

# 利用稀疏分解的高分辨率遥感图像线状特征检测

黄秋燕<sup>1,2,3</sup> 冯学智<sup>1</sup> 肖鹏峰<sup>1</sup>

1 南京大学地理信息科学系,江苏 南京,210023

2 广西师范学院北部湾环境演变与资源利用省部共建重点实验室,广西 南宁,530001

3 广西师范学院资源与环境科学学院,广西 南宁,530001

**摘要:**线状特征检测是利用遥感数据开展地物目标自动识别的重要步骤。利用高分辨率遥感图像的高度细节化特点,针对现有线状特征检测方法存在的问题,提出了一种基于稀疏分解的高分辨率遥感图像线状特征检测方法。采用 K-SVD 字典学习算法获取线状特征表达所需的过完备字典,基于稀疏分解模型,从高分辨率遥感图像中分离出高频成分,实现遥感图像线状特征的初步检测;用曲波分层自适应阈值法对分离后的高频成分作降噪处理,以提高线状特征检测的效果。利用 QuickBird 图像进行实验的结果显示,该方法在线段连续性、低对比度线段检测与椒盐噪声消除方面均有一定优势。

**关键词:**稀疏分解;过完备字典;线状特征检测;高分辨率遥感图像;自适应阈值  
中图分类号:P237 文献标志码:A

线状特征是地物目标的最基本形态之一,有效利用高分辨率遥感图像检测线状特征是地物目标自动识别的重要步骤,在遥感技术研究中备受关注<sup>[1-3]</sup>。线状特征在高分辨率遥感图像中表现为图像局部高细节的几何结构或急剧变化的边缘轮廓,在频域中属高频成分。然而,线状特征独特的色调、轮廓、边缘等成分往往纠缠在一起,导致高分辨率遥感图像的线状特征检测变得复杂。其次,高分辨率遥感图像具有高度细节化的信息表达能力,在有效表达地物轮廓信息的同时,使得同类地物光谱差异增大,地物内部几何细节常以噪声形式出现。因此,在进行线状特征检测时,应当在降噪消除同质区域内部光谱差异的同时保护地物边缘及细节信息。

目前,已有大量有关遥感图像线状特征检测的研究成果。其中,基于边缘的线状特征检测方法大都是先利用灰度梯度算子区分边缘点与背景,再将以像素为单位的边缘点连接成直线并描述其线结构,如 Sobel 算子、Laplace 算子、Canny 算子等。这类以微分为基础的线状特征检测方法直接应用于高分辨率遥感图像时,往往存在断裂、模糊及椒盐噪声等问题,难以得到较理想的线状特征检测结果;灰度梯度算子是像元基本的处理单元,很难充分利用地物目标对线状特征的丰富

承载内涵,对地物轮廓、边缘、方向信息的表达能力有限,不能有效地检测线状特征。

针对线状特征在高分辨率遥感图像上的表征及现有线状特征检测方法存在的问题,本文提出了一种基于稀疏分解<sup>[4]</sup>的利用 K-SVD 字典学习算法<sup>[5]</sup>等方法的高分辨率遥感图像线状特征检测方法。

## 1 图像稀疏分解

### 1.1 图像稀疏建模

稀疏分解的核心思想是将图像或信号在过完备的冗余字典上展开,也就是从字典中找到具有最佳线性组合的数项原子来表示信号。图像或信号的过完备展开意味着字典原子的数目大于信号的维数,这导致基的正交性不再被保证,因而基也不再是普通意义上的正交基,改称过完备字典,过完备字典中元素称为原子。引入冗余表达获得图像或信号的稀疏表示<sup>[6]</sup>,有助于特征提取、模式识别等问题的有效解决<sup>[4]</sup>。

若矩阵  $D \in R^{N \times M} (M \gg N)$  为过完备字典,  $f \in R^N$  为图像向量形式,则  $f$  在过完备字典  $D$  中最稀疏表示的目标函数为:

收稿日期:2013-06-14

项目来源:国家自然科学基金资助项目(40801166);国家 863 计划资助项目(2008AA12Z106)。

第一作者:黄秋燕,副教授,博士生,主要从事遥感数字图像处理研究。E-mail: hqiuyan@163.com

$$l_0: \min_{\alpha} \|x\|_0 \quad \text{s. t.} \quad f = Dx \quad (1)$$

式中,  $\|x\|_0$  表示伪范数, 用于衡量  $x$  的稀疏性, 等于  $x$  中非 0 元素的数目。由于最小化  $l_0$  范数是一个难以实现的非凸问题, 式(1)解一般用齐次优解逼近, 如匹配追踪<sup>[6]</sup>、基追踪算法<sup>[7]</sup>等。

假设式(1)中图像  $f$  由高频成分  $f_{\text{high}}$  与低频成分  $f_{\text{low}}$  两种不同形态分量线性组成, 对过完备字典进行再约束<sup>[8]</sup>, 即若对于原图像中的每一种形态分量, 都存在着相对应的能够稀疏表示该形态分量的字典, 并且认为该字典仅能稀疏表示该形态分量, 不能稀疏表示其他形态分量。在这一前提下, 合适图像的分量会在相应的分量基元上存在独有的稀疏表示<sup>[4,8]</sup>:

$$\begin{aligned} \{\alpha_{\text{low}}^{\text{opt}}, \alpha_{\text{high}}^{\text{opt}}\} &= \underset{\alpha_{\text{low}}, \alpha_{\text{high}}}{\text{Arg min}} \|\alpha_{\text{low}}\|_0 + \|\alpha_{\text{high}}\|_0 \\ \text{s. t.} \quad f &= f_{\text{low}} + f_{\text{high}} = T_{\text{low}}\alpha_{\text{low}} + T_{\text{high}}\alpha_{\text{high}} \end{aligned} \quad (2)$$

式中,  $T_{\text{low}}, T_{\text{high}}$  分别指能稀疏表示图像高频成分和低频成分的过完备字典;  $\alpha_{\text{low}}, \alpha_{\text{high}}$  分别指高频成分与低频成分在字典  $T_{\text{low}}, T_{\text{high}}$  中的稀疏逼近系数;  $T_{\text{low}}\alpha_{\text{low}} \approx f_{\text{low}}, T_{\text{high}}\alpha_{\text{high}} \approx f_{\text{high}}$  分别为高频成分与低频成分的稀疏逼近, 原图像的高低频成分最稀疏系数  $\{\alpha_{\text{low}}^{\text{opt}}, \alpha_{\text{high}}^{\text{opt}}\}$  可通过两种冗余字典进行稀疏分解获得。

将式(2)中的高频成分描述为反映高分辨率遥感图像线状特征为主的形态分量, 低频成分描述为反映高分辨率遥感图像的其他形态分量。若能选择匹配高分辨率遥感图像各形态分量的字典构成联合字典, 则可利用稀疏分解模型获得高分辨率遥感图像高频成分基元的稀疏表达, 实现高分辨率遥感图像中高频成分的重建, 从而将包含线状特征的高频成分从原图像中分离, 实现线状特征的初步检测。

## 1.2 字典设计与算法实现

字典设计是稀疏分解的关键环节。由于高分辨率遥感图像是一种复杂的二维信号, 包含多种边缘、纹理结构, 单凭使用者自身经验设计字典难以获得有效匹配高分辨率遥感图像各种结构特征的冗余字典, 不利于图像稀疏表示。基于学习策略的字典设计可获得自适应能力更强的字典, 有助于图像稀疏表示, 因此字典学习很有必要。K-SVD(K-singular value decomposition)是一种有效的字典学习算法, 采用该算法对字典进行参数优化。

参数优化的基本步骤为: ① 初始化: 将一幅高分辨率遥感图像分为  $n \times n$  大小的图像块, 组成

样本集; 对字典作参数初始化并列归一化。② 稀疏编码: 给定一个初字典  $D \in R^{n \times k}$ , 采用追踪算法计算图像的稀疏系数。参考文献<sup>[7]</sup>采用局部余弦变换获得高频成分初始字典, 采用曲波变换获得低频成分的初始字典。③ 字典更新直至收敛, 获得新的字典作为后续稀疏分解的过完备字典。

稀疏分解的数值实现采用块坐标松弛算法<sup>[9]</sup>进行, 具体步骤为:

1) 参数初始化, 给定最大迭代次数  $L_{\text{max}}$  及阈值  $\delta_k = \lambda_k \times L_{\text{max}}$ , 进行字典学习。

2) 根据预定的迭代次数进行迭代。当  $\delta_k > \lambda_k \times L_{\text{max}}$  时, 对于每个  $k=1, \dots, k$ , 有以下几种情况: ① 假设  $f_{\text{high}}$  固定, 更新  $f_{\text{low}}$ 。先计算残余量  $\rho = f - f_{\text{high}}$ ; 再计算低频成分稀疏逼近系数  $\alpha_{\text{low}}$ ; 然后采用软阈值法计算  $\alpha_{\text{low}}$ , 阈值为  $\delta$ , 得到  $\alpha_{\text{low}}^{\text{opt}}$ ; 接着重建  $f_{\text{low}} = T_{\text{low}}\alpha_{\text{low}}^{\text{opt}}$ 。② 假设  $f_{\text{low}}$  固定, 更新  $f_{\text{high}}$ 。先计算残余量  $\rho = f - f_{\text{low}}$ ; 再计算高频成分稀疏逼近系数  $\alpha_{\text{high}}$ ; 然后采用软阈值法计算  $\alpha_{\text{high}}$ , 阈值为  $\delta$ , 得到  $\alpha_{\text{high}}^{\text{opt}}$ ; 接着重建  $f_{\text{high}} = T_{\text{high}}\alpha_{\text{high}}^{\text{opt}}$ 。③  $f_{\text{low}} = f_{\text{low}} - \mu\gamma(\partial TV\{f_{\text{low}}\}/\partial f_{\text{low}})$ , 即用总变差 TV 对低频成分进行纠正, 参数  $\mu$  通过固定适当迭代步长保证收敛,  $\gamma$  为调节参数。

3) 更新阈值:  $\delta = \delta - \lambda$ 。

4) 当  $\delta > \lambda$ , 转到步骤 2); 否则停止迭代, 并输出分解结果。

## 2 线状特征检测方法

稀疏分解重构的高频成分仍残留高频成分的噪声。为了提高线状特征检测的效果, 有必要进一步降噪处理。曲波变换具有良好的方向特性与多尺度特性, 且能用楔形基逼近含奇异曲线的二维分片光滑函数, 对物体边缘具有最稀疏逼近能力<sup>[10]</sup>, 是目前最适合描述图像曲线奇异性的一种多分辨率方法。故此, 本文给出了一种针对高分辨率遥感图像线状特征检测的曲波分层自适应阈值去噪方法。

该方法的基本思想为: 对图像进行曲波变换, 获取曲波系数。较大的曲波系数一般以实际信号为主, 而较小的曲波系数很大程度上是噪声; 通过阈值把曲波系数依据大小划分为“信号系数”与“噪声系数”两大类, 再对噪声系数置零、衰减、逆变换重建去除噪声。设  $g_{j,l}^C = Cg$  表示带加性噪声图像  $g$  在  $j$  尺度、 $l$  方向的曲波变换系数,  $C$  为 Curvelet 变换算子。由于曲波变换中, 每个尺度子带的噪声仍然保持加性与随机平稳<sup>[10]</sup>, 阈值设

置一般用式(3)估计:

$$g_{j,l}^{CT} = \begin{cases} g_{j,l}^{CT} & |g_{j,l}^{CT}| \geq k\sigma_{j,l} \\ 0 & |g_{j,l}^{CT}| < k\sigma_{j,l} \end{cases} \quad (3)$$

式中,  $g_{j,l}^{CT}$  为硬阈值法后估计的系数;  $\sigma_{j,l}^2$  为曲波变换后的噪声方差;  $k$  指与尺度  $j$  相关的参数, 由实验确定。

由于曲波变换后的噪声系数在高频层较大, 在低频层较小, 并在高频层中不同尺度和方向上的系数特点也不同。曲波硬阈值去噪很容易过度消除曲波系数。本文引入分层自适应阈值的思想来解决这一问题, 即在高频层次中不同尺度和方向用不同的阈值去噪处理。设  $N_{j,l}$  为曲波分解层次,  $\text{Median}(|g_{j,l}^{CT}|)$  指曲波系数幅度中值, 则高频层次不同尺度和方向的阈值  $T_{j,l}$  用式(4)<sup>[10]</sup> 自适应地估算:

$$T_{j,l} = \sqrt{2 \log N_{j,l}} \frac{\text{Median}(|C(j,l)|)}{0.6745} \quad (4)$$

本文提出的线状特征检测方法为: ① 用 K-SVD 算法训练字典, 以块坐标松弛算法对式(2)作数值计算, 从高分辨率遥感图像中分离出高频成分。② 对分离后高频成分作曲波变换, 曲波变换后分别保留单层系数, 在其余各层系数分别置 0 的情况下进行重构, 考察高频成分各层次的系数特征, 试验确定尺度参数  $j$  与  $k$  值。③ 对分解尺度小于或等于  $j$  的层次, 用式(3)处理。④ 对分解尺度高于  $j$  的高频层次, 采用不同的阈值处理。高频层次不同尺度和方向的阈值采用式(4)自适应地估算。⑤ 对处理后的曲波系数作逆变换, 获得去噪后的高频图像, 以其作为线状特征精确检测的基础。

### 3 仿真实验结果分析

#### 3.1 实验数据

仿真实验数据采用两幅大小为 256 像素  $\times$  256 像素、空间分辨率为 0.61 m 的 QuickBird 全色波段图像, 如图 1(a) 所示。两幅图像主要地物为农田、行道树、草地等, 其中道路被行道树遮挡, 部分田埂因植被覆盖, 对比度低, 不易识别。线状特征在 QuickBird 全色波段影像上具有明显的方向性与局部位置特征。

#### 3.2 实验结果分析

图 2 为学习后的过完备字典, 实验中图像块大小为 11。若将字典中的原子描述为反映图像某种特征的图像基元, 则可以看出, 这些图像基元基本上可分为方向特征基元与点状特征基元两大类。

其中, 点状特征基元中较大亮度值的像素点往往聚集在特定范围内, 代表原图像中分布较短的点特征成分, 反映图像中的局部位置特征; 而方向基元的方向特征明显, 具有不同的纵横比, 即各向异性, 这有助于更稀疏地表示线状特征。其次, 点状基元及方向基元均具有不同频率, 同时基元中较高亮度值的像素点所组成的图形方向不同, 反映了图像基元的频率选择性与朝向选择性。图像基元的这些特性恰好与人类视觉系统对一种“最优”的图像表示方法应具有局部性、方向性、多分辨率的要求相吻合<sup>[11]</sup>, 说明了本文方法获取的过完备字典能较好地匹配高分辨率遥感图像线状特征, 与理论分析相吻合。同时, 相对以单个像元为处理基本单元的图像特征的表示方法, 图像基元由若干同类像素组成, 以其作为处理基本单元来描述图像特征更能充分表达地物目标对线状特征的丰富承载内涵, 有助线状特征的识别。

为验证稀疏分解重构的高频成分对高分辨率线状特征检测的有效性, 实验中取  $\lambda = 0.96$ ,  $\gamma = 0.8$ , 获取高频成分重构图, 如图 1(b) 所示。由于稀疏分解中自适应选择调节参数仍是一个尚未解决的难题, 稀疏分解参数均由实验确定。图 1(a)、1(b) 表明, 重构的高频成分中, 原图像中低频成分的噪声大部分已被消除, 同类地物内部光谱差异降低, 这有助于消除椒盐噪声, 降低对线段连续性的破坏作用, 初步验证了稀疏分解重构的高频成分有助于线状特征的检测。

图 1(c) 是 ( $j > 3, k = 2.5; j \leq 3, k = 1$ ) 重构高频成分降噪后的结果。图 1(c) 显示, 残留噪声已被进一步有效消除, 虚伪边缘也得到了抑制, 道路、田埂等地物线状特征十分清晰, 同时原图像中的低对比度线段(如图 1(c) 中低对比度田埂)已被清晰显示出来。图 1(b)、1(c) 表明, 分层自适应阈值思想的引入进一步降低了噪声残余影响; 同时, 曲波变换对物体边缘具有最稀疏逼近能力, 不仅增加了线状特征的表达能力, 也增强了低对比度线段的检测能力及遮挡道路的区分能力, 提高了线状特征检测效果。实验结果表明, 稀疏分解与曲波变换的双重作用既可有效地抑制高分辨率遥感图像中的噪声, 又能有效检测线状特征。

为进一步验证本文方法的有效性, 实验采用统一参数, 对比分析本文方法与曲波分层阈值去噪方法、Sobel 算子及 Canny 算子(图 3) 的线状特征检测效果。图 3(a) 为图 1(c) 的 Canny 算子边缘检测结果, 图 3(b) 为图 1(a) 用曲波分层阈值去噪后 Canny 算子边缘检测结果。4 组实验表明,




图1 试验图像分解结果及其降噪结果

Fig. 1 Decomposition Images and Its Denoising Result




图2 过完备字典

Fig. 2 Over-complete Dictionary

本文方法比曲波分层阈值去噪法在线段连续性、定位准确性及低对比度线段检测方面均有优势；本文方法在椒盐噪声消除、低对比度线段检测、线段连续性方面均优于 Sobel 算子与 Canny 算子，伪边缘抑制能力也优于 Canny 算子。本文方法还能局部检测到因遮挡而断裂的线段，如图 1(a) 中行道树遮挡的线段大部分被检测出来(图 3(a))。这很可能与本文采用的图像稀疏特征有关。研究表明，信号在部分缺失的情况下，稀疏分解可恢复原信号中缺失的信号<sup>[12]</sup>。




图3 线状特征检测结果比较

Fig. 3 Comparison of Linear Feature Detection Result

## 4 结 语

本文将稀疏分解引入高分辨率遥感图像线状特征检测中,用 K-SVD 学习算法获得匹配线状特征表达的过完备字典,将包含线状特征的高频成分从高分辨率遥感图像中分离出来,用曲波分层自适应阈值法对分离后的高频成分作降噪处理,得到线状特征检测结果。利用 QuickBird 图像的仿真实验证明了该方法的有效性。下一步的研究重点是如何自适应地确定稀疏分解中的参数。

## 参 考 文 献

- [1] Mei Tiancan, Li Deren, Qin Qianqing. Extraction of Linear Feature from Remote Sensing Image Based on Watershed Transform[J]. *Geomatics and Information Science of Wuhan University*, 2004, 29(4): 338-341(梅天灿,李德仁,秦前清.分水岭变换在遥感影像线状特征提取中的应用[J].武汉大学学报·信息科学版,2004,29(4):338-341)
- [2] Lin Zongjian, Liu Zhengrong. Methods and Prospects of Road and Linear Structure Extraction from Remote Sensing Image[J]. *Geomatics and Information Science of Wuhan University*, 2003,28(1): 90-93(林宗坚,刘政荣.从遥感影像提取道路信息的方法评述[J].武汉大学学报·信息科学版,2003,28(1):90-93)
- [3] Li Xiaofeng, Zhang Chi, Pan Xin, et al. Representation of Location-specific Space-time Accessibility Based on Time Geography Framework[J]. *Geomatics and Information Science of Wuhan University*, 2010, 35(9): 1 079-1 081(李晓峰,张弛,潘欣,等.贝特朗曲线性质在高分辨率遥感影像道路边缘信息提取中的应用[J].武汉大学学报·信息科学版,2010,35(9):1 079-1 081)
- [4] Starck J, Murtagh F, Fadili J M. Sparse Image and Signal Processing: Wavelets, Curvelets, Morphological Diversity[M]. Cambridge: Cambridge University Press, 2010
- [5] Aharon M, Elad M, Bruckstein A. K-SVD: an Algorithm for Designing Over-complete Dictionaries for Sparse Representation[J]. *IEEE Transactions on Signal Processing*, 2006, 54(11): 4 311-4 322
- [6] Mallat S G, Zhang Z. Matching Pursuits with Time-frequency Dictionaries [J]. *IEEE Transactions on Signal Processing*, 1993, 41(12): 3 397-3 415
- [7] Chen S S, Donoho D L, Saunders M A. Atomic De-

- composition by Basis Pursuit[J]. *SIAM Journal on Scientific Computing*, 1998, 20(1): 33-61
- [8] Starck J L, Elad M, Donoho D L. Image Decomposition via the Combination of Sparse Representations and a Variational Approach[J]. *IEEE Transactions on Image Processing*, 2005, 14(10): 1 570-1 582
- [9] Sardy S, Bruce A G, Tseng P. Block Coordinate Relaxation Methods for Nonparametric Wavelet Denoising[J]. *Journal of Computational and Graphical Statistics*, 2000, 9(2): 361-379
- [10] Starck J, Candès E J, Donoho D L. The Curvelet Transform for Image Denoising[J]. *IEEE Transactions on Image Processing*, 2002, 11(6): 670-684
- [11] Serre T, Wolf L, Bileschi S, et al. Robust Object Recognition with Cortex-like Mechanisms [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2007, 29(3): 411-426
- [12] 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

## An Approach for Linear Feature Detection from Remote Sensing Images with High Spatial Resolution Based on Sparse Decomposition

HUANG Qiuyan<sup>1, 2, 3</sup> FENG Xuezhi<sup>1</sup> XIAO Pengfeng<sup>1</sup>

1 Department of Geographical Information Sciences, Nanjing University, Nanjing 210023, China

2 Beibu Gulf Environmental Evolution and Resources Utilization Laboratory at the Provincial Ministry of Education Key Laboratory, Guangxi Normal University, Nanning 530001, China

3 School of Resource and Environment Science, Guangxi Normal University, Nanning 530001, China

**Abstract:** Linear feature detection from remote sensing data is an importance step in automatic target recognition. A high spatial resolution remote sensing image is highly detailed, which causes problems for some linear feature detection methods with edge fractures and fuzzy, salt and pepper noise. In this paper, a novel linear feature detection approach for high spatial resolution remote sensing images based on sparse decomposition is proposed. First, an over-complete dictionary for linear feature detection was designed with a K-SVD algorithm. Using the sparse decomposition model, high frequency components were extracted from high spatial resolution remote sensing images, realizing initial detection of linear features from high spatial resolution remote sensing images. Then, denoising with a Curvelet and hierarchical adaptive threshold was applied to the high frequency component, which improved the linear feature detection effect. Finally, a simulation based on QuickBird data was executed. Experimental results verified that the proposed method is superior to the Canny and Sobel methods for line continuity, low contrast line detection, and salt and pepper noise elimination.

**Key words:** sparse decomposition; over-complete dictionary; linear feature detection; high spatial resolution remote sensing image; adaptive threshold

**First author:** HUANG Qiuyan, associate professor, PhD candidate, specializes in remote sensing digital image processing and its applications. E-mail: hqiuyan@163.com

**Foundation support:** The National Natural Science Foundation of China, No. 40801166; the National High Technology Research and Development Program of China(863 Program), No. 2008AA12Z106.