

# 基于双向信号子空间投影的 高光谱图像虚拟维数估计

梅少辉, 何明一, 戴玉超

(西北工业大学 电子信息学院 陕西省信号与信息处理重点实验室, 陕西 西安 710072)

**摘要:** 提出一种基于双向信号子空间投影的高光谱图像虚拟维数估计算法。该算法分别在高光谱图像的像元方向和波段图像方向进行信号子空间估计, 虽然这两个方向上信号子空间的分布不同, 但其维数均等于图像的虚拟维数。该方法不需要对信号子空间和噪声子空间进行区分, 仅通过对不同方向上的信号子空间投影进行比较, 获取图像的虚拟维数。仿真像元实验和实际高光谱图像实验均证明该算法改善了传统的基于单向投影的虚拟维数估计算法的性能, 其性能优于常用的虚拟维数估计算法: Neyamn-Pearson 检测算法和信号子空间估计算法。

**关键词:** 虚拟维数, 本征维数, 高光谱图像, 混合像元分解

中图分类号: TP753

文献标识码: A

文章编号: 1000-2758(2012)05-0640-07

高光谱遥感是高光谱分辨率遥感的简称, 在电磁波谱的可见光、近红外、中红外和热红外波段范围内, 利用成像光谱仪纳米级的光谱分辨率, 以几十或几百个波段同时成像, 获得地物的连续光谱信息, 实现了地物的空间信息和光谱信息的同步获取, 在相关领域内具有巨大的应用价值和广阔的发展前景。但是, 随着图像维数的增加, 其在高维空间表现出不同于低维空间的特性。实际上, 高光谱图像数据在高维空间的分布往往具有一定聚集性, 数据向超立方体的角落、超(椭)球体外层聚集, 也就是说, 信号集中在某一低维空间之中, 其余大部分空间为空。在这种情况下, 很难从高维空间中直接获取信号分布特性。因此, 在进行高光谱图像处理时, 需要获取图像的本征维数 (intrinsic dimensionality, ID), 即获取描述该高维数据集的最少的独立变量个数。

近年来, 从目标检测和图像分类的角度出发, 虚拟维数<sup>[1]</sup> (virtual dimensionality, VD) 的概念被提出来定义描述高光谱数据集所需要的最少的特征光谱信号数目。研究证明, 虚拟维数可以用来决定特征约简问题中需要保留的特征数目, 波段选择问题中需要选择的波段数目, 以及用于混合像元分解的纯

净端元光谱的数目。高光谱图像的虚拟维数往往远小于其本身的维数, 如何对其进行准确估计是进行混合像元分解的一个关键问题。在高光谱图像混合像元分解中, Wu等<sup>[2]</sup>总结了6种常用的虚拟维数估计方法: ①特征值能量法; ②基于信息理论的准则 (Information Theoretic Criterion)<sup>[3]</sup>; ③最小描述长度算法 (Minimum Description Length)<sup>[4]</sup>; ④基于 Gershgorin 圆半径的方法<sup>[5]</sup>; ⑤信号子空间估计法 (Signal Subspace Estimation, SSE)<sup>[6]</sup>; ⑥Neyamn-Pearson 检测法<sup>[1]</sup>。

高光谱图像的虚拟维数通常用来确定其降维后需要保留的信号子空间的维数, 因此, 许多子空间投影法, 如主成分分析 (Principal component analysis, PCA)、矩阵的奇异值分解 (Singular value decomposition, SVD)、最小噪声分离 (Minimum noise fraction, MNF) 等, 通常被用于高光谱图像的虚拟维数估计。但在这些基于投影方法中, 仅从一个方向对图像进行投影, 需要准确区分信号子空间和噪声子空间。而在实际应用中, 对信号子空间和噪声子空间的区分往往存在一定的误差, 进而导致对图像的虚拟维数估计偏差。本文提出一种基于双向投影的虚拟维

收稿日期: 2011-10-23

基金项目: 国家自然科学基金 (61171154, 61201324)、教育部博士研究生学术新人奖和西北工业大学基础研究基金资助  
作者简介: 梅少辉 (1984—), 西北工业大学讲师, 主要从事高光谱遥感图像处理研究。

数估计算法, 分别在高光谱图像的 2 个方向进行信号子空间估计, 通过对不同方向上的信号子空间投影进行比较, 增大了信号子空间和噪声子空间之间的区分, 准确地估计出图像的虚拟维数。最后, 通过不同的实验数据验证了该算法的有效性和优越性。

## 1 基于双向子空间投影的虚拟维数估计算法

### 1.1 基于投影的虚拟维数估计

高光谱图像数据通常聚集在一个维数远小于其本身维数的低维子空间, 根据线性混合原理可知<sup>[7]</sup>, 图像中所有像元通常落入由端元光谱向量决定的一个单形体内部, 这个单形体的维数远小于图像本身的维数(通常等于图像的波段数目)。当图像数据投影到包含该单形体的一个子空间时, 混合像元分解中所用到的图像特性基本被完全保留下来<sup>[8]</sup>。因此, 包含端元决定的单形体的最小子空间维数就等于图像的虚拟维数。当图像中的所有像元投影到一个维数低于虚拟维数的子空间时, 混合像元分解中用到的很多图像信息在投影过程中丢失。因此, 高光谱图像的虚拟维数估计问题就是寻找最小的信号子空间, 包含原始高维信号的所有有用信息。

记  $\xi_i (i = 1, 2, \dots, B)$  为高光谱图像  $R$  的一组独立正交基, 其中  $B$  为信号本身的维数, 则高光谱图像  $R$  的子空间投影可以表示为

$$P_{(\xi_1, \xi_2, \dots, \xi_l)}(R) \quad l < B \quad (1)$$

整个图像数据的空间通常包含信号子空间和噪声子空间, 假设这组基按照信号贡献程度的大小排列, 则图像的虚拟维数可以通过信号子空间投影来确定, 即图像的虚拟维数等于能够保留图像中所有信号信息的子空间维数

$$VD = \arg \{ \min_{l < B} [\phi(P_{(\xi_1, \xi_2, \dots, \xi_l)}(R)) = \phi(R)] \} \quad (2)$$

式中  $\phi(\cdot)$  为判定图像中所有信号信息是否被完全保留的准则, 这个判断准则是估计图像的虚拟维数的一个关键问题。目前, 基于子空间投影的虚拟维数估计方法均是基于这一原理进行估计的, 例如, 在基于特征值能量法的虚拟维数估计中, 通过确定信号贡献度比较大的特征值数目来估计其虚拟维数。但通常情况下, 信号子空间与噪声子空间之间并不

存在一个明显的界限, 很难根据特征值大小对其进行区分, 因此依据(2)式进行虚拟维数的估计往往不够精确。

### 1.2 基于双向信号子空间投影的虚拟维数估计算法

通常情况下, 高光谱图像可以认为是一组高光谱像元的集合, 即

$$R = R_{B \times N} = \{R_i \quad i = 1, 2, \dots, N\}, \quad (3)$$

式中  $R_i = (R_{1i}, R_{2i}, \dots, R_{Bi})^T (i = 1, 2, \dots, N)$  表示图像中第  $i$  个像元向量, 代表地面上一个像元范围内的地物在所有波段范围内的反(辐)射光谱,  $N$  为图像中像元的数目。此外, 高光谱图像还可以看作为是一组波段图像的集合, 即

$$R = I_{N \times B} = \{I_j \quad j = 1, 2, \dots, B\}, \quad (4)$$

式中  $I_j = (I_{1j}, I_{2j}, \dots, I_{Nj})^T (j = 1, 2, \dots, B)$  表示图像中第  $j$  个波段的图像向量, 代表某一波段范围内图像中所有地物的反(辐)射光谱。显然,

$$R = I^T \quad (5)$$

**定理 1** 高光谱图像像元方向和波段图像方向的虚拟维数相同。

定理 1 的证明如下:

假设图像的波段数小于像元数目, 即  $B < N$ , 则像元方向的矩阵(简称为像元矩阵)  $R$  的奇异值分解为

$$\begin{aligned} R &= S \cdot V \cdot D^T \\ &= (s_1 \ s_2 \ \dots \ s_B) \begin{bmatrix} v_1 & & \\ & \ddots & \\ & & v_B \end{bmatrix} (d_1^T \ d_2^T \ \dots \ d_2^T) \\ &= \sum_{i=1}^B v_i s_i d_i^T \end{aligned} \quad (6)$$

式中  $\{s_i\}$  和  $\{d_i\}$  分别为一组正交基, 奇异值表示对应的奇异向量空间中信号分量的比重。同理, 波段图像方向的矩阵(简称波段矩阵)  $I$  的 SVD 分解为

$$\begin{aligned} I &= R^T = D \cdot V \cdot S^T \\ &= (d_1 \ d_2 \ \dots \ d_B) \begin{bmatrix} v_1 & & \\ & \ddots & \\ & & v_B \end{bmatrix} (s_1^T \ s_2^T \ \dots \ s_2^T) \\ &= \sum_{i=1}^B v_i d_i s_i^T \end{aligned} \quad (7)$$

从(6)式和(7)式可以看出, 2 个方向的矩阵分解具有相同的奇异值, 因此, 高光谱图像的像元方向和波段图像方向的虚拟维数相同。[证毕]。

目前,基于信号子空间投影的方法仅仅从图像的一个方向进行投影,很难区分信号子空间与噪声子空间。在本文中,同时在高光谱图像的2个方向进行子空间投影,由于信号在不同方向上的子空间中分布不同,因此,图像在2个方向上的信号子空间投影也不相同。本文通过判断图像在这两个方向上的投影是否一致来确定高光谱图像的虚拟维数,即当信号子空间的维数小于虚拟维数时,2个方向的信号子空间投影表现出不同的性质,但当信号子空间的维数等于或大于虚拟维数时,2个方向上信号子空间投影表现出相同或相似的性质。假设图像的波段数小于像元数目,即  $B < N$ , 记  $\lambda_i (i = 1, 2, \dots, B)$  和  $\eta_i (i = 1, 2, \dots, B)$  分别为图像在2个方向上的按照信号贡献度排列的2组正交基,根据以上分析,本文提出一种基于双向信号子空间投影(Double Signal Subspace Projection, DSSP)的虚拟维数估计方法,该方法可以表示为下式所示的二值问题

$$\begin{cases} \phi(P_{\lambda_l}(R)) \neq \phi(P_{\eta_l}(R)) & l = 1, 2, \dots, VD - 1 \\ \phi(P_{\lambda_l}(R)) = \phi(P_{\eta_l}(R)) & l = VD, VD + 1, \dots, B \end{cases} \quad (8)$$

式中,  $\lambda_l = [\lambda_1, \lambda_2, \dots, \lambda_l]$ ,  $\eta_l = [\eta_1, \eta_2, \dots, \eta_l]$ ,  $l < B$ 。因此,依据本章提出的DSSP算法,高光谱图像的虚拟维数估计为

$$VD = \arg \{ \min_{1 < l < B} [\phi(P_{\lambda_l}(R)) = \phi(P_{\eta_l}(R))] \} \quad (9)$$

实际中,由于噪声的存在,高光谱图像的虚拟维数通常可以估计为

$$VD = \arg \{ \min_{1 < l < B} [\Delta\phi(P_l(R)) \leq \tau] \} \quad (10)$$

式中  $\tau$  为检测门限,  $\Delta\phi(P_l(R))$  为2个方向的投影之间的差别

$$\Delta\phi(P_l(R)) = | \phi(P_{\lambda_l}(R)) - \phi(P_{\eta_l}(R)) | \quad (11)$$

### 1.3 基于主成分分析的DSSP算法

从(6)式和(7)式可以看出,利用SVD分解在高光谱图像的像元方面和波段图像方面提取基向量时,其对应的奇异值完全相同,因此,这两个方向上的子空间分布完全相同。本章提出的DSSP算法利用2个方向上子空间分布的不同进行虚拟维数的估计,需要从2个方向提取2组信号分布不同的基向量,因此,在本章提出的DSSP算法中,不能使用SVD进行基向量的提取。

PCA借助正交变换,将相关的随机向量转化成

其分量不相关的新随机向量,在代数上表现为将原随机向量的协方差阵变换成对角形阵,在几何上表现为将原坐标系变换成新的正交坐标系,使之指向样本点散布最分散的各个正交方向。本文利用PCA提取按照信号贡献度排列的正交基,其中,信号贡献度通过对方差贡献大小来衡量,于是,  $\lambda_i (i = 1, 2, \dots, B)$  和  $\eta_i (i = 1, 2, \dots, B)$  可以通过分别对矩阵  $R$  和  $I$  进行PCA分析获得。因此,高光谱图像  $R$  在2个方向的投影分别为

$$P_{\lambda_l}(R) = P_{\lambda_l}(R) = \lambda_l \lambda_l^T \hat{R} \quad (12)$$

$$P_{\eta_l}(R) = P_{\eta_l}(I) = \eta_l \eta_l^T \hat{I} \quad (13)$$

式中  $\hat{R}$  和  $\hat{I}$  分别为像元方向和图像方向的去均值向量组成的矩阵。为了确定图像的虚拟维数,选取子空间的投影误差(定义为图像对信号子空间的正交补投影的Frobenius范数)作为判定所有信号信息是否完全保留的准则,因此,图像在两个方向上的投影误差分别为

$$\phi(P_{\lambda_l}(R)) = \| R - P_{\lambda_l}(\hat{R}) \|_F \quad (14)$$

$$\phi(P_{\eta_l}(R)) = \| R - P_{\eta_l}(\hat{I}) \|_F \quad (15)$$

将(12)式~(15)式代入(10)式,即可利用基于PCA分析的DSSP算法进行虚拟维数。

通常情况下,如果一组数据位于一个过原点的超平面内,对这些数据做去均值处理时,去均值后的数据与原始数据的虚拟维数相同,但如果这组数据所在的超平面不过原点,去均值后数据的虚拟维数比原始数据的虚拟维数小1。因此,在使用均值后的数据进行投影重建时,还需要证明去均值后数据的维数是否等于原始数据的维数。

由线性混合模型可知,图像的像元矩阵表示为

$$R = M \cdot A \quad (16)$$

式中  $M = [m_1, m_2, \dots, m_{VD}]$  和  $A = [\alpha_1, \alpha_2, \dots, \alpha_N]$  分别表示端元光谱矩阵及其对应的丰度值向量,则图像中的像元  $r$  可以表示为

$$r = M \cdot \alpha \quad (17)$$

式中  $\alpha = [\alpha_1, \alpha_2, \dots, \alpha_{VD}]$  表示像元中各端元光谱对应的丰度值。又由于丰度  $\alpha$  必须满足和为1的约束,即

$$\sum_{i=1}^{VD} \alpha_i = 1 \quad (18)$$

因此

$$r = \sum_{i=1}^{VD} m_i \cdot \alpha_i = \sum_{i=1}^{VD-1} m_i \cdot \alpha_i + m_{VD} \cdot (1 - \sum_{i=1}^{VD-1} \alpha_i)$$

$$= \sum_{i=1}^{VD-1} (m_i - m_{VD}) \cdot \alpha_i + m_{VD} \quad (19)$$

于是,图像上的所有像元均位于不过原点的一个超平面上,因此在像元方向对数据进行去均值处理,其虚拟维数减 1,即

$$VD(\mathbf{R}) = VD(\hat{\mathbf{R}}) + 1 \quad (20)$$

在波段图像方向上,波段矩阵  $\mathbf{I}$  可以表示为

$$\mathbf{I} = \mathbf{R}^T = \mathbf{A}^T \mathbf{M}^T \quad (21)$$

丰度的 2 个约束并不对其产生影响,因此在图像上的所有波段处于一个过原点的超平面上,因此在波段方向对数据进行去均值处理,其虚拟维数不变,即

$$VD(\mathbf{I}) = VD(\hat{\mathbf{I}}) \quad (22)$$

由(20)式和(22)式可知

$$VD(\hat{\mathbf{I}}) = VD(\hat{\mathbf{R}}) + 1 \quad (23)$$

即像元方向去均值数据的虚拟维数比波段方向去均值数据的虚拟维数小 1。但在使用本文提出的 DSSP 算法进行虚拟维数估计时,仅在维数大于 2 个方向虚拟维数的空间上,其性能达到一致,于是,当 2 个方向的投影性能达到一致时空间的维数为

$$VD = \max\{VD(\hat{\mathbf{I}}), VD(\hat{\mathbf{R}})\} \\ = VD(\hat{\mathbf{I}}) = VD(\mathbf{I}) = VD(\mathbf{R}) \quad (24)$$

因此,使用 PCA 进行基向量的提取时,DSSP 算法能够正确估计出图像的虚拟维数。

## 2 实验结果与分析

### 2.1 高光谱仿真像元实验

实验从美国 USGS 光谱数据库<sup>[9]</sup>中任意选取 5 种矿物的光谱特征曲线仿真高光谱混合像元,这些矿物光谱曲线覆盖从可见光到红外域(400 nm 到 2 500 nm)的 420 个波段。在进行混合像元仿真时,依据线性混合模型进行仿真,混合像元的丰度依据和为 1 和非负性 2 个约束随机产生,总共仿真 1 000 个混合像元,并在这些像元中加入 50 dB 的高斯噪声,用于仿真传感器的测量误差、热噪声以及线性混合模型的不足,使得仿真数据更加真实。

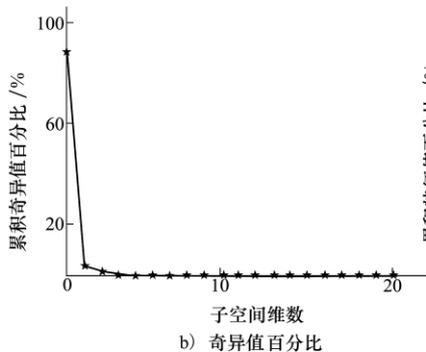
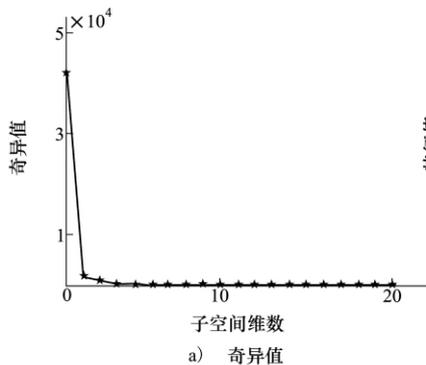


图 1 奇异值分布图

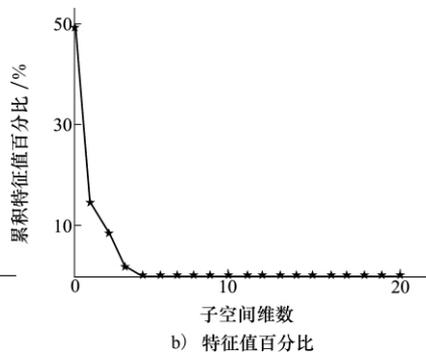
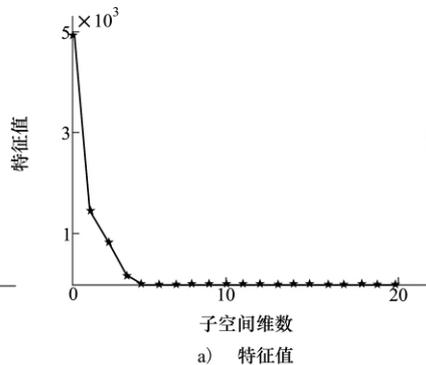


图 2 像元方向特征值分布图

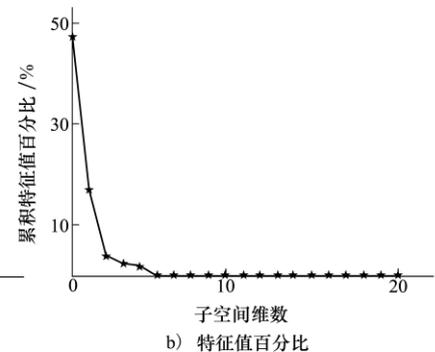
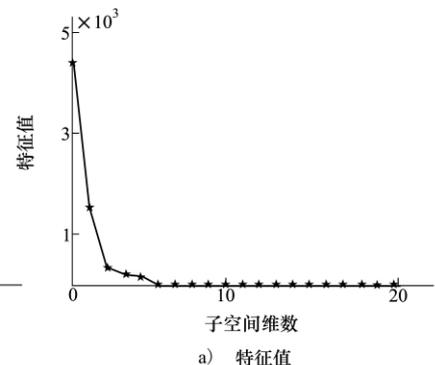


图 3 波段图像方向特征值分布图

图 1 给出了图像数据经过 SVD 分解后奇异值和奇异值百分比随子空间维数增加的变化图,从这两个图中很难区分信号子空间和噪声子空间。仔细

分析奇异值分布,可以得出该组数据的虚拟维数为 5。图 2 和图 3 分别给出了在像元方向和波段图像方向进行 PCA 分析后特征值和特征值百分比的分

布图,从图 2 可以看出,像元方向去均值数据的虚拟维数为 4,比原始图像的虚拟维数小 1,证明了(22)式的结论;从图 3 可以看出,波段方向去均值数据的虚拟维数为 5,与原始图像的虚拟维数相同,证明了(23)式的结论。但在这两个方向的基于特征值的方法中,信号子空间对应的特征值和噪声子空间对应的特征值间并不存在明显的界限,很难对其进行区分,在实际图像数据中这种区分将会变得更加模糊。

使用本文提出的 DSSP 算法进行该组像元中纯净地物数目的估计。图 4a) 给出了在 2 个方向上的不同维数的子空间中对去均值后的数据进行重构时的误差分布图,以对数形式显示,其中  $R$  和  $I$  方向上的重构误差分别使用“\*”和“o”表示。从该图可以看出,随着子空间维数的增加 2 个方向上的重构误差开始重叠,这是因为在理想情况下,当子空间的维数等于或者超出图像的虚拟维数时 2 个方向的重构误差完全相同。实际中,由于噪声的存在,则出现如图 4a) 所示的现象。2 个方向信号子空间重构误差之间的差异如图 4b) 所示,从该图很容易判断出,选取检测门限为  $1 \times 10^3$ ,这组信号的虚拟维数为 5,与实际情况完全相同。

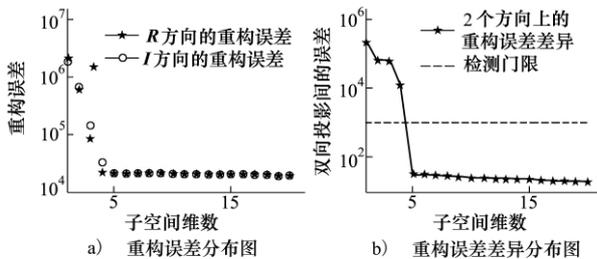


图 4 DSSP 算法对仿真图像的分析结果

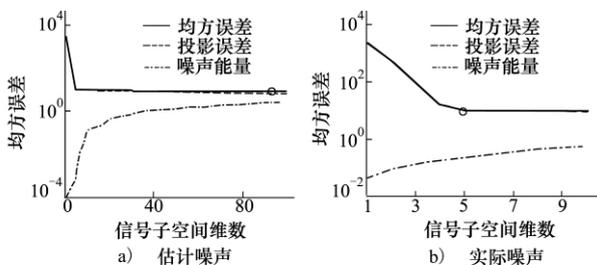


图 5 SSE 算法中均方误差随子空间维数变化曲线图

为了进一步验证本文提出的 DSSP 算法有效性,将本文提出的 DSSP 算法与信号子空间估计法

(SSE)<sup>[6]</sup>和 Neyamn-Pearson 检测法<sup>[1]</sup>进行比较。图 5 给出了使用 SSE 算法进行虚拟维数估计时,均方误差随信号子空间维数变化图,其中图 5a) 图使用文献[6]中给出的噪声估计方法估计噪声,从该图可以看出,该组数据的虚拟维数为 93,远大于其实际的虚拟维数。图 5b) 图给出使用实际噪声(仿真时加入的噪声)进行 SSE 估计时的曲线图,从该图可以看出,SSE 算法准确估计出该组数据的虚拟维数。因此,SSE 算法对噪声非常敏感,如果可以准确估计出图像的噪声,则 SSE 算法可以准确估计出图像数据的虚拟维数,但如果对于噪声估计存在偏差,则 SSE 算法对虚拟维数的估计也存在一定的偏差。而在实际应用中,对于噪声的估计通常存在一定的偏差,因此,SSE 算法的性能受限于噪声估计的准确性。本文提出的 DSSP 算法无需估计噪声,直接从原始数据出发,避免了由于噪声估计的偏差而带来的虚拟维数估计的偏差。

使用 Neyamn-Pearson 检测法对该组数据进行虚拟维数估计,图 6 给出了虚警概率  $P_f = 1 \times 10^{-3}$  时特征值差异的变化曲线图。从该图可以看出,该组数据的虚拟维数被正确估计出来。但需要注意的是,特征值差异在其索引增加到虚拟维数之前多次低于检测阈值,需要判断特征值一直低于检测阈值时的特征值索引号,这种情况在实际图像中将会变得更加复杂。

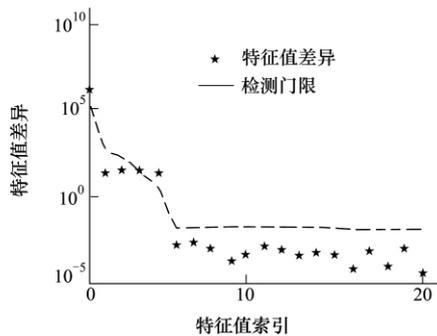


图 6 Neyamn-Pearson 检测算法中的特征值差异变化图

## 2.2 高光谱真实图像实验

实验数据来自美国 AVIRIS 多光谱扫描仪 1992 年在印第安纳北部一块农业区获取的 220 波段高光谱数据。从中筛除掉受大气污染严重、低信噪比的波段(1、2、103~110、149~165 以及 218~220),最终实验采用 185 个波段高光谱数据。实验场景 145

×145 ,图 7a) 给出了该场景的伪彩色图像 ,该区域 主要包含 16 类地物<sup>[10]</sup> ,具体分布如图 7b) 所示。

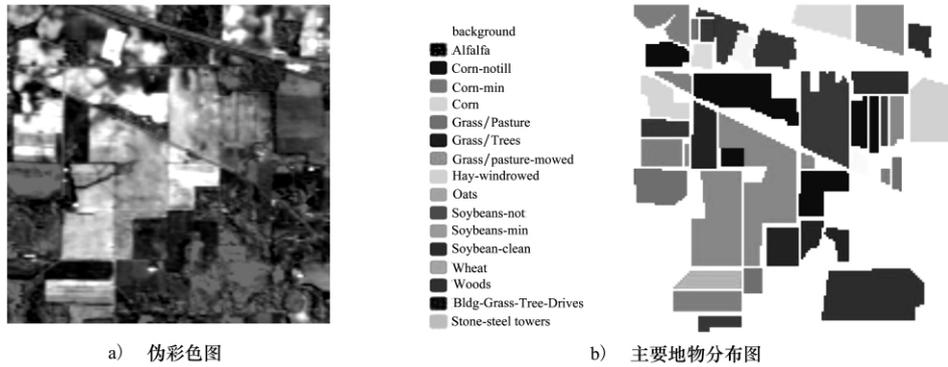


图 7 印第安纳区域高光谱图像

图 8 给出了使用本章提出的 DSSP 算法对该组图像进行虚拟维数估计时 ,重构误差间的差异随子空间维数变化的曲线图。从该图可以看出 ,该组图像的虚拟维数为 18。图 9 和图 10 分别给出了使用 SSE 算法和 Neyamn-Pearson 检测算法对该区域高光谱图像进行分析的结果 ,使用这两种算法对该组高光谱图像估计的虚拟维数分别为 9 和 20。根据图 8

给出的该区域内地物分布图像可知 ,使用本文提出的 DSSP 算法估计的结果最接近实际情况 ,估计的维数之所以多与图 8 给出地物种类数是因为图 8 并未给出背景图像的地物种类。因此 ,本章提出的 DSSP 算法的性能优于 SSE 算法和 Neyamn-Pearson 检测算法。

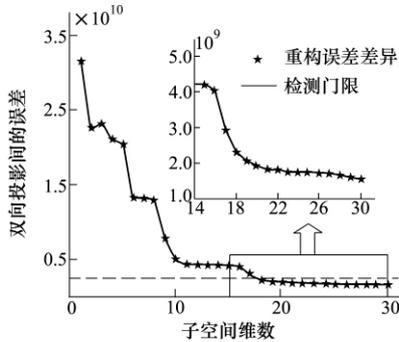


图 8 DSSP 算法对 Indian 区域高光谱图像分析时的重构误差间的差异(对数形式)分布图

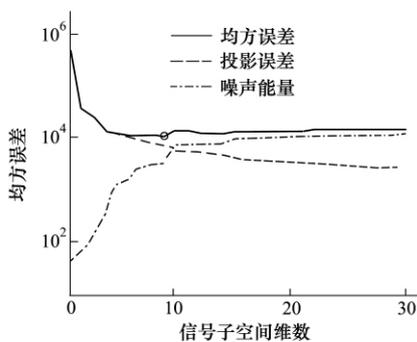


图 9 SSE 算法对 Indian 区域高光谱图像分析时均方误差随子空间维数变化曲线图

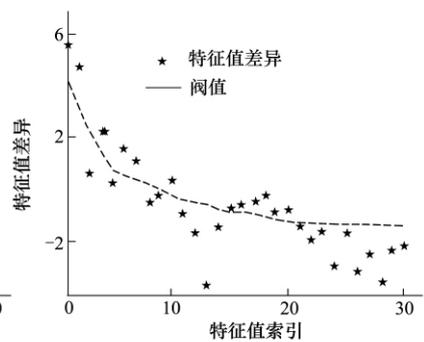


图 10 Neyamn-Pearson 检测算法对 Indian 区域高光谱图像分析时特征值差异变化图

### 3 结 论

本文提出一种基于双向信号子空间投影的虚拟维数估计方法 ,分别在低光谱图像的 2 个方向进行信号子空间估计。该方法不需要估计图像中的噪

声 ,仅通过对不同方向上的信号子空间投影进行比较 ,增大了信号子空间和噪声子空间的区别 ,估计出图像的虚拟维数。仿真和实际高光谱数据实验均证明该方法性能优于其它常用的高光谱图像虚拟维数估计算法。

### 参考文献:

[1] Chang Chein-I , Du Q. Estimation of Number of Spectrally Distinct Signal Sources in Hyperspectral Imagery. IEEE Trans on Ge-

- oscience and Remote Sensing ,2004 ,42( 3) : 608-619
- [2] Wu Chaocheng , Liu Weimin , Chang Chein-I. Exploration of Methods for Estimation of Number of Endmembers in Hyperspectral Imagery. Proceedings of SPIE ,2006 ,6378-6387
- [3] Akaike H. A New Look at the Statistical Model Identification. IEEE Trans on Automatic Control ,1974 ,AC-19: 716-723
- [4] Rissanen J. Modeling by Shortest Data Description. Automatica ,1978 ,14: 465-471
- [5] Wu H T , Yang J F , Chen F K. Source Number Estimators Using Transformed Gerschgorin Radii. IEEE Trans on Signal Processing ,1995 ,43( 6) : 1325-1333
- [6] Dias Jos<sup>ˆ</sup> , Nascimento Jos<sup>ˆ</sup>. Hyperspectral Subspace Identification. IEEE Trans on Geoscience and Remote Sensing ,2008 ,46( 8) : 2435-2445
- [7] Mei Shaohui , He Mingyi , et al. Improving Spatial-Spectral Endmember Extraction in the Presence of Anomalous Ground Objects. IEEE Trans on Geoscience and Remote Sensing ,2011 ,49( 11) : 4210-4222
- [8] He Mingyi , Mei Shaohui. Dimension Reduction by Random Projection for Endmember Extraction. IEEE Conference on Industrial Electronics and Applications ,2010
- [9] Clark R N , Swayze G A , et al. Imaging Spectroscopy: Earth and Planetary Remote Sensing with the USGS Tertracorder and Expert Systems. Journal of Geophysical Research ,2003 ,108: 5131
- [10] Landgrebe D. Multispectral Data Analysis: A Signal Theory Perspective. Purdue University West Lafayette ,1998 ,Technique Report

## A Novel DSSP ( Double Signal Subspace Projection) Algorithm for Better VD ( Virtual Dimensionality) Estimation

Mei Shaohui , He Mingyi , Dai Yuchao

( Department of Electronics Engineering , Northwestern Polytechnical University , Xi'an 710072 , China)

**Abstract:** Sections 1 and 2 of the full paper explain and evaluate our DSSP algorithm as mentioned in the title; we believe it is novel and its VD estimation is better. The core of sections 1 and 2 consists of: ( 1) . the pixel representation and image representation of a hyperspectral image are utilized to generate respectively two sets of subspaces according to the principal component analysis ( PCA) ; ( 2) . when the dimensionality of these two sets of subspaces exceeds VD of the image , both subspace projections show the same reconstruction performance; therefore , VD can be estimated by judging the difference between reconstruction performances of these two subspace projections in DSSP instead of distinguishing signal subspace from noisy subspace; ( 3) . the results of both synthetic and real hyperspectral experiments , given in Figs. 1 through 9 , demonstrate preliminarily that the performance of traditional signal subspace projection based VD estimation has been improved and that the performance of the proposed DSSP based VD estimation algorithm outperforms those of the noise whitened HFC ( NWHFC) and signal subspace estimation ( SSE) based VD estimation algorithms.

**Key words:** algorithms , classification ( of information) , data processing , eigenvalues and eigen functions , estimation , feature extraction , image processing , remote sensing , signal processing , singular value decomposition , spectrum analysis; DSSP ( Double Signal Subspace Projection) , hyperspectral , spectral mixture analysis , VD ( Virtual Dimensionality) , ID ( intrinsic dimensionality)