed images by different methods

图像	Bicubic	SCSR	CSSS	NCSR	本文算法
样本 1	7.7197	7.7324	7.7835	7.8225	7.8319
样本 2	7.8075	7.8180	7.8532	7.8597	7.8783
样本 3	7.6399	7.6459	7.6714	7.7186	7.7295
样本 4	7.5896	7.6018	7.6853	7.6934	7.7046
样本 5	7.5679	7.5720	7.6144	7.6213	7.6398
样本 6	7.5176	7.5296	7.5426	7.5751	7.5853
样本 7	7.5063	7.5157	7.5265	7.5674	7.5781
样本 8	7.6575	7.6639	7.7138	7.7312	7.7427
样本 9	7.6325	7.6423	7.6431	7.6803	7.6934
样本 10	7.8579	7.8635	7.8759	7.8935	7.8972

表 4 不同算法重建图像的平均梯度
Table 4 AG results of the reconstructed images by different methods

图像	Bicubic	SCSR	CSSS	NCSR	本文算法
样本 1	5.6319	6.4714	6.7994	7.1303	7.4015
样本 2	6.4469	7.0247	7.3642	7.8461	8.1459
样本 3	5.7034	5.9688	6.6416	7.2521	7.4538
样本 4	5.6320	6.0415	6.6007	7.3479	7.7864
样本 5	6.0458	6.3637	6.5915	6.8743	7.2502
样本 6	6.3283	6.8131	7.5212	8.1748	8.3531
样本 7	6.1018	6.5961	7.5061	7.8919	8.1484
样本 8	5.5217	6.1574	6.6579	7.4198	7.5212
样本 9	5.9164	6.5462	7.3503	7.5916	7.9731
样本 10	6.7975	7.3599	7.8714	8.5014	8.7686

4 结语

本文将多尺度思想与压缩感知理论结合运用于遥感图像超分辨率重建. 提出的算法把低分辨率图像看作高分辨率图像在测量矩阵下的采样值,从而将超分辨率重建问题转换为压缩感知框架下的信号重建问题. 同时考虑到遥感图像的尺度特性,根据多尺度训练样本集学习判别字典,并使用包含遥感图像类别信息的判别字典对低分辨率图像的各子区域进行超分辨率重建. 与其他几种算法相比,本文算法从主观视觉上来看,重建图像的细节信息更丰富;从客观评价指标上来看,评价指标的取值均有所提高.

[参考文献]

[1] DONOHO D L. Compressed sensing[J]. IEEE transactions on information theory,2006,52(4):1 289-1 306.
[2] TSAIG Y,DONOHO D L. Extensions of compressed sensing[J]. Signal processing,2006,86(3):549-571.
[3] CANDÈS E J,WAKIN M B. An introduction to compressive sampling[J]. IEEE signal processing magazine,2008,25(2):21-30.
[4] FAN N. Super-resolution using regularized orthogonal matching pursuit based on compressed sensing theory in the wavelet domain[C]//IEEE international conference on computer graphics, imaging and visualization. Tianjin, China: IEEE, 2009: 349-354.

- [5] YANG J, WRIGHT J, HUANG T S, et al. Image super-resolution via sparse representation[J]. IEEE transactions on image processing, 2010, 19(11): 2 861–2 873.
- [6] YANG S, SUN F, WANG M, et al. Novel super resolution restoration of remote sensing images based on compressive sensing and example patches-aided dictionary learning [C]//IEEE international workshop on multi-platform/multi-sensor remote sensing and mapping. Xiamen, China: IEEE, 2011: 1–6.
- [7] KULKARNI N, NAGESH P, GOWDA R, et al. Understanding compressive sensing and sparse representation-based super-resolution[J]. IEEE transactions on circuits and systems for video technology, 2012, 22(5): 778–789.
- [8] PAN Z, YU J, HUANG H, et al. Super-resolution based on compressive sensing and structural self-similarity for remote sensing images[J]. IEEE transactions on geoscience and remote sensing, 2013, 51(9): 4 864–4 876.
- [9] DONG W, ZHANG L, SHI G, et al. Nonlocally centralized sparse representation for image restoration[J]. IEEE transactions on image processing, 2013, 22(4): 1 620–1 630.
- [10] TRINH D, LUONG M, DIBOS F, et al. Novel example-based method for super-resolution and denoising of medical images[J]. IEEE transactions on image processing, 2014, 23(4): 1 882–1 895.
- [11] REN K, XU F. Super-resolution images fusion via compressed sensing and low-rank matrix decomposition[J]. Infrared physics and technology, 2015, 68: 61–68.
- [12] DONG C, LOY C C, HE K, et al. Image super-resolution using deep convolutional networks[J]. IEEE transactions on pattern analysis and machine intelligence, 2016, 38(2): 295–307.
- [13] DAUBECHIES I, DEFRISE M, DE MOL C. An iterative thresholding algorithm for linear inverse problems with a sparsity constraint[J]. Communications on pure and applied mathematics, 2004, 57(11): 1 413–1 457.
- [14] ZHANG X, BURGER M, BRESSON X, et al. Bregmanized nonlocal regularization for deconvolution and sparse reconstruction[J]. SIAM journal on imaging sciences, 2010, 3(3): 253–276.
- [15] ZHANG Z, RAO B D. Extension of SBL algorithms for the recovery of block sparse signals with intra-block correlation[J]. IEEE transactions on signal processing, 2013, 61(8): 2 009–2 015.
- [16] BRADY D J, HAGEN N. Multiscale lens design[J]. Optics express, 2009, 17(13): 10 659–10 674.
- [17] YANG M, ZHANG L, FENG X, et al. Fisher discrimination dictionary learning for sparse representation[C]//IEEE international conference on computer vision. Barcelona, Spain: IEEE, 2011: 543–550.
- [18] GAN L. Block compressed sensing of natural images[C]//IEEE international conference on digital signal processing. Cardiff, UK: IEEE, 2007: 403–406.

[责任编辑:顾晓天]