

中图分类号: TP751.1 文献标志码: A 文章编号: 1006-8961(2011)11-2081-07

论文索引信息: 杨萌, 张弓. 遥感图像变化区域的无监督压缩感知 [J]. 中国图象图形学报, 2011, 16(11): 2081-2087

遥感图像变化区域的无监督压缩感知

杨萌, 张弓

(南京航空航天大学信息科学与技术学院, 南京 210016)

摘要: 传统的基于结构特征的遥感图像变化检测方法, 易受成像稳定性的影响而误差很大。针对图像内在的稀疏性结构信息, 提出基于压缩感知(CS)的遥感图像变化检测方法。通过自适应构造超完备字典将图像局部信息投影到高维空间中, 实现图像的稀疏表示, 并运用随机矩阵得到了数据在高维空间中的低维特征子空间。最后利用模糊C均值(FCM)聚类算法进行无监督聚类, 实现遥感图像变化区域信息的重构。实验结果表明, 本文方法不仅能够很好的检测出图像的轮廓变化和图像的区域变化, 而且对噪声具有很好的鲁棒性。

关键词: 变化检测; 遥感图像; 压缩感知(CS); 模糊C均值(FCM)聚类

Unsupervised compressive sensing of change area in remote sensing images

Yang Meng, Zhang Gong

(College of Information Science & Technology, Nanjing University of Aeronautics and Astronautics, Nanjing 210016 China)

Abstract: Traditional remote sensing image change detection approaches based on structure features are usually limited by imaging stability. In this paper, we introduce a new method for unsupervised change detection in remote sensing images using compressive sensing (CS) based on the image inherent sparse structures. For this algorithm, a large collection of image patches is projected onto high dimensional spaces through redundant dictionary, giving an adaptive sparse representation per each image patch. A random matrix is taken as measurement matrix to realize feature space dimension reduction. Then, the final change detection is realized by clustering the feature vector space using the fuzzy C-mean clustering (FCM) algorithm, achieving the reconstruction of change regional information. The experimental results demonstrate that the proposed algorithm has good change detection results both in contour and region and has a good robustness.

Keywords: change detection; remote sensing image; compressive sensing (CS); fuzzy C-means (FCM) clustering

0 引言

遥感图像变化检测是指利用多时相获取的同一地区区域的遥感图像来确定和分析地表变化, 提供地物的空间展布及其变化的定性及定量信息, 它在地物地层分析、国土资源普查和军事、灾害监测等方面

面拥有广泛的应用价值和商业价值。

随着遥感图像变化检测技术的不断发展, 研究者提出了多种变化检测算法。图像差值方法^[1]是将两幅图像的灰度值相减, 通过差值图像与所选取的阈值进行比较, 来区分变化与不变化的区域。对数比值方法^[2]是在得到两幅图像对应像素的比值后, 再对其取对数。相比于差值方法, 对数比值方法

收稿日期: 2010-09-29; 修回日期: 2010-12-11

基金项目: 国家自然科学基金项目(61071163)。

第一作者简介: 杨萌(1980—), 男, 南京航空航天大学通信与信息系统专业博士研究生, 主要研究方向为遥感图像分析和信号稀疏性分析。E-mail: yangmeng372901@163.com。

对图像的乘性噪声较为不敏感。基于马尔可夫随机场(MRF)模型的变化检测方法^[3]是利用差值图像或对数比值图像数据的局部相关性,用一个2维随机场描述图像模型,它使用条件概率描述图像的数据分布,表征了图像数据的空间相关性。基于主分量分析(PCA)的变化检测方法^[4]是通过对差值图像或对数比值图像的局部邻域使用主分量变换,得到每个像素点的特征向量,然后进行k均值聚类得到变化检测二值图像。相比基于MRF的方法,基于PCA的方法具有更优的计算速度和对低水平噪声干扰的鲁棒性。基于非抽取离散小波变换(UDWT)的变化检测方法^[5]是通过对差值图像或对数比值图像进行小波变换^[6],得到图像的多尺度多方向分解子图,从各子图中抽取并融合多尺度信息得到每个像素点的特征向量,然后进行k均值聚类得到变化检测二值图像。相比于基于PCA的方法,基于UDWT的方法利用了图像的多尺度信息,在一定程度上提高了变化检测效果。基于PCA的方法和基于UDWT的方法在低噪声水平下对噪声具有较好的鲁棒性,但随着噪声水平的提高,其变化检测性能会下降,并且,基于UDWT的方法对于具有丰富纹理信息的图像,其基函数的选择以及分解层数会影响检测性能。另外,不同的SAR图像或多光谱图像,采用差值图像还是对数比值图像,对基于PCA的方法和基于UDWT的方法的检测效果会有很大影响。

基于上述原因,本文利用新的差异图像模型,通过对超完备字典和变换系数自适应学习训练,获得差异图像局部结构信息的稀疏性特征表示,以随机矩阵作为压缩采样矩阵,得到特征子空间。最后利用聚类方式重构变化区域,提出遥感图像变化区域的自适应压缩感知方法。实验结果表明,本文方法具有很好的变化检测性能,并且对噪声具有很好的鲁棒性。

1 基于压缩感知的变化检测方法

稀疏信号表示、分析和感知是信号处理、优化方法、机器学习诸领域的研究热点之一^[7-11]。尤其是最近几年,以信号稀疏性为前提的压缩感知理论受到了广泛关注^[12]。

传统意义上的测量算子并非总是可以或者稳定

地实现信号的超分辨率稀疏表示。Candès^[13-14]和Donoho^[15]等学者研究表明,随机测量算子可以稳定地实现信号的超分辨率稀疏表示,由此开启了研究压缩感知这一新理论的大门。该理论指出,如果信号是可压缩的或在某个变换字典下是稀疏的,就可以用一个与变换字典不相关的观测矩阵将变换所得高维信号投影到一个低维空间上,并且可以从这些少量的投影中以高概率重构出原信号。

压缩感知理论主要研究信号的稀疏表示、压缩测量和重构,属于信号稀疏性分析的范畴。信号、图像的稀疏性分析方法,一直是计算机视觉、数学、数据压缩、模式识别等领域的研究目标。本节后续内容将依据压缩感知理论,自适应地构造超完备字典实现图像数据的稀疏表示,利用随机测量矩阵降低特征矢量的维数,得到以高概率保持图像结构信息的特征子空间,运用聚类算法重构出图像的轮廓变化和图像的区域变化,完成无监督变化检测过程。

受成像条件的影响,在进行变化检测时比较所有待检测点之间的匹配程度是不现实的,因此根据实际遥感图像的配准精度,我们假定由于配准误差引起的像素点的偏移将不超过一个给定的窗口大小。在此假定下,考虑不同时段获取的同一地表区域的遥感图像

$$I_1 = \{I_1(i, j) \mid 1 \leq i \leq M_1, 1 \leq j \leq N_1\}$$

$$I_2 = \{I_2(i, j) \mid 1 \leq i \leq M_1, 1 \leq j \leq N_1\}$$

我们的目标是获得一个检测算子 Λ ,使得差异图像 I_α 中每个像素位置 (i, j) 指定一个标号(0或1)。如此,把变化检测问题模型化为一个二分类问题,令 $\Omega = \{w_1, w_2\}$ 为类别集合,其中 w_1 指变化类, w_2 指未变化类。本文检测算法的实现步骤如下:1)计算图像 I_1 和 I_2 的差异图像 I_α ,对图像 I_α 的每个像素取 $h_\alpha \times h_\alpha$ 邻域;2)利用自适应稀疏表示算法给出所有邻域图像片的稀疏表示;3)对稀疏信号进行压缩采样,把观测量作为特征向量;4)进行FCM聚类,得到差异图像 I_α 的模糊划分矩阵,通过对图像 I_α 中各像素局部邻域内平均隶属度的比较,将该位置像素指定为所属的类别(w_1 或 w_2),从而得到检测算子 Λ ,重构出图像的轮廓变化和图像的区域变化信息,实现遥感图像的无监督变化检测。本文检测算法可用流程图表示(图1)。




图 1 本文方法用于变化检测的流程图
Fig. 1 Flowchart of the proposed approach

1.1 计算差异图像

一般意义下,遥感图像 I 含有加性噪声的模型表示为 $I = I + N$, 含有乘性噪声的模型表示为 $I = I + NI$ 。这里,将加性噪声和乘性噪声模型统一起来写为

$$I = I + N(I + E)$$

式中, E 是一个单位矩阵(矩阵中的元素全为 1)。于是,差异图像就可以表示为

$$I_\alpha = \frac{|I_2 - I_1|}{m_{I_2}} + N$$

式中, m_{I_2} 表示图像 I_2 的均值。

所以,对差异图像 I_α 的 $h_\alpha \times h_\alpha$ 图像中各像素表示为

$$I_\alpha(i, j) = \frac{|I_2(i, j) - I_1(i, j)|}{m_{I_2}} \quad (1)$$

式中, $(i, j) \in \{1 \leq i \leq h_\alpha, 1 \leq j \leq h_\alpha\}$ 。为了后面讨论方便,我们把差异图像 I_α 中 (i, j) 位置邻域的 $h_\alpha \times h_\alpha$ 图像片记作 $\square_{i, j}$ 。

1.2 自适应稀疏表示

建立在超完备基础上的稀疏表示具有较强的数据压缩能力,并且稀疏性可以提供稳健的建模假设。相对于非自适应构造字典方法,自适应方法具有更好的逼近性能,下面将讨论通过 K 奇异值分解(K-SVD)算法^[10,16]实现数据信号的自适应稀疏性表示。K-SVD 算法实质上是对回归模型中的拟合项进行多次奇异值分解,求得超完备字典的 K 个原子,通过正交匹配追踪法(OMP)实现数据信号的稀疏表示。

将式(1)所获得的差异图像 I_α 中 (i, j) 位置邻域的 $h_\alpha \times h_\alpha$ 图像片 $\square_{i, j}$ 的各列向量首尾相接排成 h_α^2 维列向量 v_{ij} , 然后将 $v_{ij}(1 \leq i \leq M_I, 1 \leq j \leq N_I)$

组合成矩阵形式:

$$\mathbf{X} = [v_{11}, v_{12}, \dots, v_{21}, v_{22}, \dots, v_{M_I N_I}]$$

设字典 Ψ , 信号集合 \mathbf{X} 在字典 Ψ 下的稀疏表示集合 α 。字典学习和稀疏表示问题可以描述为回归模型

$$\min_{\Psi, \alpha} \left\{ \sum_{l=1}^L \|\mathbf{X}^l - \Psi \alpha^l\|^2 \right\} \text{ 满足 } \forall j \|\alpha^j\|_{\ell^0} \leq S \quad (2)$$

这里, ℓ^0 表示 0 范数; α^l 表示 α 的第 l 列向量; S 是自然数,表示信号的稀疏度。

由文献[16-17]可知,式(2)的拟合项可以表示为

$$\begin{aligned} \min_{\Psi, \alpha} \left\{ \left\| \vec{\mathbf{X}} - (\alpha \square \Psi) \vec{\mathbf{E}} \right\|^2 \right\} &= \\ \min_{\Psi, \alpha} \left\{ \left\| \mathbf{X} - \sum_{j=1}^K \Psi^j \alpha^j \right\|_F^2 \right\} &= \\ \min_{\Psi, \alpha} \left\{ \left\| \left(\mathbf{X} - \sum_{j \neq k}^K \Psi^j \alpha^j \right) - \Psi^k \alpha^k \right\|_F^2 \right\} &= \\ \min_{\Psi, \alpha} \left\{ \left\| \mathbf{E}^{(k)} - \Psi^k \alpha^k \right\|_F^2 \right\} & \quad (3) \end{aligned}$$

式中, \square 表示 Khatri-Rao 矩阵积^[17]; $\vec{\mathbf{X}}$ 表示将矩阵 \mathbf{X} 各列向量首尾相接排成的列向量; $\vec{\mathbf{E}}$ 表示将单位矩阵 \mathbf{E} 主对角线元素排成的列向量。K-SVD 算法即是依据式(3),迭代更新误差项 $\mathbf{E}^{(k)}$ 获得数据集 \mathbf{X} 在优化意义下的超完备变换字典 Ψ 和相应变换系数 α ,从而实现 \mathbf{X} 的稀疏表示。

K-SVD 算法如下:

- 1) 选取冗余离散余弦变换矩阵作为初始字典 $\Psi^{(0)}$ 。
- 2) 设 $t = 1$, 重复步骤 3)—5), 以迭代次数 T 和逼近误差 ε 设定停止迭代条件; 停止迭代后转到步骤 7)。
- 3) 在 ℓ^2 范数意义下归一化字典 Ψ 的各原子。
- 4) 用正交匹配追踪(OMP)算法计算信号矩阵 \mathbf{X} 在字典 Ψ 下的稀疏表示系数矩阵 α , 即求解如下优化问题

$$\begin{aligned} \forall \mathbf{X}^l \in \mathbf{X}, l = 1, \dots, L \\ \min_{\alpha^l} \left\{ \|\mathbf{X}^l - \Psi \alpha^l\|^2 \right\} \end{aligned}$$

满足 $\|\alpha^l\|_{\ell^0} \leq S$, \mathbf{X}^l 表示 \mathbf{X} 的第 l 列向量, α^l 表示 α 的第 l 列向量。

- 5) 对每一个 $k; 1 \leq k \leq K$, 做循环迭代, 这里 K 是 \mathbf{X} 行向量的维数。

(1) 定义指标集

$$\Omega^{(k)} = \{l | 1 \leq l \leq L, \alpha_k^l \neq 0\}$$

式中, α_k^l 表示 α 的第 k 行向量 α_k 的第 l 元素。

(2) 计算

$$E^{(k)} = \alpha - (\Psi\alpha - \Psi^k\alpha_k)$$

α_k 表示 α 的第 k 行向量, Ψ^k 表示 Ψ 的第 k 列向量。

(3) 选取指标集 $\Omega^{(k)}$ 在 $E^{(k)}$ 中所对应的列, 记作 $E_{\Omega^{(k)}}^{(k)}$ 。

(4) 运用奇异值分解(SVD): $E_{\Omega^{(k)}}^{(k)} = U\Lambda V$, 更新 $\Psi^k = U^1$ 和 $\alpha_k = \Lambda(1,1) \cdot V^1$, U^1 表示 U 的第 1 列向量, V^1 表示 V 的第 1 列向量, $\Lambda(1,1)$ 表示 Λ 的第 1 行、第 1 列元素, 即最大特征值。

6) 令 $t = t + 1$ 。

7) 执行步骤 3) 和步骤 4), 输出结果 ψ 和 α 。

运用 K-SVD 算法就可以得到具有 S 稀疏度的信号集合 X 在超完备字典 Ψ 下的稀疏表示集合 α 。

1.3 随机压缩采样

信号 α^l (将 K-SVD 算法得到的稀疏表示集合 α 视为矩阵的第 l 列向量) 在字典 Ψ 下具有稀疏度 S , 测量算子 Φ 选为以高概率满足 RIP 性质的高斯随机矩阵, 则有

$$Y = \Phi\alpha \quad (4)$$

记 $Y = [\eta_{11}, \eta_{12}, \dots, \eta_{21}, \eta_{22}, \dots, \eta_{M_1N_1}]$, 则 Y 为差异图像 I_α 的特征子空间, 在 1.4 节中, 将对这个集合中的元素进行分类。

利用变换 (4) 对稀疏表示集合 α 进行压缩采样, 本文中测量算子 Φ 取为元素服从独立同分布的高斯分布 $N(0, \frac{1}{M})$ 的 $M \times N$ 阶矩阵, 这里

$$M \geq cS \ln(N/S) \quad (5)$$

事实上, 式 (5) 只是给出了估计 M 值的约束范围, 目前还没有文献从理论上解决有关随机矩阵测量数 M 的确切最小值问题^[18-19]。在 2.1 节的实验中以式 (5) 为依据, 给出 M 的经验估计值。

1.4 重构变化区域信息

通常情况下, 软阈值分类算法优于硬阈值分类算法。模糊 C 均值(FCM)聚类算法是一种典型的软阈值无监督动态聚类算法, 该算法面对大规模数据集是相对可扩展的, 并且具有较高的效率。取 $c = 2$, 即将特征子空间分为变化类 w_1 与未变化类 w_2 。利用特征向量 η_{ij} , 运用 FCM 聚类算法, 得到差异图像 I_α 中每个像素 $I_\alpha(i, j)$ 分别隶属于类 w_1 和类 w_2 的隶属度 $u_{i,j}$ 和 $1 - u_{i,j}$, 这里 $0 \leq u_{i,j} \leq 1$ 。记

m_1 为像素 $I_\alpha(i, j)$ 的 $h_\alpha \times h_\alpha$ 邻域中各像素隶属于变化类 w_1 的隶属度平均值, m_2 为像素 $I_\alpha(i, j)$ 的 $h_\alpha \times h_\alpha$ 邻域中各像素隶属于未变化类 w_2 的隶属度平均值。定义检测算子

$$\Lambda(i, j) = \begin{cases} 0 & m_1 \geq m_2 \\ 1 & m_1 < m_2 \end{cases} \quad (6)$$

则 Λ 可视为一个二值矩阵, 即为原图像 I_1 和变化图像 I_2 的变化检测二值图像。

2 实验结果及分析

2.1 实验结果

选取 3 组不同时段获取的同一地表区域的遥感图像, 如图 2(a)(b)、(d)(e)、(g)(h) 所示。图(a)(b)为美国西南部的内华达州的 Tahoe 湖地区分别于 1986 年 8 月和 1992 年 8 月获得的多光谱遥感图像^[20]; 图(d)(e)为中国台湾南部的石门水库地区, 分别于 1998 年 10 月和 1999 年 9 月获得的库区沉积物清理前后的 SAR 遥感图像; 图(g)(h)为俄罗斯西部的莫斯科地区, 分别于 2000 年 4 月和 2002 年 5 月获得的多光谱遥感图像。基于压缩感知的检测方法 1 中的各项参数选取: 窗宽 $h_\alpha = 5$, 信号的稀疏度 $S = 6$ 和随机采样矩阵 Φ 的行数 $M = 12$ 。

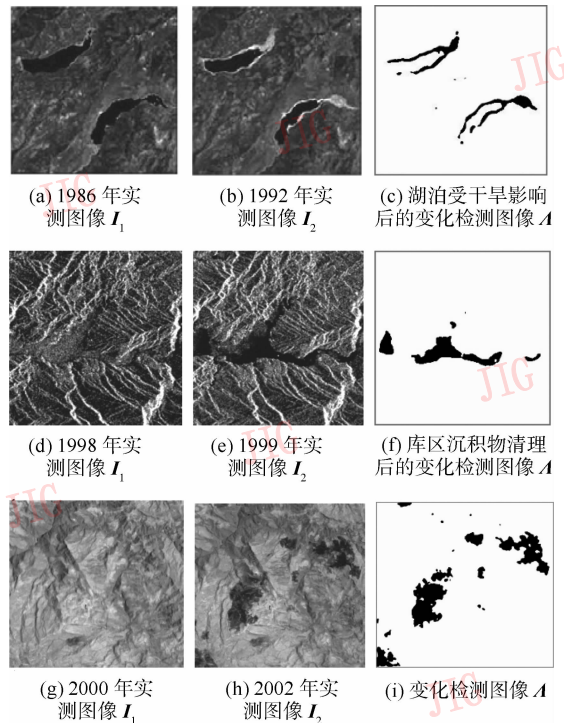


图 2 本文算法检测结果

Fig. 2 Change detection results for the proposed method

变化检测系统基于 MATLAB7.0 平台开发。本文算法(基于 CS)所得到的变化检测二值图像实验结果如图 2(c)(f)(i)所示。

2.2 检测性能鲁棒性分析

为了凸显本文算法的稳定性优势,我们选取图 2(a)(b)进行实验,讨论在不同噪声水平下,各变化检测算法对噪声的鲁棒性比较。由于图像的信噪比是难于计算的,这里我们用信号与噪声的方差之比来近似图像的信噪比^[21],首先分别计算未添加噪声时两幅图像所有列向量的方差,将两幅图像列向量方差的平均值认为是信号方差,求出信号方差和噪声方差的比值,再转化成成分贝数,最后进行修正。定义如下修正后的信噪比为

$$SNR = 10\lg\left(\frac{v_1 + v_2}{2v_n}\right) \quad (7)$$

式中, v_1 为未添加噪声时图 2(a)的列向量的样本方差所构成的行向量的平均值; v_2 为未添加噪声时图 2(b)的列向量的样本方差所构成的行向量的平均值; v_n 为图 2(b)所添加噪声的方差。

定义 \mathbf{A} 和 \mathbf{A}_{v_n} 之间差异的测度为

$$\mathfrak{M} = \frac{\sum_{i=1}^{M_1} \sum_{j=1}^{N_1} |\mathbf{A}(i,j) - \mathbf{A}_{v_n}(i,j)|}{\sum_{i=1}^{M_1} \sum_{j=1}^{N_1} |\mathbf{A}(i,j)|} \quad (8)$$

式中, \mathbf{A} 是图 2(b)未添加噪声时的变化检测二值图像; \mathbf{A}_{v_n} 是图 2(b)添加方差为 v_n 的噪声后的变化检测二值图像。式(8)反映了变化检测算法对噪声的鲁棒性。算法对噪声的鲁棒性越好, \mathfrak{M} 的值越接近于“0”。

本文方法(CS 方法)与基于 PCA 方法^[4]和基于 UDWT 方法^[5]对乘性噪声的鲁棒性比较见图 3(a)。这里以图 2(a)(b)为例,对两幅图像中的图 2(b)添加均值为 0,方差为 v_n 的高斯乘性噪声,相应的模型为 $I_2 = I_2 + N \cdot I_2$,本文方法利用式(1)得到差异图像,基于 PCA 方法和基于 UDWT 方法,利用对数比值法得到差异图像。方差 v_n 的取值范围

$$v_n = \{0.1, 0.2, \dots, 0.9, 1.0\}$$

分别利用式(7)(8)求得相应的信噪比(SNR)和差异测度(\mathfrak{M})。以 SNR 为自变量,以 \mathfrak{M} 为因变量得到 SNR- \mathfrak{M} 曲线(图 3(a))。

本文方法与基于 PCA 方法和基于 UDWT 方法对加性噪声的鲁棒性比较见图 3(b)。这里我们用

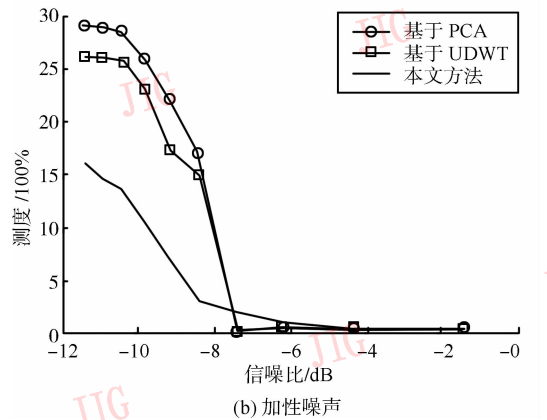



图 3 3 种检测方法的 SNR- \mathfrak{M} 曲线
Fig. 3 The three methods' SNR- \mathfrak{M} graphics

图 2(a)(b)为例,对两幅图像中的图 2(b)添加均值为 0,方差为 v_n 的高斯加性噪声,相应的模型为 $I_2 = I_2 + N$,本文方法利用式(1)得到差异图像,基于 PCA 方法和基于 UDWT 方法利用差值法得到差异图像。方差 v_n 的取值范围

$$v_n = \{0.02, 0.04, 0.06, \dots, 0.18, 0.20\}$$

分别利用式(7)和式(8)求得相应的 SNR 和差异测度(\mathfrak{M})。以 SNR 为自变量,以 \mathfrak{M} 为因变量得到 SNR- \mathfrak{M} 曲线(图 3(b))。如图 3 所示,相比于基于 PCA 方法^[4]和基于 UDWT 方法^[5],本文所提出的算法对噪声具有较好的鲁棒性。基于 PCA 方法的思想是将每一个图像片的数据协方差矩阵进行特征分解,从而得到与信号相对应的信号分量和与信号分量不相关的噪声分量,该方法本身对较高水平的噪声特别是乘性噪声抑制能力较弱,因此,基于 PCA 方法只能对低水平的加性噪声有较好的抑制作用。小波变换可以对图像进行多尺度多方向分解,基于 UDWT 方法利用了图像的多尺度特性,所以可以非常好的刻画信号的非平稳性,可以在不同尺度下根

据信号和噪声的分布来降噪,但基函数的选取以及小波尺度分解的层数增强了其对噪声的敏感性。本文方法首先将图像的不同噪声模型统一为加性噪声模型,从一定程度上实现了信号与噪声统计意义上的分离;然后利用自适应稀疏表示算法自适应字典学习算法分离出信号的特征子空间,进一步抑制噪声。所以,本文方法比基于 PCA 方法和基于 UDWT 方法对噪声具有更好的鲁棒性。

2.3 检测性能定量分析

为了定量分析本文算法的检测性能,我们选取图 2(a)(b) 进行实验。真实地表变化以及各种检测算法检测出的变化结果分别显示在图 4(a)~(d) 中。参考地表真实变化图包含 37 953 个无变化像素点,以及 2 047 个变化像素点。在无噪声条件下,图 4 和表 1 给出了各方法的数值结果。从图 4 和表 1 中可以看出,本文方法总体上优于基于 PCA 方法^[4]和基于 UDWT 方法^[5]。

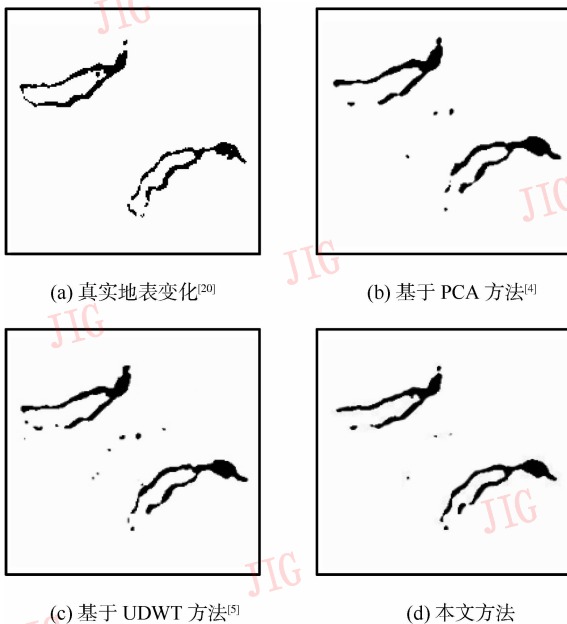


图 4 各种方法的检测结果比较

Fig. 4 The results with different detection algorithms for image

表 1 3 种方法的检测结果

Tab. 1 Change detection results for three approaches

算法	虚警点数	漏检点数	错误总数
基于 PCA ^[4]	43	76	119
基于 UDWT ^[5]	56	39	95
本文方法	31	37	68

3 结 论

自适应变换字典具有良好的去相关性和能量压缩特性,变换后的系数实现了图像的稀疏表示。随机高斯矩阵具有以高概率保持原信号信息的特性。本文以自适应稀疏表示算法实现图像的稀疏表示,以随机高斯矩阵作为观测矩阵,提出一种基于压缩感知的无监督变化检测方法。该方法首先对两幅图像求差异图像;运用自适应稀疏表示算法,得到差异图像中每个像素邻域的稀疏表示;采用服从高斯分布的随机矩阵进行压缩采样,得到压缩域的特征向量;最后,利用 FCM 聚类算法得到差异图像中每个像素的隶属度,依据差异图像中每个像素邻域的平均隶属度来确定该像素的类别,从而实现了图像轮廓和区域变化信息的重构。

实验结果和性能分析表明,本文方法具有很好的检测效果。利用定义的信噪比泛函 SNR 和差异测度(\mathfrak{M})得到 SNR- \mathfrak{M} 曲线,分析表明本文方法对于加性噪声和乘性噪声均具有很好的鲁棒性。但是由于自适应稀疏表示算法执行耗时较长,算法效率稍差。因此,下一步工作是研究自适应稀疏表示相关内容,提高算法效率。

参考文献 (References)

- [1] Rogerson P A. Change detection thresholds for remotely sensed images [J]. *Journal of Geographical Systems*, 2002, 4(1): 85-97.
- [2] Bazy Y, Bruzzone L, Melgani F. Automatic identification of the number and values of decision thresholds in the log-ratio image for change detection in SAR images [J]. *IEEE Geoscience and Remote Sensing Letters*, 2006, 3(3): 349-353.
- [3] Bruzzone L, Príteo D. Automatic analysis of the difference image for unsupervised change detection [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2000, 38(3): 1171-1182.
- [4] Celik T. Unsupervised change detection in satellite images using principal component analysis and k-mean clustering [J]. *IEEE Geoscience and Remote Sensing Letters*, 2009, 6(4): 772-776.
- [5] Celik T. Multiscale change detection in multitemporal satellite images [J]. *IEEE Geoscience and Remote Sensing Letters*, 2009, 6(4): 820-824.
- [6] Pesquet J C, Krim H, Carfantan H. Time-invariant orthonormal wavelet representations [J]. *IEEE Transactions on Signal Processing*, 1996, 44(8): 1964-1970.

- [7] Engan K, Skretting K, Husøy J H. Family of iterative LS-based dictionary learning algorithms, ILS-DLA, for sparse signal representation [J]. Digital Signal Processing, 2007, 17 (1) : 32-49.
- [8] Varshney K R, Cetin M, Fisher J W, et al. Sparse representation in structured dictionaries with application to synthetic aperture radar [J]. IEEE Transactions on Signal Processing, 2008, 56 (8) : 3548-3561.
- [9] Wright J, Yang A Y, Ganesh A, et al. Robust face recognition via sparse representation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2009, 31 (2) : 210-227.
- [10] Duarte-Carvajalino J M, Sapiro G. Learning to sense sparse signals: simultaneous sensing matrix and sparsifying dictionary optimization [J]. IEEE Transactions on Image Processing, 2009, 18 (7) : 1395-1408.
- [11] Skretting K, Engan K. Recursive least squares dictionary learning algorithm [J]. IEEE Transactions on Signal Processing, 2010, 58 (4) : 2121-2130.
- [12] Compressive Sensing Resources [DB/OL]. (2010-8-20) [2010-9-02]. <http://dsp.rice.edu/cs/>.
- [13] Candès E, Romberg J, Tao T. Robust uncertainty principles: exact signal reconstruction from highly incomplete frequency information [J]. IEEE Transactions on Information Theory, 2006, 52 (2) : 589-509.
- [14] Candès E, Tao T. Near optimal signal recovery from random projections: universal encoding strategies [J]. IEEE Transactions on Information Theory, 2006, 52 (12) : 5406-5425.
- [15] Donoho D. Compressed sensing [J]. IEEE Transactions on Information Theory, 2006, 52 (4) : 1289-1306.
- [16] 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.
- [17] Xu Luzhou, Stoica P, Jian Li. A diagonal growth curve model and some signal processing applications [J]. IEEE Transactions on Signal Processing, 2006, 54 (9) : 3363-3371.
- [18] Candès E, Wakin M B. An introduction to compressive sampling [J]. IEEE Signal Processing Magazine, 2008, 25 (2) : 21-23.
- [19] Tsaig Y, Donoho D L. Extensions of compressed sensing [J]. Signal Processing, 2006, 86 (3) : 549-571.
- [20] Southwest U. S. change detection images from the EROS Data Center [DB/OL]. (2003-11-25) [2010-3-20]. <http://geochange.er.usgs.gov/sw/changes/natural/reno-tahoe/>.
- [21] Sijbers J, Scheunders P, Bonnet N, et al. Quantification and improvement of the signal-to-noise ratio in a magnetic resonance image acquisition procedure [J]. Magnetic Resonance Imaging, 1996, 14 (10) : 1157-1163.