

改进的高光谱图像线性预测波段选择算法

周 杨¹ 厉小润¹ 赵辽英²

(¹ 浙江大学电气工程学院, 浙江 杭州 310027
² 杭州电子科技大学计算机应用技术研究所, 浙江 杭州 310018)

摘要 通过波段选择可以显著提高高光谱遥感图像分类与解混的效率。提出了两种改进的线性预测(LP)波段选择方法,用图像的偏度或峰度度量波段信息量,结合互信息(MI)或 K-L 散度度量波段间的相似性,选择本身信息量大,且彼此间最不相似的两个波段作为初始波段,再通过改进的线性预测选择后续波段。噪声波段的存在会影响波段选择的效果,导致分类或解混精度低于预期。为了减弱噪声波段的不利影响,进一步提出噪声波段去除的方法,基于小波域的熵估计每波段的噪声,去除噪声较大的波段后进行波段选择。真实高光谱图像波段选择后分类和解混实验结果表明,改进的基于线性预测的波段选择方法能明显提高分类和解混的精度和效率,是一种有效的高光谱图像降维方法。

关键词 遥感;波段选择;线性预测;噪声去除

中图分类号 TP751.1 **文献标识码** A **doi**: 10.3788/AOS201333.0828002

Modified Linear-Prediction Based Band Selection for Hyperspectral Image

Zhou Yang¹ Li Xiaorun¹ Zhao Liaoying³

(¹ College of Electrical Engineering, Zhejiang University, Hangzhou, Zhejiang 310027, China
² Research Institution of Computer Application Technology, Hangzhou Dianzi University, Hangzhou, Zhejiang 310018, China)

Abstract Band selection can greatly increase the efficiency of classification and unmixing of hyperspectral image. Two modified linear-prediction (LP) band selection methods based on similarity are proposed, which measure the information amount of bands through Skewness or Kurtosis and measure the similarity of bands through mutual information (MI) or K-L (Kullback-Leibler) divergence. The least similar two bands with large information amount are selected as the initial two bands, and the rest bands are selected by modified linear prediction. However, the existence of noise bands will affect the result of band selection, making the accuracy of classification or unmixing lower than expected. In order to weaken the adverse effect of noise bands, further efforts are made to estimate the noise of every band through wavelet entropy and remove the bands with considerable noise before band selection. The experiments of classification and unmixing after band selection for real hyperspectral images indicate that linear prediction based band selection can greatly increase the accuracy and efficiency of classification and unmixing, and it is an effective dimensionality reduction method for hyperspectral image.

Key words remote sensing; band selection; linear prediction; noise removing

OCIS codes 100.3008; 280.4788; 300.6320

1 引 言

高光谱遥感是由成像光谱仪在电磁波谱从紫外

至中红外区域中的数百个非常窄且连续的波段上同时获取信息,得到每个像素完整连续的光谱曲线^[1]。

收稿日期: 2013-02-01; **收到修改稿日期**: 2013-03-30

基金项目: 国家自然科学基金(61171152)、教育部支撑技术项目(62510216)、浙江省自然科学基金(LY13F020044)

作者简介: 周 杨(1988—),女,硕士研究生,主要从事高光谱遥感图像波段选择方面的研究。

E-mail: wuzklnh123@gmail.com

导师简介: 厉小润(1970—),男,博士,副教授,主要从事混沌控制、模式识别等方面的研究。E-mail: lxr@zju.edu.cn

在获得较高光谱分辨率的同时, 高光谱遥感数据维度较高, 带来了数据量的增大, 且由于波段之间的相关性很高, 信息冗余量大, 会造成计算机存储和处理能力的浪费。如何在无损重要信息的情况下剔除冗余信息, 尽可能地降低数据的维度, 成为一个重要问题。

针对这个问题, 目前有两类降维方法^[2]: 一种是基于变换的特征提取方法, 如主成分分析^[3], 投影寻踪^[4]等; 另一种是基于非变换的特征选择方法, 如波段选择^[5-6]等。波段选择方法从原始的数百个波段中选出最能表示整体特征的数个或数十个波段, 并以此来表示整个数据集^[7]。由于波段选择可以保留原始数据的物理意义, 因而被广泛应用。已有的波段选择方法主要有基于信息量排序的方法^[8], 如熵与联合熵^[9]; 基于类间可分性^[9]的方法, 如 B (Bhattacharyya) 距离^[10], JM (Jeffreys-Matuszta) 距离^[11]等; 基于聚类的方法, 如 AP (Affinity Propagation) 聚类^[12], 自适应波段选择方法^[13], 还有基于波段重构误差最小的方法, 如基于相似度的线性预测方法 (LP)^[14]。LP 因准确性高而被广泛采用, 但其初始波段的选择是通过遍历搜索投影最大的两个波段, 没有考虑到波段本身的信息量, 而且效率较低。本文采用偏度或峰度^[15]结合 K-L 散度 (Kullback-Leibler divergence)^[16]和互信息 (MI)^[17]来确定初始波段, 并在选择后续波段时去掉部分不会入选的波段, 标准更加明确, 效率也有所提高。

未经噪声处理的波段选择后分类或解混的精度往往低于预期, 其原因是以特异性为目标的波段选择方法选择的波段往往包含噪声波段, 而噪声波段特异性较高, 这就造成了无用数据的利用, 降低了分类或解混的精度。针对该问题, 目前解决方法主要有波段选择前去噪^[18-19], 归一化最小均方自适应滤波去噪^[20]、信噪比分析^[21]和通过观察波段图像人为

去除某些噪声波段^[22]。为了能自动去除噪声波段, 首先应该对每波段的噪声进行估计, 目前已有许多学者提出噪声估计方案, 其中研究得较多的是小波段分析法^[23-24]。本文对前期基于相似度的波段选择工作^[25]进行了扩展, 先通过各波段图像小波子带的熵进行噪声估计, 将噪声较大的波段去除, 再使用改进的线性预测进行波段选择, 以保证利用原始数据中的有用信息, 达到较高的分类与解混的精度和效率。

2 算法描述

该算法包括两大步骤: 1) 基于波段图像小波子带的熵进行噪声波段去除; 2) 用改进的线性预测波段选择算法进行波段选择。

2.1 噪声波段的去除

噪声波段的的存在会对数据处理造成干扰, 从而影响整个波段选择的效果。因此, 需要先去除噪声波段再进行波段选择。

在光学遥感中, 图像噪声主要由周期性 (系统) 噪声和随机噪声构成, 其中周期性噪声可以由频域变换滤波有效地消除, 而随机噪声的影响一直存在, 这种随机噪声一般认为是加性噪声^[26]。通常采用零均值高斯白噪声对这种加性噪声进行模拟。对于方差为 σ^2 的零均值高斯白噪声, 其每个点的取值符合概率分布:

$$P_G(x) = \frac{1}{\sqrt{2\pi\sigma}} \exp\left(-\frac{x^2}{2\sigma^2}\right), \quad -\infty < x < +\infty, \quad (1)$$

对于概率密度为 $P(x)$ 的信号, 可以用熵来度量信号中所含的平均信息量。根据信息熵的定义^[27]:

$$H = - \int P(x) \lg[P(x)] dx, \quad (2)$$

可以推导得出高斯噪声的熵为

$$\begin{aligned} H_G &= - \int P_G(x) \lg[P_G(x)] dx = - \int P_G(x) \lg\left(\frac{1}{\sqrt{2\pi\sigma}}\right) dx - \int P_G(x) \lg\left[\exp\left(-\frac{x^2}{2\sigma^2}\right)\right] dx = \\ &= \frac{1}{2} \lg(2\pi\sigma^2) + \frac{\lg(e)}{2\sigma^2} \int x^2 P_G(x) dx = \frac{1}{2} \lg(2\pi e) + \frac{1}{2} \lg\sigma^2, \end{aligned} \quad (3)$$

由(3)式可看出, 高斯噪声的熵值与方差之间呈对数增长关系。

由于各波段图像信息是信号和高斯噪声的叠加, 信号不一定满足高斯分布, 所以各波段图像的熵与方差之间不满足这种对数关系。采用小波变换可

以将信号和噪声分离, 因为小波变换后, 图像的能量主要集中在尺度大的子带, 而尺度小的高频子带系数的幅度较小能量较低。因此, 当噪声较大时, 可将最高频率子带的系数看成全部是噪声^[28]。文献^[23]证明了小波变换不改变图像噪声的熵, 却可

以大大降低图像信号的熵,所以在小波高频对角子带中信号的影响力有限,图像的熵主要是高斯噪声的熵,其与噪声方差基本满足(3)式的对数关系,即图像的熵的大小可以反映图像噪声的大小。

基于以上分析,可以通过计算每波段图像小波域高频对角子带的熵,根据熵的大小估计该波段图像噪声的大小并进行排序,进而去除一定量噪声较大的波段。去噪后再进行波段选择,能够保证信息的有效利用。

2.2 改进的线性预测波段选择算法

杜谦等^[14]提出的基于相似性的线性预测波段选择算法的基本步骤为

- 1) 选择一对初始波段 B_1 和 B_2 , 构成所选波段子集 $\Phi = \{B_1, B_2\}$;
- 2) 用线性预测准则搜索与当前 Φ 中所有波段最不相似的第三个波段 B_3 , 更新 $\Phi = \Phi \cup \{B_3\}$;
- 3) 重复步骤 2), 直到 Φ 中波段数满足需求。

该方法选择波段的关键是两个初始波段的确定和用线性预测准则选择后续波段。

2.2.1 初始波段的确定

波段选择的目的是选择信息量大, 波段间相似性低的最优波段组合, 因此, 要选择本身信息量大, 彼此间相似性又低的两个波段作为初始波段。波段本身的信息量可以用波段数据的偏度或峰度^[15]来衡量。

假设随机变量 x 具有二到四阶中心矩, 即:

$$\begin{aligned}\mu_2 &= \mathbf{E}[x - \mathbf{E}(x)]^2 = \mathbf{D}(x) = \sigma^2, \\ \mu_3 &= \mathbf{E}[x - \mathbf{E}(x)]^3, \\ \mu_4 &= \mathbf{E}[x - \mathbf{E}(x)]^4, \end{aligned} \quad (4)$$

则称 $S = \frac{\mu_3}{\sigma^3}$ 为随机变量的偏度 (Skewness), 称 $K =$

$\frac{\mu_4}{\sigma^4} - 3$ 为随机变量的峰度 (Kurtosis)。

偏度描述了随机变量分布的不对称程度, 而峰度则描述了随机变量密度函数曲线的陡峭程度。对标准正态分布而言, 偏度越大, 数据的不对称性越强; 峰度越大, 数据密度函数曲线越陡峭。即偏度和峰度值越大说明数据越偏离正态分布, 所含的信息量越大^[15]。因此, 可以选择偏度 (或峰度) 最大的波段作为第一个初始波段。

第二个初始波段是通过某种相似度量准则确定的与第一个初始波段最不相似的波段。与文献 [14] 不同, 下面分别采用 K-L 散度和 MI 作为相似度量准则, 对应的方法分别称为 LP-KL 和 LP-

MI 波段选择算法。

K-L 散度是一个在信息论中广泛应用的相似度量准则。假设两个离散随机信号的概率分布函数为 $\mathbf{P} = [P_1, \dots, P_n, \dots, P_N]^T$ 和 $\mathbf{Q} = [Q_1, \dots, Q_n, \dots, Q_N]^T$, 而且 $\sum_{n=1}^N P_n = \sum_{n=1}^N Q_n = 1$, 则定义 \mathbf{Q} 相对于 \mathbf{P} 的 K-L 散度为

$$D_{\text{KL}}(\mathbf{P} \parallel \mathbf{Q}) = \sum_{n=1}^N P_n \log \frac{P_n}{Q_n}, \quad (5)$$

(5) 式的物理意义是用 \mathbf{Q} 中元素来表达 \mathbf{P} 中元素所需要的额外信息。K-L 散度越大, \mathbf{Q} 来表达 \mathbf{P} 的难度越大, 也即 \mathbf{Q} 与 \mathbf{P} 越不相似。因此 K-L 散度在波段选择中可以作为相似度量准则。

MI 也是信息论的基本概念, 它描述了两个系统的统计相关性, 或者说一个系统存在于另一个系统中的信息量。MI 可以用信息熵来描述:

$$I(A, B) = H(A) + H(B) - H(A, B), \quad (6)$$

其中, A, B 为两个信息系统, I 为信息熵, MI 也可以作为相似度量准则, MI 越小, 两个信号越不相似。

如(5)、(6)式所示, 将与第一个波段 K-L 散度最大或 MI 最小作为第二个波段选取的准则, 所选的两个初始波段既考虑了波段本身的信息量又考虑了两个波段的相似性, 且只需两步排序, 降低了算法的时间复杂度。

2.2.2 线性预测准则选后续波段及其改进

线性预测准则是一种衡量相似度的前向搜索准则, 它能共同衡量一个波段和一组波段的相似度。

假设 Φ 中有两个含 N 个像素的初始波段 B_1 和 B_2 , 可用下式来预测第三个与 B_1, B_2 最不相似的波段 B :

$$B' = a_0 + a_1 B_1 + a_2 B_2, \quad (7)$$

此处 B' 是用波段 B_1 和 B_2 对波段 B 的线性预测。参数向量 $\mathbf{a} = [a_0, a_1, a_2]^T$ 的值可以用最小二乘法来确定:

$$\mathbf{a} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{B}, \quad (8)$$

\mathbf{X} 是一个 $N \times 3$ 矩阵, 第一列是全 1 向量, 第二列、第三列为 B_1 和 B_2 的元素。以(7)式进行线性预测, 每个波段所对应的预测误差为 $e = \|B - B'\|$, 将对应最大预测误差 e_{\max} 的波段当做与 B_1, B_2 最不相似的波段选出, 作为 B_3 并入 Φ , 接下来将 B_3 扩充到 \mathbf{X} 矩阵的第四列, (7)式可推广为

$$B' = \mathbf{Xa}. \quad (9)$$

用(9)式进行线性预测, 并用相同方法选出余下波段, 直到 Φ 中元素数量达到所需。

直接用上述线性预测准则选取后续波段, 由于

要计算剩余波段中的每个波段的预测误差,计算量较大。事实上,那些预测误差很小的波段随着 Φ 中已选波段数的增加,其新的预测误差不可能是最大的,可以预先排除,但是排除波段数量多可能会影响最后选择波段的数量,所以在选择波段数不超过总波段数一半的情况下,对文献[13]中提出的线性预测准则选后续波段做如下改进:每次迭代过程中预先排除预测误差最小的波段。

通过这种方法每次排除选中可能性最低的波段,不影响波段选择结果但可以减少波段选择的计算量。以 MI 和 K-L 散度确定初始波段的线性预测波段选择方法分别称为 LP-MI 算法和 LP-KL 算法。

3 实验验证

通过高光谱图像分类与解混实验来验证提出的改进的线性预测波段选择方法的有效性。下文中去除噪声波段后所进行的原始 LP 方法、LP-MI 和

LP-KL 算法分别称为 R-LP、R-LP-MI 和 R-LP-KL 算法,未去除噪声波段的三种方法分别称为 O-LP、O-LP-MI 和 O-LP-KL 算法,R-all bands 和 O-all bands 为作为对照的全波段处理方法。

3.1 高光谱遥感图像分类实验

选取拍摄于美国印第安纳州的 AVIRIS Indian pines 高光谱数据为实验数据^[29]。该数据有 220 个波段,波长范围从 0.4~2.5 μm ,光谱分辨力为 10 nm,空间分辨力为 17 m。实验所用的图像大小为 145 pixel \times 145 pixel,去除水吸收波段 [104-108], [150-163], 220, 剩余 200 波段用于进一步处理。

首先,为验证去噪的必要性,对 Indian pines 高光谱数据分别用 O-LP-KL 和 R-LP-KL 算法进行波段选择,设定选择 10 个波段,两种方法所选各波段图像及其对应的小波子带的熵如图 1、图 2 和表 1、表 2 所示。




图 1 O-LP-KL 波段选择算法所选波段图像(AVIRIS Indian pines 高光谱数据)
Fig. 1 Images of bands selected by O-LP-KL (AVIRIS Indian pines dataset)




图 2 R-LP-KL 波段选择算法所选波段图像(AVIRIS Indian pines 高光谱数据)
Fig. 2 Images of bands selected by R-LP-KL (AVIRIS Indian pines dataset)

表 1 O-LP-KL 波段选择所选波段小波子带的熵

Table 1 Wavelet subband entropy of bands selected by O-LP-KL (AVIRIS Indian pines dataset)

Band 1	Band 23	Band 29	Band 32	Band 40	Band 57	Band 61	Band 75	Band 81	Band 89
6.991	5.633	5.437	5.875	6.164	6.269	6.561	6.369	6.124	6.647

表 2 R-LP-KL 波段选择所选波段小波子带的熵

Table 2 Wavelet subband entropy of bands selected by R-LP-KL (AVIRIS Indian pines dataset)

Band 20	Band 23	Band 29	Band 32	Band 33	Band 35	Band 54	Band 56	Band 87	Band 116
5.936	5.633	5.437	5.875	5.820	5.907	5.543	5.631	5.928	5.861

由图 1 可看出,未去噪直接波段选择所选波段如第 1,40,57,61,75,81,89 波段图像较模糊,噪声较大,其在表 1 中对应的小波子带的熵也较大,这些波段对后续处理有不利的影响,而在去掉一定量噪声波段(如去掉 60 波段)后,这些波段不会再被选

到,所选波段(如图 2 所示)噪声较小,其在表 2 中所对应的小波子带的熵也较小,由此可看出,去除噪声波段是有效的。下面进一步通过分类实验来验证噪声波段去除能提高波段选择性能。

Purdue 大学给出的关于 AVIRIS Indian pines

区域的实地调查报告中指出该区域包含 16 类不同的地物,选择样本数较多的 6 类典型地物,这 6 类各自所对应的地物和其分类样本个数如表 3 所示。每类选 10% 为训练样本,剩余为测试样本,波段选择后采用支持向量机 (SVM)^[30-32] 与 K 近邻 (KNN)^[33] 分类算法进行分类。首先需要确定去掉波段的最佳数量。在此对两种分类方法每次去掉不同数量的噪声波段后进行全波段分类,分类结果如表 4 和 5 所示。其中,卡帕系数是在综合了用户精度和制图精度两个参数上提出的一个最终指标,简单卡帕系数计算公式如下:

$$x_{\text{Kappa}} = \frac{P_o - P_c}{1 - P_c}, \quad (10)$$

式中 P_o 为观测一致率, P_c 为期望一致率。

表 3 选择的地物类型及样本数

Table 3 Land cover classes and sample numbers for the 6 classes

Land cover types	Number of samples
Corn-notill	1434
Grass-pasture	497
Grass-trees	747
Soybean-notill	968
Soybean-mintill	2468
Woods	1294

表 4 KNN 去掉不同数量噪声波段后全波段分类结果
Table 4 All-bands classification results of KNN after removing different quantities of noise bands

Number of removed bands	Classification accuracy	Kappa coefficient	Classification time /s
0	0.7816	0.7241	17.48
10	0.7928	0.7383	17.41
20	0.7936	0.7391	17.63
30	0.7945	0.7399	16.03
40	0.7975	0.7441	18.24
50	0.8001	0.7476	15.52
60	0.8062	0.7553	14.96
70	0.8043	0.7531	14.95
80	0.8014	0.7493	14.72

由表 4、表 5 可知,去掉一定数量的噪声波段相比未去噪可以提高分类精度,对于 SVM 还可缩短分类时间。在 KNN 和 SVM 中,分别去掉 60 波段和 40 波段可以达到最大分类精度,由此可确定两种分类算法去掉噪声波段的最佳数量为 60 和 40 波段。为了进一步提高效率,将进行有波段选择的分类,所用的波段选择方法分别为 R-LP、R-LP-MI、R-LP-KL 和 O-LP、O-LP-MI、O-LP-KL 算法,并以 60 和 40 为

KNN 和 SVM 算法中去掉噪声波段的数量。

表 5 SVM 去掉不同数量噪声波段后全波段分类结果
Table 5 All-bands classification results of SVM after removing different quantities of noise bands

Number of removed bands	Classification accuracy	Kappa coefficient	Classification time /s
0	0.8615	0.8245	462.6
10	0.8873	0.8571	450.0
20	0.8921	0.8634	430.8
30	0.8999	0.8730	402.6
40	0.9021	0.8760	374.6
50	0.8997	0.8731	374.0
60	0.8966	0.8691	347.1
70	0.8949	0.8670	334.5
80	0.8928	0.8643	272.8

两种分类方法去掉最佳数量噪声波段后分类精度随选择波段数量变化曲线如图 3、图 4 所示,各种分类方法选择波段时间随选择波段数变化关系曲线如图 5 所示。

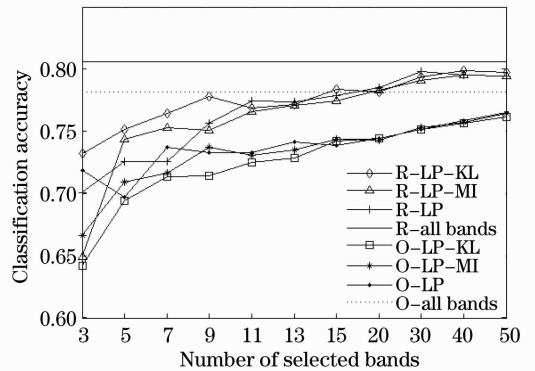


图 3 各种波段选择算法选择波段数与分类精度关系曲线 (KNN)

Fig. 3 Relation curves of number of selected bands and classification accuracy using various band selection algorithms (KNN)

由图 3~5 可知,在 SVM 和 KNN 两种分类算法的实验结果中,三种波段选择算法在去掉噪声波段后相比未去噪直接波段选择,分类精度都有所提高,波段选择时间也有所缩短,并且由于 SVM 分类时间随波段数减少而缩短,KNN 分类时间受波段数影响不大,所以去噪后波段选择与分类的总时间也将明显缩短。三种波段选择算法相比较,两种分类算法中 LP-MI 和 LP-KL 都可以达到比原始 LP 算法高的分类精度,且都在选择 40 波段时分类精度达到最高,而波段选择时间比原始 LP 算法短,而且随着选择波段数增多,波段选择时间相比原始 LP 算法缩短得越来越明显。由此可证明 R-LP-MI 和




图 4 各种波段选择算法选择波段数与分类精度关系曲线(SVM)

Fig. 4 Relation curves of number of selected bands and classification accuracy using various band selection algorithms (SVM)

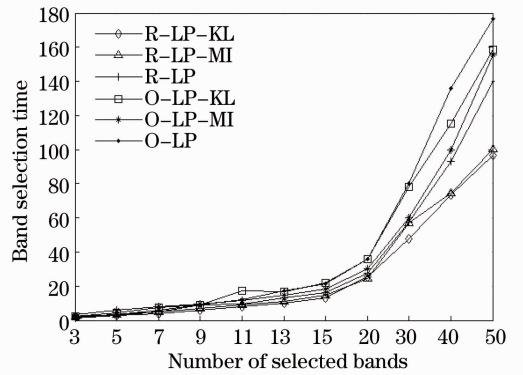


图 5 各种波段选择算法选择波段数与波段选择时间的关系曲线

Fig. 5 Relation curves of number of selected bands and classification time using various band selection algorithms

R-LP-KL 两种波段选择方法对高光谱图像分类的有效性。

3.2 高光谱遥感图像解混实验

采用由 AVIRIS 成像光谱仪拍摄于美国内华达州 Cuprite 地区的高光谱矿物图像^[34]做解混实验,并将图像中十种主要的矿物端元作为参考端元,分别为绿脱石、明矾石、白云母、蓝线石、钙铁榴石、高岭石、镁铝榴石、水铍长石、胶岭石和楣石。

解混过程采用应用广泛的非负矩阵分解(NMF)^[35]算法,输入数据分别为去噪后波段选择数据,直接波段选择数据与全波段数据。经多次实验的结果比较,选取去掉波段数 60,选择波段数 50 作为实验参数。三种波段选择算法对于明矾石的解混效果如图 6 所示。表 6 为三种算法的重构误差的对比数据,表 7 列举了每种端元的估计结果与参考数据的光谱角距离(SAD)及其平均值的对比数据,重构误差与 SAD 的大小可以反映高光谱图像解混的精度。




图 6 三种波段选择算法对明矾石的解混效果曲线。(a) LP-KL; (b) LP-MI; (c) LP

Fig. 6 Unmixing result curves of muscovite got by three band selection algorithms. (a) LP-KL; (b) LP-MI; (c) LP

表 6 各波段选择算法解混重构误差(AVIRIS Cuprite 高光谱数据)

Table 6 Unmixing reconstruction error got by various band selection algorithms (AVIRIS Cuprite dataset)

Band selection algorithm	R-LP-MI	O-LP-MI	R-LP-KL	O-LP-KL	R-LP	O-LP	All bands
Reconstruction error	0.0297	0.0304	0.0306	0.0307	0.0303	0.0308	0.0298

由图 6 可以看出,三种波段选择算法的解混结果曲线相差不大,均接近于真实端元光谱,且去噪的结果比未去噪结果更接近真实光谱。由表 6、7 的实

验结果可以看出,去噪后的波段选择算法不损失全波段的解混精度,而未去噪直接波段选择解混精度有所降低,而且因为去噪缩小了数据源,会缩短波段

选择时间,所以去除噪声波段是有效的。并且由于上节实验验证了 LP-KL 和 LP-MI 两种算法相对于原始 LP 算法的高效性,在此可进一步得出结论:R-

LP-KL 和 R-LP-MI 两种波段选择算法对于高光谱遥感图像解混是有效的。

表 7 各波段选择算法每种端元光谱的 SAD 解混指标(AVIRIS Cuprite 高光谱数据)

Table 7 Unmixing SAD indexes of every endmember got by various band selection algorithms (AVIRIS Cuprite dataset)

Endmember	R-LP-MI	O-LP-MI	R-LP-KL	O-LP-KL	R-LP	O-LP	All bands
Nontronite	0.1743	0.2998	0.3528	0.1620	0.1489	0.3634	0.3591
Alunite	0.1341	0.1044	0.2187	0.2089	0.2004	0.2184	0.2157
Muscovite	0.1725	0.1699	0.0934	0.0964	0.0967	0.1393	0.0945
Dumortierite	0.1441	0.2382	0.1549	0.1408	0.1351	0.0983	0.1580
Andradite	0.1396	0.1098	0.2130	0.1362	0.1348	0.2094	0.2475
Kaolinite	0.0642	0.1119	0.1396	0.0696	0.0525	0.1618	0.1852
Pyrope	0.0208	0.0179	0.1025	0.0779	0.0684	0.0999	0.1077
Buddingtonite	0.0561	0.0839	0.0316	0.0318	0.0318	0.0231	0.0822
Montmorillonite	0.0373	0.0669	0.0322	0.1360	0.0667	0.0252	0.0693
Sphene	0.0305	0.0185	0.0659	0.0351	0.0332	0.0588	0.1529
Average	0.1668	0.1774	0.1786	0.1918	0.1538	0.1834	0.1798

4 结 论

提出了一种有效的高光谱图像波段选择方法,先基于小波域的熵估计每波段的噪声,去除噪声较大的波段后,再采用改进的线性预测波段选择算法 LP-KL 和 LP-MI 进行波段选择,对原始 LP 算法的初始波段的确定和后续波段的选择都进行了改进。实验结果表明,该方法一方面减弱了噪声波段对高光谱遥感图像处理的不利影响,相比直接波段选择提高了其分类或解混的精度和效率,另一方面,改进的波段选择算法相比原始的线性预测算法提高了波段选择效率。该方法逻辑明确,易于实施,是一种有效的高光谱图像降维方法。

该方法不足之处主要在于不能自动确定去除噪声波段和选择波段数量的最优值,将来的工作重点放在提高算法的智能性,进一步提高高光谱图像处理的精度和效率。

参 考 文 献

- 1 C-I Chang. Hyperspectral Imaging: Techniques for Spectral Detection and Classification[M]. New York: Plenum, 2003.
- 2 A R Webb. Statistical Pattern Recognition (2nd edition) [M]. Wang Ping, Yang Peilong Transl.. Beijing: Electronic Industry Press, 2004.
- 3 A R Webb. 统计模式识别(第二版)[M]. 王 萍, 杨培龙译. 北京: 电子工业出版社, 2004.
- 4 Tang Guoan, Zhang Youshun, Liu Yongmei. Remote Sensing Digital Image Processing [M]. Beijing: Science press, 2004.
- 5 汤国安, 张友顺, 刘咏梅. 遥感数字图像处理[M]. 北京: 科学出版社, 2004.
- 6 J H Friedman, J W Tukey. A projection pursuit algorithm for exploratory data analysis[J]. IEEE Trans Computers, 1974, 23(9): 881-889.

- 5 S Serpico, L Bruzzone. A new search algorithm for featureselection in hyperspectral remote sensing images[J]. IEEE Trans Geosci Remote Sens, 2001, 39(7): 1360-1367.
- 6 F Melgani, L Bruzzone. Classification of hyperspectral remote sensing images with support vector machines[J]. IEEE Trans Geosci Remote Sens, 2004, 42(8): 1778-1790.
- 7 Yuan Jinsha, Zhao Zhenbing, Gao Qiang, et al.. Review and prospect on infrared /visible image registration[J]. Laser & Infrared, 2009, 39(7): 693-699.
- 8 苑津莎, 赵振兵, 高 强, 等. 红外与可见光图像配准研究现状与展望 [J]. 激光与红外, 2009, 39(7): 693-699.
- 9 Zhang Jinhong. Optimal Band Selection Methods of Hyperspectral Remote Sensing Data [D]. Nanjing: Nanjing University of Information Science and Technology, 2005.
- 10 杨金红. 高光谱遥感数据最佳波段选择方法研究[D]. 南京: 南京信息工程大学, 2005.
- 11 Wang Guoming, Sun Lixin. Wareband selection in optimized classification of high-spectrum RS imagery [J]. Northeast of Surveying and Mapping, 1999, 22(4): 21-23.
- 12 王国明, 孙立新. 高光谱遥感影像优化分类波段选择[J]. 东北测绘, 1999, 22(4): 21-23.
- 13 Zhang Yamei. Spectrum characteristics of surface features reflection and high spectral imaging remote sensing [J]. Electro-Optic Technology Application, 2008, 23(5): 6-11.
- 14 张亚梅. 地物反射波谱特征及高光谱成像遥感[J]. 光电技术应用, 2008, 23(5): 6-11.
- 15 P W Mausel, W J Kramver, J K Lee. Optimum band selection for supervised classification of multispectral data [J]. Photogrammetric Engineering and Remote Sensing, 1990, 56: 55-60.
- 16 Cheng Hong, Wang Zhiqiang, Zhang Yaoyu. Research on geometric rectification of aerial images[J]. J Northeast Normal University, 2009, 41(3): 50-54.
- 17 Wu Chao, Wu Yiquan. Target detection in hyperspectral image using projection pursuit based on chaotic particle swarm optimization [J]. Acta Optica Sinica, 2011, 31(12): 1211003.
- 18 吴 超, 吴一全. 基于混沌粒子群优化投影寻踪的高光谱图像目标检测[J]. 光学学报, 2011, 31(12): 1211003.
- 19 Qian Du, He Yang. Similarity-based unsupervised band selection for hyperspectral image analysis [J]. IEEE Geoscience and Remote Sensing Letters, 2008, 5(4): 564-568.

- 15 Zhao Xuanmin, Xu Wei, Shi Yimin, *et al.*. Mathematical Statistics [M]. Beijing: Beijing Science and Technology Press, 2003.
- 赵选民, 徐伟, 师义民, 等. 数理统计 [M]. 北京: 北京科学出版社, 2003.
- 16 C Cachin. An information theoretic model for steganography[C]. LNCS: 2nd Int'l Workshop on Information Hiding, 1998, 1525: 306—318.
- 17 T M Cover, J A Thomas. Elements of Information Theory[M]. New York: Wiley-Interscience, 1991.
- 18 Q Du. Band selection and its impact on target detection and classification in hyperspectral image analysis [C]. IEEE Workshop on Advances in Techniques for Analysis of Remotely Sensed Data, 2003: 374—377.
- 19 S Jia, Z Ji, Y Qian, *et al.*. Unsupervised band selection for hyperspectral imagery classification without manual band removal[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2012, 5(2): 531—543.
- 20 Chen Cong, Lu Qipeng, Peng Zhongqi. Preprocessing methods of near-infrared spectrum based on NLMS adaptive filtering[J]. Acta Optica Sinica, 2012, 32(5): 0530001.
- 陈丛, 卢启鹏, 彭忠琦. 基于NLMS自适应滤波的近红外光谱去噪处理方法研究[J]. 光学学报, 2012, 32(5): 0530001.
- 21 Fu Qiang, Xiangli Bin, Jing Juanjuan. System signal-to-noise ratio analysis based on imaging chain model in multispectral remote sensing [J]. Acta Optica Sinica, 2012, 32(2): 0211001.
- 付强, 相里斌, 景娟娟. 基于多光谱遥感成像链模型的系统信噪比分析[J]. 光学学报, 2012, 32(2): 0211001.
- 22 Liu Xuesong, Ge Liang, Wang Bin. An unsupervised band selection algorithm for hyperspectral imagery based on maximal information [J]. Infrared and Millimeter Wave Technology, 2012, 31(2): 166—176.
- 刘雪松, 葛亮, 王斌. 基于最大信息量的高光谱遥感图像无监督波段选择方法[J]. 红外与毫米波学报, 2012, 31(2): 166—176.
- 23 Li Tianyi, Wang Minghui, Chang Huawen, *et al.*. An entropy-based estimation of noise variance in wavelet domain [J]. Journal of Beijing University of Posts and Telecommunications, 2011, 34(5): 1—5.
- 李天翼, 王明辉, 常化文, 等. 基于熵检测的图像噪声方差小波域估计[J]. 北京邮电大学学报, 2011, 34(5): 1—5.
- 24 D Donoho, I M Johnstone. Ideal spatial adaptation by wavelet shrinkage[J]. Biometrika, 1994, 81(3): 425—455.
- 25 Y Zhou, X Li, J Cui. High-efficiency hyperspectral unmixing based on band selection [C]. Third Global Congress on Intelligent Systems, 2012: 140—143.
- 26 Gao Lianru, Zhang Bing, Zhang Xia. Study on the method for estimating the noise in remote sensing images based on local standard deviations [J]. J Remote Sensing, 2007, 11(2): 201—208.
- 高连如, 张兵, 张霞. 基于局部标准差的遥感图像噪声评估方法研究[J]. 遥感学报, 2007, 11(2): 201—208.
- 27 C E Shannon. A mathematical theory of communication [J]. Bell System Tech Journal, 1948, 27: 379—423, 623—656.
- 28 Lin Zhemin, Kang Xuelei, Zhang Liming. EM algorithm for estimating the noise deviation of the image in the wavelet domain [J]. Infrared and Millimeter Wave Technology, 2001, 20(3): 199—202.
- 林哲民, 康学雷, 张立明. 小波域中进行图像噪声方差估计的EM方法[J]. 红外与毫米波学报, 2001, 20(3): 199—202.
- 29 AVIRIS NW Indiana's Indian Pines 1992 Data Set. [Online]. Available: <https://engineering.purdue.edu/biehl/MultiSpec/hyperspectral.html>.
- 30 F Melgani, L Bruzzone. Classification of hyperspectral remote sensing images with support vector machines[J]. IEEE Trans Geosci Remote Sens, 2004, 42(8): 1778—1790.
- 31 Zhao Chunhui, Qi Bin, Zhang Yan. Hyperspectral image classification based on variational relevance vector machine [J]. Acta Optica Sinica, 2012, 32(8): 0828004.
- 赵春晖, 齐滨, 张焱. 基于改进型相关向量机的高光谱图像分类[J]. 光学学报, 2012, 32(8): 0828004.
- 32 Chong Wei, Sha Yizhuo, Xing Hongyan, *et al.*. A new correction algorithm for diffuse irradiance measured with rotating shadow-band pyranometer based on support vector regression [J]. Acta Optica Sinica, 2012, 32(1): 0112001.
- 崇伟, 沙奕卓, 行鸿彦, 等. 一种基于支持向量机回归的旋转遮光带日射表散射辐照度修正新算法[J]. 光学学报, 2012, 32(1): 0112001.
- 33 T Cover, P Hart. Nearest neighbor pattern classification[J]. IEEE Trans Inf Theory, 1967, 13(1): 21—27.
- 34 J P Hoffbeck, D A Landgrebe. Classification of remote sensing images having high spectral resolution [J]. Remote Sensing of Environment, 1996, 57(3): 119—126.
- 35 D D Lee, H S Seung. Learning the parts of objects by non-negative matrix factorization [J]. Nature, 1999, 401(6755): 788—791.

栏目编辑: 李文喆