

doi: 103969/j.issn.0490-6756.2017.03.014

# 噪声抑制的高光谱图像虚拟维数分析

何秉钧<sup>1</sup>, 蒋鸣飞<sup>2</sup>, 罗欣<sup>3</sup>, 王蓉<sup>3</sup>

(1. 四川农业大学, 雅安 625014; 2. 中国电子科技集团公司第十研究所, 成都 610036; 3. 电子科技大学, 成都 611731)

**摘要:** 在高光谱数据降维过程中, 通常用虚拟维数来表征数据的本征维数. 经典的虚拟维数分析算法主要运用假设检验准则设定特征值门限, 通过特征值判定来决定虚拟维数值. 但是, 在强噪声干扰下, 经典算法不能有效分析出虚拟维数值. 本文提出了一种噪声抑制的高光谱图像虚拟维数分析方法(NCVD), 该算法通过对数据矩阵进行QR分解, 减小了算法的运算量; 采用滑动噪声检测窗口对噪声成分进行滤除, 提高了估计维数的准确性; 结合最小二乘算法对判别门限进行修正, 使虚拟维数估计结果更具合理性; 采用模拟数据和真实数据进行实验, 实验结果证明, 本文所提算法的可行性和较现有算法的优越性.

**关键词:** 高光谱图像; 虚拟维数; QR分解; 滑动噪声检测

**中图分类号:** TP391 **文献标识码:** A **文章编号:** 0490-6756(2017)02-0303-06

## Virtual dimensionality analysis of hyperspectral imagery with noise being constrained

HE Bin-Jun<sup>1</sup>, JIANG Ming-Fei<sup>2</sup>, LUO Xin<sup>3</sup>, WANG Rong<sup>3</sup>

(1. Sichuan Agricultural University, Ya'an 625014, China;

2. The 10th Research Institute of Chinese Electronic Technology Group Corporation, Chengdu 610036, China;

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

**Abstract:** In dimensionality reduction process of hyperspectral data, intrinsic dimension is normally characterized by virtual dimension. Classic algorithm mainly uses hypothesis-testing criterion to set eigenvalue threshold and correspondingly obtains virtual dimension. But under strong noises, it may not estimate very well. A noise constrained virtual dimension (NCVD) analysis method of hyperspectral imagery is proposed in this paper. It decreases the computational complexity by the QR decomposing; improves the accuracy of the estimated dimension by adopting sliding noise detection window to filter the noise; synthesizes the least squares algorithm to modify threshold for reasonable results. The experimental results prove the feasibility and superiority of the proposed algorithm by using simulated and real data.

**Keywords:** Hyperspectral imagery; Virtual dimension; QR decomposing; Sliding noise detection

## 1 引言

随着高光谱遥感技术<sup>[1]</sup>不断发展与成熟, 如何

有效地处理获取的遥感数据已成为当今世界遥感领域研究的一个重要方向<sup>[2]</sup>. 高光谱数据维数高、数据量大、冗余繁多, 处理起来较为困难<sup>[3]</sup>, 对其进

收稿日期: 2016-08-01

基金项目: 国家 973 计划项目(2013CB733400); 中央高校基本科研业务费项目(ZYGX2013J120); 电子科技大学本科教育教学研究项目(2015XJYYB088)

作者简介: 何秉钧(1996-), 男, 研究方向为高光谱图像. E-mail: 576366081@qq.com

行降维(即用低维数据来反映图像的主要特征)能够减少数据量,去除数据冗余,为进一步处理数据奠定了基础<sup>[4,5]</sup>. 维数降低到何种程度才算既反映出了高维数据的本质特性,又最大化的除去了数据的冗余信息已成为广泛关注的问题. 近年来在高维数据处理中普遍采用的维数分析(Dimensionality Analysis)技术就是针对这一问题产生的.

高维度的特征集和大规模的样本集,隐写分析技术对分类器的要求越来越高<sup>[6]</sup>. 高光谱数据处理中的维数分析技术就是通过某种数学手段得到高光谱数据的本征维数<sup>[7,8]</sup>(Intrinsic Dimensionality, ID)(能够反映高维空间数据本质特征的最小维数). 基于虚拟维数<sup>[9]</sup>(Virtual Dimensionality, VD)的维数分析方法是一类典型的高光谱数据维数分析方法. 所谓虚拟维数就是指光谱特征不同的信号源的最小数目. 这些信号源反映了高维数据的分类特性,在维数分析中,往往认为虚拟维数值近似等于本征维数值. HFC<sup>[10]</sup>、NWHFC<sup>[9]</sup>和 NSP<sup>[9]</sup>算法是经典的虚拟维数估计算法,它们均利用假设检验准则和设定特征值判别门限估计数据的虚拟维数,但仍存在以下问题:(1)在强噪声作用下算法估计出的虚拟维数值不再稳定,受噪声干扰较大<sup>[9]</sup>;(2)当端元较多时,算法估计出的虚拟维数误差较大,不利于数据的降维处理;(3)根据所确定的虚拟维数对遥感图像进行分类处理,分类效果不理想,没有客观的反应出图像包含的基本地物信息<sup>[9]</sup>.

本文结合纽曼-皮尔逊准则和设定特征值门限的方法提出了一种噪声抑制的虚拟维数分析算法,简称 NCVD 算法. 该算法利用矩阵的 QR 分解减小了处理高维数据的运算量;为了降低噪声对虚拟维数估计的干扰,采用滑动噪声检测窗口滤除  $Q$ 、 $R$  矩阵的协方差矩阵与相关系数矩阵特征邻差中的噪声成分;通过设定的虚拟邻差选择器,保证了维数估计的准确性.

## 2 高光谱图像的分解和噪声滤除

经典的虚拟维数分析方法没有对高光谱数据进行预处理,未能解决高维数据处理中运算量过大的问题,而所提算法通过 QR 分解将原始高光谱数据分解为正交矩阵  $Q$  和上三角矩阵  $R$ ,利用正交矩阵  $Q$  无关的特点和上三角矩阵  $R$  数据集中的特点分析虚拟维数值,减小了维数分析的运算量. 将  $L \times N_R \times N_C$  ( $L$  为数据波段数;  $N_R \times N_C$  为数据的空

间尺寸) 维的高光谱原始数据  $M$  通过 *Schmidt* 正交化得到正交矩阵  $Q$ ,再利用数据矩阵  $M$  和正交矩阵  $Q$  求得上三角矩阵  $R$ . 于是,数据矩阵  $M$  被分解为

$$M = (r_{11}q_1, r_{12}q_1 + r_{22}q_2, \dots, \sum_{j=1}^L r_{jN_R \times N_C} q_j) = (q_1, q_2, \dots, q_L) \begin{bmatrix} r_{11} & r_{12} & \dots & r_{1N_R \times N_C} \\ 0 & r_{22} & \dots & r_{2N_R \times N_C} \\ \dots & \dots & \dots & \dots \\ 0 & 0 & \dots & r_{LN_R \times N_C} \end{bmatrix} = Q \cdot R \quad (1)$$

计算上三角矩阵  $R$  的  $L \times L$  维相关系数矩阵  $R_r$  和协方差矩阵  $R_c$ ,并分别求得  $R_r$  与  $R_c$  的特征值  $r_r(r_{r1}, r_{r2}, \dots, r_{rL})$  和  $r_c(r_{c1}, r_{c2}, \dots, r_{cL})$ ,利用  $r_r$  与  $r_c$  求得  $R_r$  与  $R_c$  的特征值差值向量  $r(r_1, r_2, \dots, r_{L-1}, r_L)$ :

$$r_i = r_{ri} - r_{ci}, \quad i = 1, 2, \dots, L-1, L \quad (2)$$

比较  $r$  中相邻分量之间的关系,得到特征邻差向量  $r_d(r_{d1}, r_{d2}, \dots, r_{dL-2}, r_{dL-1})$ .

$$r_{di} = |r_{i+1} - r_i|, \quad i = 1, 2, \dots, L-1 \quad (3)$$

通过计算特征值差值向量和特征邻差向量,可去除两组特征值内部及相互间存在的信息冗余,有利于后续的虚拟维数判别. 同理,可得到单位正交矩阵  $Q$  的相关系数矩阵  $Q_r$  和协方差矩阵  $Q_c$  的特征值差值向量  $q(q_1, q_2, \dots, q_{L-1}, q_L)$  和特征邻差向量  $q_d(q_{d1}, q_{d2}, \dots, q_{dL-2}, q_{dL-1})$ .

由于数据获取时来自环境、传感器等方面的干扰,高光谱数据中不免存在一定的噪声,需要进行滤除,否则将影响维数估计的准确性<sup>[11]</sup>. 所提算法针对特征邻差中噪声干扰引起的异常点,设定滑动噪声检测窗口  $Z$ .

$$Z = A \prod \left( \frac{t-n}{T} \right) = \begin{cases} A, & n - \frac{T}{2} \leq t \leq n + \frac{T}{2}, n = 1, 2, 3, \dots \\ 0, & \text{else} \end{cases} \quad (4)$$

其中,  $A$  为幅度伸缩系数;  $T$  为窗口宽度系数. 我们设  $d(n, d_n)$  为待检测点,假定  $d(n, d_n)$  的可变邻域为  $\delta_m$ ,  $m$  为邻域内点的个数,根据  $m$  自动调节滑动窗口的宽度  $T$ ,利用领域  $\delta_m$  内各点的值调整幅度伸缩系数  $A$ ,通过窗口的滑动,确定领域  $\delta_m$  内各点的分布特点及变化规律,并结合下式检测出异常点.

$$|d_n - A| > \epsilon, d(n, d_n) \in N_d \quad (5)$$

其中,  $\epsilon$  为阈值;  $N_d$  为噪声点集合. 最后, 计算邻域  $\delta_m$  内各点的均值, 用均值替代异常点.

利用滑动噪声检测窗口  $Z$  分别检测并滤除  $r_d, q_d$  中的噪声成分, 可得到经过噪声抑制后的特征邻差向量  $\lambda(\lambda_1, \lambda_2, \dots, \lambda_{L-1})$  和  $\omega(\omega_1, \omega_2, \dots, \omega_{L-1})$ .

### 3 虚拟维数分析

#### 3.1 正交矩阵 $Q$ 的特征邻差判别门限设定

将单位正交矩阵  $Q$  的特征值差值向量  $q$  拆分成  $\eta(\eta_1, \eta_2, \dots, \eta_{L-1}) = (q_1, q_2, \dots, q_{L-1})$  及  $\xi(\xi_1, \xi_2, \dots, \xi_{L-1}) = (q_2, q_3, \dots, q_L)$ . 假定信号源是未知正常数, 噪声是高斯白噪声, 则虚拟维数估计转化为一个二元假设问题<sup>[12]</sup>. 假设.

$$H_0: \varphi_l = \eta_l - \xi_l = 0; H_1: \varphi_l = \eta_l - \xi_l > 0, \\ l = 1, 2, \dots, L-1 \quad (6)$$

当  $H_0$  为真时, 特征邻差表现噪声特征, 当  $H_1$  为真时, 特征邻差表现为信号特征. 在假设  $H_0$  和  $H_1$  前提下,  $\varphi$  近似服从正态分布, 其条件概率密度函数分别为

$$p_0(\varphi_l) = p(\varphi_l | H_0) \cong N(0, \sigma_{\varphi_l}^2), \\ l = 1, 2, \dots, L-1 \quad (7)$$

$$p_1(\varphi_l) = p(\varphi_l | H_1) \cong N(u_l, \sigma_{\varphi_l}^2), \\ l = 1, 2, \dots, L-1 \quad (8)$$

均值  $u_l$  是未知常数, 方差  $\sigma_{\varphi_l}^2$  为

$$\sigma_{\varphi_l}^2 = \text{Var}(\eta_l - \xi_l) = \\ \text{Var}(\eta_l) + \text{Var}(\xi_l) - 2\text{Cov}(\eta_l, \xi_l), \\ l = 1, 2, \dots, L-1 \quad (9)$$

通过式(7)~(9)可设定虚警概率:

$$P_F = \int_k^{+\infty} p_0(\varphi) dz \quad (10)$$

给定虚警概率  $P_F$  结合上式便可确定单位正交矩阵  $Q$  的邻差向量  $q_d$  的判别门限  $k$ , 也可看作是去噪后特征邻差向量  $\omega$  的判别门限.

#### 3.2 上三角矩阵 $R$ 的特征邻差判别门限设定

HFC 和 NWHFC 算法是直接比较高光谱数据相关系数矩阵和协方差矩阵的特征值, 结合纽曼-皮尔逊准则直接设定判别门限. 但这些算法均未利用分解矩阵的特点设定门限, 导致估计维数的准确性也不高<sup>[13]</sup>. 本文所提算法将单位正交矩阵  $Q$  的相关系数矩阵  $Q_r$  和协方差矩阵  $Q_c$  的特征邻差判别门限经过线性变换, 得到上三角矩阵  $R$  的相关系数矩阵  $R_r$  和协方差矩阵  $R_c$ . 特征邻差的判别门限, 在减小运算量的同时提高了维数分析的准

确性.

由于 QR 分解本质上是一种线性变换,  $R$  和  $Q$  之间存在线性关系, 因此  $R$  矩阵特征邻差向量  $\lambda$  的判别门限  $\tau$  可以由  $Q$  矩阵特征邻差向量  $\omega$  的判别门限  $k$  经过线性变换得到, 假设

$$\tau = ak + b \quad (11)$$

对非零  $\omega_i$  及其对应的  $\lambda_i$ , 根据最小二乘算法, 最小化以下代价函数.

$$S = \sum_{i=1}^{L-1} (\lambda_i - a - b\omega_i)^2, \omega_i \neq 0 \quad (12)$$

可得到  $a, b$  的估计值  $\hat{a}, \hat{b}$ , 如下式.

$$\hat{b} = \frac{\sum \omega_i \lambda_i - \frac{1}{(L-1)} \sum_{i=1}^{L-1} \omega_i \sum_{i=1}^{L-1} \lambda_i}{\sum_{i=1}^{L-1} \omega_i^2 - \frac{1}{(L-1)} \sum_{i=1}^{L-1} \omega_i} \\ \hat{a} = \frac{1}{(L-1)} \sum_{i=1}^{L-1} \lambda_i - \hat{b} \frac{1}{(L-1)} \sum_{i=1}^{L-1} \omega_i \quad (13)$$

将  $\hat{a}, \hat{b}$  代入(11)式便得到  $\lambda$  的判别门限  $\tau$ , 如下式.

$$\tau = \hat{a}k + \hat{b} \quad (14)$$

#### 3.3 虚拟维数值确定

设定虚拟特征邻差选择器, 如下式.

$$\lambda_l > \tau, \quad \lambda_l \in E_\lambda \\ \lambda_l < \tau, \quad \lambda_l \notin E_\lambda \quad (15)$$

当  $\lambda_l > \tau$  时, 邻差  $\lambda_l$  表现为主要特征; 当  $\lambda_l < \tau$  时, 差值  $\lambda_l$  表现非主要特征. 将  $\lambda(\lambda_1, \lambda_2, \dots, \lambda_{L-1})$  依次通过虚拟特征邻差选择器后, 统计  $E_\lambda$  中元素的个数, 就可得到高光谱原始数据的虚拟维数值.

## 4 实验结果与分析

#### 4.1 模拟数据实验

模拟数据的生成采用 AVIRIS 成像光谱仪获取并经过校准的 50 个波段的高光谱遥感图像, 图像空间尺寸为  $400 \times 350$ , 波谱类型为反射波谱, 场景为赤铜矿地理特征, 如图 1(a) 所示. 用自动目标生成算法<sup>[14]</sup> (Automatic Target Generation Process, ATGP) 从该数据集中提取的  $N$  组模拟端元特征  $\eta_i (i=1, 2, \dots, N)$ , 通过下式合成出模拟高光谱数据矩阵  $Z_s$ .

$$Z_s[l] = \sum_{i=1}^N a_i(l) \eta_i, l = 1, 2, \dots, 400 \times 350 \quad (16)$$

系数列向量  $a_i(l)$  满足

$$\sum_{i=1}^N a_i(l) = 1, a_i(l) > 0, l = 1, 2, \dots, 400 \times 350 \quad (17)$$




图 1 实验高光谱图像

Fig. 1 Experimental hyperspectral image

4.1.1 噪声的影响 表 1 是当模拟端元数  $N=5$ 、虚警概率  $P_F=10^{-3}$  时,在不同信噪比(SNR)的高斯白噪声干扰下,用 HFC、NWHFC、NCVD 和 NSP 四种算法确定的虚拟维数值.从表中不难发现,当信噪比分别大于  $15:1$ ,  $20:1$  和  $20:1$  时,NCVD、HFC 和 NSP 算法确定的维数保持稳定,值分别为 5, 4 和 4, NCVD 算法相较于 HFC 和 NSP 算法稳定性较好.当信噪比分别为  $5:1$  和  $10:1$  时, HFC、NSP 和 NCVD 算法确定的虚拟维数值分别是 2, 3, 3 和 2, 3, 6.这是由于当噪声干扰较强时,数据特征与特征之间的关系变得非常模糊,在维数分析中,可能将原本较为接近的特征合并为同一特征,导致确定维数的减少;有时,也可能将同一特征拆分成两个乃至多个特征,导致确定维数的增加.在强噪声干扰下,NCVD 算法受影响较小,所确定的维数可靠性明显高于 HFC、NSP 算法.当信噪比为  $40:1$  时,模拟数据基本表现为信号特征, HFC、NWHFC、NSP 和 NCVD 算法确定的虚拟维数值分别是 4, 4, 4, 5, NCVD 算法确定的维数与模拟端元数一致,维数估计准确性也好于其他三种算法.

表 1 不同信噪比下确定的虚拟维数值

Tab. 1 Virtual dimension values of different SNR

SNR	HFC	NWHFC	NSP	NCVD
SNR=5:1	2	3	3	3
SNR=10:1	2	4	3	6
SNR=15:1	3	4	3	5
SNR=20:1	4	4	4	5
SNR=30:1	4	4	4	5
SNR=40:1	4	4	4	5

4.1.2 端元个数的影响 表 2 是当虚警概率  $P_F=10^{-4}$  时,用不同个数的端元模拟的高光谱遥感图像数据,在加入信噪比为  $30:1$  的高斯白噪声后,用四种算法确定的虚拟维数值.当模拟端元数为 5 时,

由于端元特征较少,特征与特征间的距离较大,各种特征表现较为明显,四种算法确定的维数较一致,都接近或等于模拟端元数.当混合端元特征增加到 8 和 10 时,由于存在的端元特征较多,特征与特征之间距离缩小,各种端元特征表现不再明显, HFC、NWHFC 和 NSP 算法往往将较相似的多个特征视为一个特征,导致估计维数的减少.特别是当模拟端元数为 10 时,估计出的维数误差较大.而 NCVD 算法受混合端元数影响较小,在混合的端元特征增加时,能够有效地区分各种特征,较准确地估计出虚拟维数.

表 2 不同混合端元数下确定的虚拟维数值

Tab. 2 Virtual dimension values of different mixed End-members

N	HFC	NWHFC	NSP	NCVD
N=5	4	4	4	5
N=8	5	6	5	8
N=10	5	6	5	11

## 4.2 真实数据实验

这里采用两种类型的真实高光谱数据,分别为如图 1(b)所示的 224 波段的 AVIRIS 成像光谱仪获取的赤铜矿地理特征高光谱遥感图像另一场景(图像空间尺寸为  $614 \times 512$ ; 波谱类型为反射波谱)和如图 1(c)所示的 863 遥感数据中的 OMIS 模块化成像光谱仪数据(辽东湾及辽河入海口高光谱遥感图像其中一场景,图像空间尺寸为  $536 \times 512$ ).

4.2.1 虚警概率的影响 图 2 是 AVIRIS 高光谱数据在不同虚警概率  $P_F$  下,四种算法确定的虚拟维数值的点线图.从理论上来说,随着预测准确性的增加,即当虚警概率  $P_F$  递减且无限趋近于 0 时,虚拟维数值应逐步减小.从图 2 中可以看出 HFC 算法确定的虚拟维数不随  $P_F$  值改变而改变,其估计值始终为 4; NWHFC、NSP 和 NCVD 算法确定的虚拟维数符合理论分析.从虚拟维数变化趋势来看,本文所提算法确定的虚拟维数随虚警概率  $P_F$  变化幅度相较于 NWHFC 和 NSP 算法较小,说明 NCVD 算法的稳定性优于其他三种算法.

表 3 是 OMIS 高光谱数据,在不同虚警概率  $P_F$  下,通过四种算法确定的虚拟维数值.从表中不难发现,当虚警概率值  $P_F=10^{-1}$  和  $P_F=10^{-2}$  时, NWHFC 和 NSP 算法估计出的虚拟维数值误差极大,不能作为后续处理数据的参考,而 NCVD 算法受  $P_F$  影响较小,估计出的虚拟维数值变换范围不大,在要求精度不高的情况下仍然能够较好的分析出数据的虚拟维数.




图 2 虚警概率与虚拟维数关系图

Fig. 2 The diagram false alarm probability and virtual dimension

表 3 不同  $P_F$  下的虚拟维数值

Tab. 3 Virtual dimension values of different  $P_F$

$P_F$	HFC	NWHFC	NSP	QRVD
$P_F=10^{-1}$	—	98	112	22
$P_F=10^{-2}$	—	41	35	18
$P_F=10^{-3}$	26	22	11	16
$P_F=10^{-4}$	8	11	5	12
$P_F=10^{-5}$	4	7	5	11

4.2.2 分类效果比较 图 3 是当虚警概率  $P_F = 10^{-5}$  时, 用确定的 OMIS 高光谱数据的虚拟维数值

对图像进行 K-均值非监督分类后得到的分类图像. 其中, 在虚警概率  $P_F = 10^{-5}$  时, HFC、NWHFC、NSP 和 NCVD 算法得到的虚拟维数值分别为: 4, 7, 5, 11. 图 3(a) 为在 OMIS 遥感图像的可见光波长范围中选取三个波段合成的伪彩色图像, 作为评判分类效果的参考, 图 3(b)~3(e) 分别表示当所估维数分别是 4, 5, 7, 11 时, 分类后得到的分类图像. 为方便描述将图像划分为 6 个区域, 图中数字表示划分区域的序号. 参照图 3(a), 图 3(b)~3(e) 都将最为简单的区域 6 归为一类, 说明各种维数分析算法都能够有效地分析出简单的地物特征; 对于相对简单的区域 1, 2, HFC 和 NSP 算法做出了简单的分类, 基本表现了地貌特征, 而 NWHFC 和 NCVD 算法对此区域分析较为细致, 表现出了一些在可见光谱中未能反映的地貌特征; 从图 3(b) 和 3(c) 可以知道, HFC 和 NSP 算法只将 3, 4, 5 连成的区域分成了 2~3 类, 完全无法体现这些复杂地物的分布特征; 从图 3(d) 可知 NWHFC 算法也只是对这一复杂区域做出了简单的分析, 虽然基本表现出了区域 5 的地貌特征, 但是对于区域 3, 4 没有给出很好的划分. 而 NCVD 算法不仅较为完整表现了区域 5 的地貌特征, 而且将区域 3, 4 中细微的地貌特征做出了很好的区分.




图 3 OMIS 高光谱遥感图像非监督分类图

Fig. 3 Unsupervised classification maps of OMIS hyperspectral image

## 5 结 论

本文提出的噪声抑制的虚拟维数估计算法主要有以下三个特点: 第一, 将高光谱数据矩阵进行 QR 分解, 利用 Q 矩阵正交的特点和 R 矩阵数据集中的特点决定虚拟维数能够增加所估维数的准确性并减小计算的复杂度; 第二, 设定滑动噪声检测窗口有效地减少了噪声对维数分析的影响; 第三, 运用最小二乘算法求得 Q 矩阵与 R 矩阵特征邻差门限间的线性变换系数, 使结果更具有合理性. 从实验结果可知: 所提算法较 HFC、NWHFC 和 NSP 算法, 在强噪声作用下仍能够较为准确的

估计出数据的虚拟维数, 随着虚警概率的减少所估虚拟维数值较 NWHFC 和 NSP 算法维数变化幅度较小, 说明所提算法具有良好的稳定性; 此外, 通过对 OMIS 高光谱图像进行非监督分类, 还说明用 NCVD 算法分析出的维数指导非监督分类, 其分类效果好于 HFC、NWHFC 和 NSP 算法.

本文提出算法在抗噪性能及分类效果上均取得了良好的效果, 在此基础上可以展开进一步的工作: (1) 结合不同滤波器的特点, 进一步完善滑动噪声检测窗口的设计, 提高检测和滤除噪声的性能; (2) 考虑将其它最优化技术运用到邻差门限变换系数估计中; (3) 寻找有观测区域地面实测光谱

数据的高光谱图像,进行有监督分类实验,进一步验证算法的性能.

#### 参考文献:

- [1] 徐元进,胡光道.穷举法在高光谱遥感图像地物识别中的应用[J].四川大学学报:工程科学版,2007,39(5):168.
- [2] 杨晓敏,吴炜,干宗良,等.一种基于稀疏字典和残余字典的遥感图像超分辨率重建算法[J].四川大学学报:工程科学版,2015,47(3):71.
- [3] 杨晓敏,吴炜,严斌宇,等.基于双重字典及联合特征的遥感图像超分辨率算法[J].四川大学学报:自然科学版,2015,52(5):1045.
- [4] 李伟生,王卫星,罗代建.用Harris-Laplace特征进行遥感图像配准[J].四川大学学报:工程科学版,2011,43(4):89.
- [5] Harsanyi J C, Chang Chein-I. Hyperspectral image classification and dimensionality reduction: an orthogonal subspace projection approach [J]. IEEE Trans Geosci Remote, 1994, 32(4): 779.
- [6] 张敏情,狄富强,刘佳.基于选择性集成分类器的通用隐写分析[J].四川大学学报:工程科学版,2015,47(1):36.
- [7] Mojaradi B, Abrishami-Moghaddam H, Zoj M J V, *et al.* Dimensionality reduction of hyperspectral data via spectral feature extraction[J]. IEEE Trans Geosci Remote, 2009, 47(7): 2091.
- [8] Chang C I, Du Q. A noise subspace projection approach to determination of intrinsic dimensionality for hyperspectral imagery [C]//Proceedings of Image and Signal Processing for Remote Sensing V. Florence, Italy: SPIE, 1999.
- [9] Chang C I, Du Q. Estimation of number of spectrally distinct signal sources in hyperspectral imagery [J]. IEEE Trans Geosci Remote, 2004, 3(42): 608.
- [10] Harsanyi J C, Farrand W, Hejl J, *et al.* Automatic identification of spectral endmembers in hyperspectral image sequences[C] //Proceedings of International Symposium on Spectral Sensing Research. San Diego, USA: IEEE, 1994.
- [11] 邓翔宇,刘增力.基于改进的MCA和K-SVD的图像稀疏表示去噪算法[J].四川大学学报:自然科学版,2016,53(4):774.
- [12] 李若晨,李勤,琚生根,等.图像内部Move-Copy篡改盲取证算法研究[J].四川大学学报:自然科学版,2016,53(1):67.
- [13] 赵超,李东方,唐亚勇.分位点门限自回归时间序列模型的贝叶斯分析[J].四川大学学报:自然科学版,2016,53(4):748.
- [14] Ren H, Chang C I. Automatic spectral target recognition in hyperspectral imagery [J]. IEEE Trans Aero Elec Sys, 2003, 39(4): 1232.