

小波树结构在贝叶斯压缩感知图像重构中的应用研究

袁琴^{1,2} 吴宣够² 熊焰²

(黄山学院机电与信息工程学院 黄山 245041)¹

(中国科学技术大学计算机科学与技术学院 合肥 230026)²

摘要 结合贝叶斯和压缩感知理论,提出了一种基于小波变换的图像压缩和重建方法。这种算法充分利用了小波变换系数的结构特征和相关性,有效地提高了图像的压缩比例和重建精度。对小波变换的尺度系数采用基于预测的恢复算法;对高频系数的恢复结合了贝叶斯理论和压缩感知理论,采用了一种基于回归模型的方法,通过高斯混合参数对未知权值参数赋予确定的先验分布,以限制系数的稀疏性。该方法能够得到未知参数的一组具有较高概率的模型,从而实现系数在MMSE意义下的重建。与现有的图像压缩方法以及其它基于压缩感知的图像压缩方法相比,该算法能够获得较高的图像重建质量和较大的图像压缩比。

关键词 压缩感知,小波变换,图像压缩,贝叶斯

中图分类号 TN95 **文献标识码** A

Research on Application of Wavelet Tree Structure in Bayesian Compressive Sensing Image Reconstruction

YUAN Qin^{1,2} WU Xuan-gou² XIONG Yan²

(School of Mechanical Electronic & Information Engineering, Huangshan University, Huangshan 245041, China)¹

(Computer Science and Technology College, University of Scientific Technology, Hefei 230026, China)²

Abstract Combining Bayesian learning and compressive sensing, an image compression and reconstruction method based on wavelet transform was proposed in this article. Utilizing the specific structure and correlation of wavelet transforming coefficients, this method improves the image compression rate and reconstruction accuracy effectively. At same time, a regression model based on prediction is adopted in coefficient reconstruction, Gaussian mixture parameters are used to predefine the prior conditional density of the unknown parameters in order to enforce the sparsity. This method can get a group of model with high probability of the coefficients, and result in reconstruction of the image in sense of MMSE. Compared with other image compression methods and CS based image reconstruction methods, the proposed method can get reconstruction images with high quality and get bigger compression rate.

Keywords Compressive sensing, Wavelet, Image compression, Bayesian

目前数字图像压缩最常用的方法是基于变换编码的方法:首先对图像进行某种稀疏变换,如离散余弦变换、小波变换等,然后对变换系数进行某种阈值处理,只对其中一些显著系数进行编码和传输;在接收端利用接收到的显著系数重建图像^[1]。这种图像压缩方法必须按照 Nyquist 采样率进行采样,这加大了数据采集端硬件实现的难度;另一方面,在数据传输的时候只保留了其中极少一部分显著系数,而丢弃了大多数非显著系数。那么我们能否在采样的时候直接按照图像所包含的信息量进行采样呢?压缩感知理论就是这样一种直接按照信号信息量进行采样的方法^[2]。

压缩感知理论指出,对于稀疏信号、可压缩信号,可以用远低于 Nyquist 采样率所要求的采样数据进行信号或图像的高效重建。在压缩感知理论中,对信号的采样、压缩编码发生在同一个步骤,即利用信号的稀疏性,以远低于 Nyquist 采样

率的速率对信号进行非相关测量。压缩感知理论的解码过程不是编码的简单逆过程,而是通过求解一个非线性最优化问题,在概率意义上实现信号的精确重构或者一定误差下的近似重构,解码所需测量值的数目远小于传统理论下的样本数。

由于其压缩采样特性,压缩感知理论近年来在图像压缩和重构等领域得到了广泛的应用。Han 等人给出了基于压缩感知理论的图像表示方法^[3];Wu 等人将滑动自回归模型应用到基于 CS 理论的图像编码中^[4];Goyal 等人从信息论的角度比较了不同的基于 CS 理论的图像编码方法^[5]。由于小波变换(DWT)在图像压缩领域的广泛应用,过去几年学者们越来越多地考虑将 DWT 与压缩感知理论相结合以实现图像的压缩编码^[6]。然而大多数文献都只考虑了小波变换系数的稀疏特性。文献[7]指出充分利用 DWT 系数的结构特征能够进一步降低重建图像所需要的样本数据,同时能够保持图像

到稿日期:2013-05-13 返修日期:2013-08-05 本文受国家自然科学基金:未来无线网络体系结构与关键技术(61170233),校级科研项目(2010xkj005),教育厅科研项目(KJ2011B164)资助。

袁琴(1974—),女,硕士,讲师,主要研究方向为无线传感网、压缩感知,E-mail: djyq@hsu.edu.cn;吴宣够(1979—),男,博士生,主要研究方向为视频与传输、压缩感知与传感器网络;熊焰男,教授,博士生导师,主要研究方向为分布式处理、移动计算、计算机网络和信息安全。

重建的质量。

本文在分析小波变换系数各层之间以及每一层内部之间的统计特性的基础上,针对其不同特性提出了一种新的基于压缩感知理论的 DWT 压缩编码方法,对尺度系数和高频系数采用不同的采样和编码方法。小波变换的尺度系数包含了图像的大部分能量并且具有较强的层内互相关性;高频系数与相对应的尺度系数具有较强的相关性且相邻系数之间也具有较强的相关性。对于尺度系数,可以采用基于预测的压缩感知编码方法;对于高频分量,可以采用基于 Bayesian 理论的编码方法。在重建过程中,本文采用了一种基于回归模型的系数重建方法,通过高斯混合参数对未知权值参数赋予确定的先验分布来限制系数的稀疏性。该方法能够得到未知参数的一组具有较高概率的模型,从而实现系数在 MMSE 意义下的重建。基于压缩感知的图像压缩方法直接根据图像所包含的信息量进行采样,而不需要先进行系数变换,然后对显著系数进行编码传输,从而减少了图像重建所需要的样本数。同时在本文中我们还利用了图像小波系数的结构特性进行压缩编码和重建,进一步减少了图像重建所需要的样本数,同时能够保证图像重建的质量。仿真表明了本文方法的有效性。

1 小波树结构

小波变换系数不仅具有稀疏特性,而且系数各层之间以及每一层内部都具有很强的相关性。本节首先分析小波系数的统计特性,以便根据小波系数的统计特性确定不同的压缩采样方法和重建方法。

图 1 所示为 2 层 DWT,其中左上角 LL 为低频-尺度系数;其它部分为高频系数。尺度系数为显著系数,具有较大值,包含了图像的大部分信息。大部分高频系数的幅值很小,趋近于 0,与图像的细节信息相关。小波系数不仅具有稀疏特性,而且系数之间具有较强的相关性。接下来首先分析小波系数之间的相关性,采用 Pearson 相关系数 ρ 作为衡量系数之间相关性强弱的标准^[8]。




图 1 小波变换系数示意图

图 2(a)所示为尺度系数沿水平方向、垂直方向、对角线方向的相关性示意图。从图中可以看出,尺度系数尽管是对原图像降采样以后得到的低分辨率图像,但是与相邻系数的相关系数 $\rho > 0.8$ 。这意味着相邻系数之间存在非常大的冗余。图 2(b)所示为尺度系数与高频系数之间的相关性。从图中可以看出,尺度系数与高频系数之间的相关性较弱。




图 2 尺度系数平均相关性示意图

LH_L, HL_L, HH_L 的小波系数反映了在水平方向、垂直方向、对角线方向的高频分量,具有较大值的系数集中在某些固定区域。如图 3(a)所示,高频系数某一层内部各系数与相邻系数之间的平均相关性 $\rho(LH/HL/HH, |\Delta x| \leq 1, |\Delta y| \leq 1) > 0.5$ 。图 3(b)所示为层与层之间小波系数的相关性。

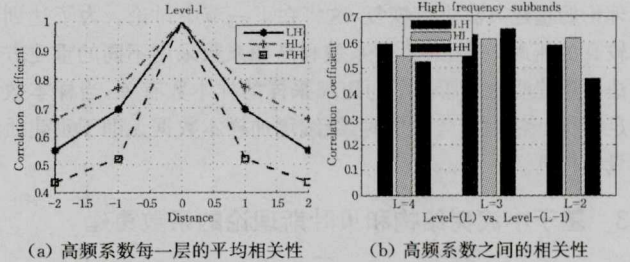


图 3 高频系数相关性示意图

2 基于压缩感知的图像压缩

基于压缩感知理论的图像压缩方法和传统的基于变换编码的图像压缩方法完全不同。本节结合第 2 节分析的图像小波变换系数的特征,提出了一种基于压缩感知理论的图像压缩方法,如图 4 所示。

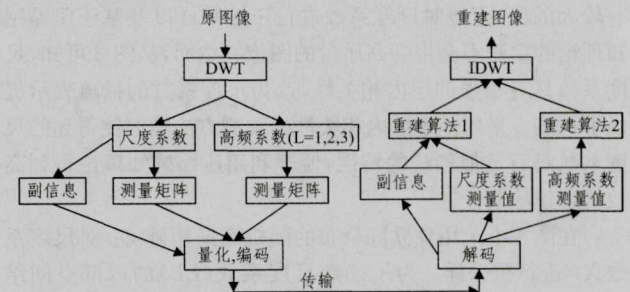


图 4 压缩感知图像压缩流程

首先对原图像进行 2-D DWT 以实现图像的稀疏表示,然后采用随机采样矩阵实现对系数的非相关采样。文献^[9]表明独立同分布高斯矩阵满足压缩感知理论中非相关采样的限制条件,因此在本文中采用独立同分布的高斯矩阵来实现系数的压缩采样。理论上讲,为了重建图像,需要将采样矩阵一起传输以实现图像的精确重构。然而,事实上在图像压缩中不用对每一幅图像都进行采样矩阵的传输,因为这种采样矩阵可以通过种子进行伪随机产生,所以只需要进行种子的传输。

由于小波系数的特殊性,尺度系数包含了图像的大部分能量且具有很强的层内相似性但是层间相似性较弱;高频系数与其对应的尺度系数具有较强的相关性且相邻系数之间也具有较强的相关性;高频系数包含了图像的细节信息,直接丢弃高频系数会造成图像信息的丢失,因此对于尺度系数和高

频系数我们采用不同的采样策略,且每一层高频系数的压缩采样比例也不同。这样就可以依据小波系数的特征确定压缩采样的样本数,从而既达到较高的压缩比,又能实现图像的精确重建。通常情况下,精确重建图像所需要的样本数据远小于小波系数的数据量,从而实现了图像的压缩。

在得到压缩采样的样本数据以后,需要对数据进行分组以及量化编码。通常采用无损编码,比如熵编码等,有利于图像高质量的重建。在传输过程中,数据可能受到噪声或者干扰的影响,从而影响到数据传输的质量。但是在基于压缩感知理论的图像压缩中,这种噪声造成的数据污染不会对图像的重建质量造成重要影响。因为每一个压缩采样的样本都是 Nyquist 采样下所有样本的一个非线性投影,所以单一样本数据的缺失对整个样本数据所包含的信息量影响非常小。

在解码端,尺度系数和低频系数可以采用基于压缩感知理论的重建方法进行恢复,这将在下一节中讨论。为了达到较高的压缩效率,对尺度系数和低频系数采用不同的重建方法。重建质量与所采用的压缩采样的样本数有关,当样本数足以保证精确重建图像时,继续增加样本数据无助于重建质量的提高。

3 基于小波树结构和贝叶斯理论的系数重建

尺度系数包含了图像的大部分能量,大多具有较大的值,且相邻系数之间具有很强的相关性;高频系数值较小,但是包含了图像的细节信息,直接丢弃高频系数会造成重建图像信息的丢失。针对小波系数的不同特征,本文对尺度系数和低频系数采用不同的压缩感知重建算法:基于预测的压缩感知重建算法和基于贝叶斯理论的压缩感知重建算法。

3.1 尺度系数的恢复

小波变换的尺度系数包含了图像的大部分能量,大多具有较大的值,直接对尺度系数进行压缩采样以及基于压缩感知理论的重建不会得到高质量的图像。然而,从图 2 可知,尺度系数具有很强的层内相关性,这为尺度系数的稀疏表示提供了可能。采用基于层内相关性的预测方法能够使得到的尺度系数具有近似稀疏的特性,便于利用压缩感知理论得到高效的恢复质量。

在图 4 中采用独立同分布的随机高斯矩阵 Φ_L 对尺度系数 X_L 进行重采样。为了确定尺度系数(LL)的内部空间结构,首先将 LL 层系数划分为 4×4 的块。对于每一块中的系数,采用具有不同频率和方向的空间 Gabor 滤波器提取每一块的主要方向。利用这样的滤波器,每一个尺度系数相对于滤波器核都有一个输出,具有最大输出值的方向被当作代表方向。对于每一块,计算每一方向系数的数量,具有最大数量的方向被认为是系数内部结构的主要方向。每一块中主要方向的信息被作为附加信息传输到接收端。如果在某一块中没有主要方向,则选择具有较小平均绝对误差的方向作为主要方向。

在接收端利用接收到的辅助信息进行尺度系数的预测解码。在接收到压缩采样样本数据和辅助信息之后,可以通过求解式(1)所示的目标函数实现尺度系数的恢复:

$$\min_{1 \leq l \leq S} \|R[X_L(s)]\|_{l_1} \quad \text{s.t.} \quad \|\Phi_L X_L - Y_L\| \leq \xi \quad (1)$$

式中, X_L, Y_L 分别表示尺度系数和压缩测量值; ξ 表示噪声分量, Φ_L 表示测量矩阵; S 为 4×4 系数块的数量; $R[\cdot]$ 表示利用某一方向模型进行层内系数预测的残差。

3.2 高频系数恢复

为了实现对高频系数的精确重构,我们采用了一种基于 Bayesian 理论的重构方法。这种压缩感知重构方法将系数的恢复问题看作是一个线性回归问题,而待重建的系数是模型中的未知参数。然后利用高斯混合参数对未知参数赋予确定的先验条件分布,从而实现参数的稀疏性限制。这种压缩感知重建方法能够得到恢复系数所需要的一组具有较高后验概率密度的模型,从而实现系数在最小均方误差(MMSE)意义下的重构。

假设 $X_L \in R^N, L$ 为小波系数的层数。在考虑噪声的情况下,压缩采样数据可以表示为:

$$Y_L = \Phi_L X_L + w_L \quad (2)$$

假设噪声为加性噪声,且服从高斯分布,则 $w_L \sim N(0, \sigma^2 I_M), M$ 为压缩采样的样本数。

为了限制 X_L 的稀疏性,假设其由高斯混合密度函数产生,则 X_L 满足如下分布:

$$P(X_L | s) \sim N(0, R(s)) \quad (3)$$

其中, $R(s)$ 为协方差矩阵,且由高斯混合参数 s 构成的随机向量 $s = [s_0, s_1, \dots, s_{N-1}]^T$ 确定。假设 $\{X_{L_n} | s_n\}_{n=0}^{N-1}$ 相互独立且 $P(x_n | s_n) \sim N(0, \sigma_n^2), \{s_n\}_{n=0}^{N-1}$ 服从贝努力分布 $P(s_n = 1) = p_1$, 则 $R(s)$ 为对角阵,且 $[R(s)]_{n,n} = \sigma_n^2$ 。为了限制其稀疏性,设 $\sigma_0^2 = 0$, 且 $p_1 \ll 1$ 。则当 $s_n = 0, X_{L_n} = 0; s_n = 1, X_{L_n} \neq 0$ 时,系数的 X_L 的最小均方误差估计可以表示为

$$\hat{X}_{L,mmse} \triangleq E(X_L | Y_L) = \sum_{s \in S} P(s | Y_L) E\{X_L | Y_L, s\} \quad (4)$$

其中, S 表示所有模型参数构成的集合。由式(2)可得

$$E(X_L | Y_L, s) = R(s) \Phi_L^T A(s)^{-1} Y_L \quad (5)$$

当信号维数较大时,模型集合 S 可能的取值会很大。为了计算的简便,只选取其中几个具有较大概率的模型。则 X_L 的近似最小均方误差估计可以表示为

$$\hat{X}_{L,ammse} \triangleq \sum_{s \in S_*} P(s | Y_L) E\{X_L | Y_L, s\} \quad (6)$$

S_* 表示具有较大概率的模型集合。

由式(5)和式(6)可知,为了得到 X_L 的最小均方误差估计,需要得到 $P(s | y), A(s)^{-1}$ 以及 S_* 。模型向量集合 S 可以表示为 $S \triangleq \{0, 1\}^N, N$ 为待恢复的系数的维数。 X_L 的最小均方误差估计就是从 S 中选出具有较大概率的一组模型向量 S_* , 以及确定 $\{P(s | Y_L)\}_{s \in S_*}$ 。

由 Bayesian 理论可知,模型向量 s 的后验概率密度可以表示为

$$P(s | Y_L) = \frac{P(Y_L | s) P(s)}{\sum_{s' \in S} P(Y_L | s') P(s')} \quad (7)$$

在确定 S_* 后, s 的后验概率密度可以近似表示为

$$P(s | Y_L) \approx \frac{P(Y_L | s) P(s)}{\sum_{s' \in S_*} P(Y_L | s') P(s')} \quad (8)$$

从式(7)、式(8)可知, $P(s | Y_L)$ 与 $P(Y_L | s) P(s)$ 具有正比关系,因此 S_* 的选择与选择 $s \in S$ 使得 $P(Y_L | s) P(s)$ 取较大值等价。为了计算方便,对 $P(Y_L | s) P(s)$ 取对数,得到模型向量的选择标准为:

$$\begin{aligned} v(s, Y_L) &= \ln P(Y_L | s) P(s) = \ln P(Y_L | s) + \ln P(s) \\ &= -\frac{1}{2} Y_L^T A(s)^{-1} Y_L - \frac{1}{2} \ln \det(A(s)) - \frac{1}{2} M \ln 2\pi \\ &\quad + \sum_{n=0}^{N-1} \ln P(s_n) \end{aligned}$$

$$= -\frac{1}{2} Y_L^T A(s)^{-1} y - \frac{1}{2} \ln \det(A(s)) - \frac{1}{2} M \ln 2\pi + \|s\|_0 \ln \frac{p_1}{1-p_1} + N \ln(1-p_1) \quad (9)$$

式中,零范数 $\|s\|_0$ 表示 s 中非 0 元素的个数。

因为 $P(Y_L | s)P(s) = P(Y_L, s)$, $P(Y_L, s) = e^{v(s, Y_L)}$, 因此 $P(Y_L, s)$ 与 $v(s, Y_L)$ 成正比关系, 则 S_* 就是由与 $v(s, Y_L)$ 较大值对应的模型向量 s 组成的集合。为了方便快捷地得到模型向量集合 S_* , 可以采用一种树形搜索方法——贝叶斯匹配追踪(BMP)。首先, 假定混合参数 $\{s_i\}_i^N = 0$, 一次只将一个混合参数由 0 变为 1, 则可以得到 N 个模型向量, 记为 $S^{(1)}$; 由式(9)可以得到集合 $S^{(1)}$ 中所有模型向量的 $v(s, Y_L)$, 然后选择其中 D 个具有最大 $v(s, Y_L)$ 值的模型向量, 记为 $S^{(2)}$ 。接下来将 $S^{(1)}$ 中模型向量的一个混合参数由 0 变为 1, 将得到的模型向量记为 $S^{(2)}$, 由式(9)计算 $S^{(2)}$ 中所有模型向量的 $v(s, Y_L)$ 值, 选择 D 个具有最大 $v(s, Y_L)$ 值的模型向量, 记为 $S^{(3)}$ 。以此类推, 直到满足停止迭代的条件, 则 $S_* = S^{(D)}$ 。

3.3 参数估计

前面的推导是在参数 $\theta = \{p_1, \sigma^2, \sigma_1^2\}$ 已知的情况下得到的。然而通常情况下参数 $\theta = \{p_1, \sigma^2, \sigma_1^2\}$ 是未知的, 必须对其进行估计。对参数的估计可以采用基于期望值最大化的方法实现。

由式(2)可知:

$$P(X_L | s, \sigma_1^2) \sim N(0, \sigma_1^2 D(s)) \quad (10)$$

式中, $D(s)$ 是由混合参数 s 构成的对角矩阵。由式(2)可知

$$P(Y_L | s, \sigma_1^2, \sigma^2) \sim N(0, \sigma_1^2 \Phi_L D(s) \Phi_L^T + \sigma^2 I_M) \quad (11)$$

令 $\alpha = \frac{\sigma^2}{\sigma_1^2}$, 假设 Φ_L 是由 Φ_L 中与混合参数 s 非 0 元素相对应的列向量构成的矩阵, 则

$$P(Y_L | s, \sigma_1^2, \sigma^2) \sim N(0, \sigma_1^2 (\Phi_L \Phi_L^T + \alpha I_M)) \quad (12)$$

基于期望值最大化的参数估计方法可以表示为:

$$\hat{\theta}^{(i+1)} = \arg \max_{\theta} \sum_{s \in S_*} P(s | Y_L, \hat{\theta}^{(i)}) \ln P(Y_L, s | \hat{\theta}^{(i)}) \quad (13)$$

式中, $\ln P(Y_L, s | \hat{\theta}) = \ln P(Y_L | s, \sigma_1^2, \alpha) + \ln P(s | \lambda)$, $\lambda = 1 - p_1$ 。

由式(13)可知

$$\hat{\lambda}^{(i+1)} = \arg \max_{\lambda} \sum_{s \in S_*} P(s | Y_L, \hat{\theta}^{(i)}) \ln P(s | \lambda) \quad (14)$$

$$\text{由于 } \ln P(s | \lambda) = \sum_{n=0}^{N-1} \ln P(s_n | \lambda) = \sum_{n=0}^{N-1} \ln(\lambda + (1-2\lambda)s_n),$$

因此

$$\frac{\partial \ln P(s | \lambda)}{\partial \lambda} = \sum_{n=0}^{N-1} \frac{1-2s_n}{\lambda + (1-2\lambda)s_n} = \frac{K_s}{\lambda-1} + \frac{N-K_s}{\lambda} \quad (15)$$

式中, $K_s = \|s\|_0$ 。则

$$\hat{\lambda}^{(i+1)} = 1 - \frac{1}{N} \sum_{s \in S_*} P(s | Y_L, \hat{\theta}^{(i)}) K_s \quad (16)$$

同理可得:

$$\hat{\alpha}^{(i+1)} = \frac{1}{\sigma_1^2} \sum_{s \in S_*} P(s | Y_L, \hat{\theta}^{(i)}) \frac{1}{M-K_s} \|y\|^2 I_M - \Phi_L (\Phi_L^T \Phi_L)^{-1} \Phi_L^T \quad (17)$$

$$\hat{\sigma}_1^{(i+1)} = \frac{1}{M} \sum_{s \in S_*} P(s | Y_L, \hat{\theta}^{(i)}) \|Y_L\|^2 (\Phi_L \Phi_L^T + \alpha I_M)^{-1} \quad (18)$$

整个算法的主要步骤可以概括为:

1. 对原图像进行小波分解; 利用尺度系数的层内相关性对尺度系数进行预测编码; 对高频系数利用高斯随机采样矩阵进行随机压缩采样;

2. 利用接收到的副信息对尺度系数进行预测解码, 其可以通过求解: $\min \sum_{1 \leq l \leq S} \|R[X_L(s)]\|_{l_1}$ s. t. $\|\Phi_L X_L - Y_L\| \leq \xi$ 实现;

3. 利用贝叶斯理论对高频系数进行 MMSE 意义下的重构, 从而保留图像的细节信息;

For $l=2: L$ (L 为小波分解的级数)

a) $P(X_L | s) \sim N(0, R(s))$, X_L 为小波系数, $R(s)$ 为协方差矩阵, 且由高斯混合参数 s 构成的随机向量 $s = [s_0, s_1, \dots, s_{N-1}]^T$ 确定; X_L 的近似最小均方误差估计可以表示为 $\hat{X}_{L, \text{mmse}} \triangleq \sum_{s \in S_*} P(s | Y_L) E\{X_L | Y_L, s\}$, S_* 为模型向量;

b) 模型向量 S_* 的确定: S_* 是与 $v(s, Y_L)$ 较大值对应的模型向量 s 组成的集合, 本算法是通过 BMP 算法求得 S_* ;

c) 模型参数的估计: a) 和 b) 的计算都是在假设参数 $\theta = \{p_1, \sigma^2, \sigma_1^2\}$ 已知的情况下得到的, 实际中参数预先并不知道, 因此需要通过望值最大化的方法进行估计。

4) 利用求解得到的尺度系数和高频系数进行小波反变换实现图像的精确重构。

4 仿真实验

本节通过计算机仿真来验证本文方法的有效性。首先将本文方法——TS-BCS 与现有的基于压缩感知理论以及稀疏表示的图像压缩方法: BP^[10]、BCS、StOMP^[11]、Lasso^[12] 相比较。选择具有代表性的灰度图像 Lena、Babana 等作为测试图像。首先对每幅图像进行 4 层表波变换。在所对比的方法中, 线性压缩方法就是传统的基于变换的图像压缩方法; 其它基于压缩感知理论的方法是对整个小波变换系数进行压缩采样, 然后进行重建的方法。本文所提出的方法在编码端采用两个不同的独立同分布高斯随机矩阵对尺度系数和高频系数分别进行压缩采样。由于尺度系数包含了图像的大部分能量, 因此对尺度系数进行类全采样, 采样比列为 0.95。由于高频系数的系数性, 可以直接进行压缩采样, 每一层系数的采样比列分别为 0.5、0.25、0.1。所有基于压缩感知理论的方法所采用的压缩采样样本数相同。

图 5 和图 6 分别为测试图像 Babana 和 Lena 基于贝叶斯压缩感知和小波树结构贝叶斯压缩感知重建算法的重构结果。从图中可以看出, 采用本文算法的重建图像的视觉质量明显高于基于贝叶斯方法的重建结果。这是因为本文方法在贝叶斯理论的基础上进一步实现了高频系数在 MMSE 意义下的恢复, 更好地保留了图像的细节信息, 因此能够得到更好的重建质量。





图 5




图 6

为了更好地比较本文算法与其它基于压缩感知理论和系数表示方法的重建图像质量,将本文方法与其它方法的重建质量进行比较,如图 7 所示。在比较中采用 PSNR 作为衡量图像重建质量的标准。由图 7 可知,在压缩比相同的情况下,本文所提出的算法都能获得比其它基于系数表示的图像压缩方法更好的重建结果。在压缩比较大的情况下,一些基于稀疏表示的方法的重建结果甚至比直接保留尺度系数的重建方法的质量更差,比如 StoMP、Lasso。这是因为当压缩采样的样本数较少时,没有达到精确恢复小波系数所需样本数的要求,因此重建结果较差。随着压缩采样样本数的提高,各种方法的重建质量都有明显的提高。当压缩比越低时,各种 CS 方法的重建结果越接近。



(a) Babana




(b) Lena

图 7 不同的方法随降采样比例的重建误差比较


本文所提出的方法在对尺度系数恢复的时候利用了尺度系数内部的相关性。由于表波变换系数的层内以及层间关系与图像的分辨率和小波分解的级数有关,因此接下来验证图像的分辨率和小波分解的级数对 TS-BCS 重建算法的影响。采用的测试图像为 4096×4096 和 512×512 的 Lena 图像,对两幅图像分别进行 7 级和 4 级小波变换。图 8 所示为不同压缩比条件下的重建质量比较。从图中可以看出,对于 4096×4096 的图像,7 级小波变换的重建质量更高;对于 512×512 的图像,4 级小波变换的重建质量更高。这是因为尽管多级小波变换能够使图像去相关,但是并不表示级数越高,去相关效果越好。理论上讲,如果低频段功率谱的带宽大于小波低通滤波器,则这一级小波变换就不需要。对于 4096×4096 的图像,7 级小波变换能够更好地对原图像进行去相关处理;而对于 512×512 的图像,4 级小波变换就已经足够,进一步增

加分解级数会使得尺度系数的重建质量降低。

最后将本文算法与传统的图像压缩方法相比较,包括基于离散余弦变换(DCT)的 Jpeg 算法和基于小波变换的 EZW 和 SPIHT 算法。图 9 所示为相同压缩比情况下的重建图像。为了便于比较,采用了一幅具有均匀场景的遥感图像。从图中可以看出基于 DCT 的 Jpeg 压缩算法效果非常差,这是因为 DCT 值分布比较均匀;基于小波变换的 EZW 和 SPIHT 算法均存在明显的模糊区域;基于本文算法的重建图像质量明显优于其它算法,保留了图像的细节信息。



(a) 1bpp



(b) 0.5bpp

图 8 小波分解级数和图像分辨率对 TS-BCS 重建质量的影响




图 9 不同图像压缩方法的比较

结束语 本文结合压缩感知理论和贝叶斯理论提出了一种基于小波变换的图像压缩方法。这种方法利用了小波变换尺度系数的层内相关性,对尺度系数和低频系数采用不同的恢复算法。在分析尺度系数层内相关性的基础上提出了一种基于预测的系数恢复算法。对于高频系数,利用其稀疏特性,对不同层的小波系数按照不同的压缩比例进行采样,然后对每一层系数进行基于贝叶斯理论的重建。这种恢复方法能够得到一组具有较高概率的模型,从而实现系数在 MMSE 意义下的重建。仿真表明,本文算法能够很好地恢复图像;在压缩比相同的情况下,恢复质量优于其它基于稀疏表示的压缩方法和传统压缩方法。

参考文献

- [1] 刘荣科, 张晓林, 廖晓涛. 一种基于分类 DCT 的图像压缩算法[J]. 遥测遥控, 2011, 22(4): 173-178
- [2] Candès E J, Tao T. Near-optimal signal recovery from random projections: Universal encoding strategies? [C]// IEEE Trans Inf Theory. 2006; 54: 406-5425
- [3] Han B, Wu F, Wu D P. Image representation by compressive sensing for visual sensor networks[J]. J Vis Commun. Image

R. ,2010,21:325-333

- [4] Wu X L, Zhang X J. Model-guided adaptive recovery of compressive sensing [C] // Proc IEEE Data Compression Conf. (DCC'09). Mar. 2009;123-132
- [5] Goyal V K, Fletcher A K, Rangan S. Compressive sensing and lossy compression[J]. IEEE Signal Process. Mag. , 2008, 25; 48-52
- [6] Venkatraman D, Makur A. A compressive sensing approach to object-based surveillance video coding[C]//Proc IEEE Int. Conf Acoustics Speech & Signal Process (ICASSP'09). 2009; 3513-3516
- [7] Baraniuk R G, Cevher V, Duarte M F D, et al. Model-based compressive sensing[J]. IEEE Trans Inf Theory. , 2010, 56; 1982-2001

(上接第 296 页)

- [14] Hsieh J-W, Hu W-F, Chang C-J, et al. Shadow elimination for effective moving object detection by Gaussian shadow modeling [J]. Image and Vision Computing, 2003, 21(6); 505-516
- [15] Nicolas H, Joint J-M P. moving cast shadows segmentation and light source detection in video sequences[J]. Signal Processing; Image Communication, 2006, 21(1); 22-43
- [16] Zhang W, Fang X Z, Yang X K, et al. Moving cast shadows detection using ratio edge[J]. IEEE Trans. Multimedia, 2007, 9; 1202-1213
- [17] Stander J, Mech R, Ostermann J. Detection of moving cast sha-

(上接第 313 页)

- [2] Pohl C, Genderen J. Multi-sensor image fusion in remote sensing; concepts, methods and applications [J]. Remote Sensing, 1998, 9(5); 823-854
- [3] 潘泉, 于昕, 程咏梅, 等. 信息融合理论的基本方法与进展[J]. 自动化学报, 2003, 29(4); 599-615
- [4] 程英蕾, 赵荣椿, 李卫华, 等. 基于像素级的图像融合方法研究[J]. 计算机应用研究, 2004, 21(2); 169-172
- [5] 瞿继双, 王超, 王正志. 基于数据融合的遥感图像处理技术[J]. 中国图像图形学报, 2002, 7(10); 985-992
- [6] Wckdl. Some terms of reference in data fusion [J]. Transactions on Geoscience and Remote Sensing, 1999, 37(3); 1190-1193
- [7] 瞿继双, 王超, 王正志. 基于数据融合的遥感图像处理技术[J]. 中国图像图形学报, 2002, 7(10); 985-992
- [8] Pennec E L, Mallat S. Image compression with geometrical wavelets [C] // MVancouver Canada; Proc of ICIP. 2000, 661-646
- [9] Candes E J. Ridgelets: Theory and Applications [D]. Stanford; Department of Statistics, Stanford University, 1998
- [10] Starck J L, Candes E J, Donoho D L. The curvelet transform for image denoising [J]. Trans Image Processing, 2005, 14(3); 343-359
- [11] Do M N, Vetterli M. Contourlets; a new directional multi-resolution image representation [C] // Conference Record of the 36th

- [8] Dunn P F. Measurement and Data Analysis for Engineering and Science [C] // New York; McGraw-Hill, 2005; 275-281
- [9] Candès E J, Tao T. Reflections on compressed sensing[J]. IEEE Inform. Theory Soc. Newslett. , 2008, 58; 20-23
- [10] Chen S, Donoho D L, Saunders M A. Atomic decomposition by basis pursuit[J]. SIAM J. Sci. Comput. , 1999, 20; 33-61
- [11] Donoho D L, Tsaig Y, Drori I, et al. Sparse solution of underdetermined linear equations by stage wise orthogonal matching pursuit[R]. Tech. Rep. 2006-02. Dept. of Statistics, Stanford University, Stanford, CA, 2006; 1-13
- [12] Efron B, Hastie T, Johnstone I, et al. Least angle regression[J]. Ann. Stat. , 2004, 32; 407-499

dows for object segmentation [J]. IEEE Trans. Multimedia, 1999, 1; 65-76

- [18] Andersen M S, Jensen T, Madsen C B. Estimation of Dynamic Light Changes in Outdoor Scenes Without the use of Calibration Objects[C]//18th Int. Conf. Pattern Recognition. 2006, 4; 91-94
- [19] Stauffer C, Grimson W E L. Adaptive background mixture models for real-time tracking[C] // IEEE Computer Society Conf. Computer Vision and Pattern Recognition. 1999, 2; 637-663
- [20] Prati A, Mikic I, Trivedi M M, et al. Detecting Moving Shadows; Algorithms and Evaluation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2003, 25(7); 918-923

Asilmar Conference on Signals, Systems and Computers. 2002; 497-501

- [12] Eslami R, Radha H. The Contourlet transform for image denoising using cycle spinning [C] // Proceedings of Asilomar Conference on Signals, Systems and Computers. 2003; 1982-1986
- [13] Cunha A L, Zhou J, Do M N. The nonsubsample Contourlet theory design and application [J]. Transaction on Image Processing, 2006, 15(10); 1780-1792
- [14] 沈洁, 胡学龙, 杨义军, 等. 基于非子采样 Contourlet 变换的图像融合算法[J]. 微电子学与计算机, 2009, 26(10); 74-81
- [15] 吴一全, 陈飒, 罗子娟. 基于无下采样 Contourlet 变换的图像融合[J]. 中国电视学与图像分析, 2008, 13(2); 111-115
- [16] 翟军涛, 那彦. 基于 NSCT 的多光谱和全色图像的融合[J]. 激光与红外, 2008, 38(3); 282-284
- [17] 林玉池, 周欣, 宋乐. 基于 NSCT 变换的红外与可见光图像融合技术研究[J]. 传感器与微系统, 2008, 27(12); 45-47
- [18] 宋杨, 万幼川. 一种自适应的基于局部小波系数特征的遥感图像融合方法[J]. 遥感信息, 2007; 3-6
- [19] 邹容, 李玲玲, 李翠华. 基于非下采样 Contourlet 的多聚焦图像融合方法[J]. 厦门大学报, 2009, 48(6); 812-816
- [20] 朱康, 贺新光, 杨波. 一种基于小波系数局部特征的选择性遥感图像融合方法[J]. 遥感信息, 2011, 5(3); 9-14
- [21] 朱康, 贺新光. 基于 Contourlet 系数局部特征的选择性遥感图像融合算法[J]. 激光与光电子学进展, 2012, 49(2); 44-49