

文章编号: 1672-8785(2013)02-0027-08

Hyperion 高光谱影像波段选择方法比较研究

孙 华^{1,2} 鞠洪波² 张怀清² 林 辉¹ 刘 华² 凌成星² 符利勇²

(1. 中南林业科技大学林业遥感信息工程研究中心, 湖南长沙 410004 ;

2. 中国林业科学研究院资源信息研究所, 北京 100091)

摘要: Hyperion 影像的光谱分辨率高, 数据体积庞大, 而且相邻波段之间的相关性强, 信息冗余度较高, 给数据处理与解译带来了很多问题。鉴于此, 提出了通过将分段主成分分析和波段指数相结合来开展波段选择与降维研究的思想。同时采用自适应波段选择法、波段指数法和主成分分析累计贡献率方法进行了波段选择方法的对比研究; 对 4 种波段选择方法所得到的结果进行了最佳波段组合、地物可分性和图像变换比较分析。实验结果表明, 分段主成分分析与波段指数综合方法可以有效抑制由于全局变换造成局部重要光谱被滤除的现象, 同时还可兼顾自适应分区后各子区间及区间内波段之间的相关性, 有效降低高光谱数据的维度。由此可见, 该方法的波段选择效果优于传统的自适应波段选择方法、波段指数法以及主成分分析累计贡献率方法。

关键词: 高光谱遥感; 数据降维; 分段主成分分析; 自适应波段选择法; Hyperion

中图分类号: TP751 **文献标识码:** A **DOI:** 10.3969/j.issn.1672-8785.2013.02.005

Comparison of Band Selection Methods for Hyperion Image Data

SUN Hua^{1,2}, JU Hong-bo², ZHANG Huai-qing², LIN Hui¹, LIU Hua², LING Cheng-xing², FU Li-yong²

(1. Research Center of Forestry Remote Sensing & Information Engineering, Central South

University & Technology, Changsha 410004, China; 2. Research Institute of Forest

Resources Information Technique, Chinese Academy of Forestry, Beijing 100091, China)

Abstract: Hyperion images have the features of high spectral resolution, large quantity of data, strong correlation among adjacent bands and high information redundancy. These features have brought many problems to the data processing and interpretation of them. To solve these problems, an idea of band selection and dimensionality reduction by combining the segmented principal component analysis with the band index algorithm is proposed. The adaptive band selection method, band index method and cumulative contribution rate method are used to carry out a comparative study in band selection. The results obtained by four band selection methods are analyzed in optimal band combination, feature reparability and image transformation. The experimental results show that the segmented principal component analysis and band index algorithm can not only restrain the phenomenon that some local important spectra may be filtered due to the global transformation, but also can take into account the adaptive partition subinterval correlation among the bands and effectively reduce the hyperspectral data dimension. The method is better than the traditional adaptive band selection method, band index method and cumulative contribution rate method in band selection.

收稿日期: 2012-12-08

基金项目: 国家重大专项(E0305/1112/02); 十二五“国家高技术研究发展计划(863 计划)”课题(2012AA102001)

作者简介: 孙华(1979-), 男, 湖南隆回人, 讲师, 博士, 主要研究方向为遥感图像分析与森林资源监测。

E-mail: sunhuayiwen@126.com

Key words: hyperspectral remote sensing; dimension reduction; segmented principal component analysis; adaptive band selection; Hyperion

0 引言

高光谱遥感技术是当前遥感研究领域的前沿和热点, Hyperion 数据则是成像高光谱数据中的典型代表, 其在 $0.4 \sim 2.5 \mu\text{m}$ 光谱范围内共有 242 个波段。与传统的光学遥感影像相比, Hyperion 数据的光谱分辨率可以达到纳米级, 它包含了更为丰富的地物信息, 在目标地物识别与变化检测方面具有独特的优势^[1], 因而已被广泛应用于农业、林业、环境以及军事等各个领域。但是其波段多、光谱分辨率高以及数据量大的优点却会给数据的存储、传输和处理带来很多问题^[2-3], 导致传统的图像分析与处理技术对其已经不再适用。因此, 在用高光谱数据进行处理之前, 需要采用特定的算法对数据进行降维, 保留用于分析的重要信息, 去除大量的冗余数据, 从而将高维数据变换到有意义的低维空间以形成新的图像^[4-6]。

近年来, 关于高光谱图像降维与波段选择的研究不断增多。通过归纳可以将其分成特征提取和特征选择两类。其中, 特征选择是依据某种准则从原始特征中选出部分最能反映类别区分统计特性的相关特征的^[7]。一般通过计算影像的熵、协方差矩阵、波段指数以及最佳指数^[8-9], 并在此基础上求出各种地物类别的统计距离, 从原始特征空间中直接选出包含主要信息的特征来构成新的子集^[10], 使得被选的光谱子集能够有效地用于地物类型识别。基于主成分变换的波段选择方法和基于类间可分性^[11]的波段选择方法是多种特征选择方法中的代表。这类依据不同需要通过从原始波段中选出最具代表意义的波段子集来实现数据降维的方法, 虽然最大程度地保留了原始图像的信息, 但是其计算过程复杂, 效率较低。然而, 光谱特征提取则是以严密的数学理论为依据, 通过将高维空间中的信息映射到低维空间中来实现降维的。主成分分析变换^[12-13]、基于投影寻踪的特征提取^[14]以及基于决策边界的特征提取^[15-16]是其中

几种常用的转换方法。完成光谱特征提取后, 原始数据的光谱信息将会遭到破坏, 甚至可能会造成部分信息丢失。鉴于传统的光谱特征提取方法会使波段光谱的原始物理意义发生改变, 一些研究人员提出用基于主成分分析的特征提取方法^[17-18]和基于分段主成分分析的特征提取方法^[19-20]来实现高光谱数据的降维与波段选择。此类方法仅需计算原始数据的协方差矩阵与均值, 而并非是对原始图像进行真正意义上的主成分变换。这样不仅可以大大降低计算程度, 而且还可以保留原始波段的光谱意义。但是在这类分析中, 局部重要光谱波段可能会被滤除掉, 从而影响图像的分类精度。

综上所述, 现有的研究成果大多注重通过单个方法的纵向独立分析来实现高光谱数据的降维与波段选择, 而综合利用特征选择和特征提取的方法却较少, 缺乏不同方法之间的横向对比。鉴于此, 本文以 Hyperion 影像为研究对象, 利用基于分段主成分分析和波段指数的综合方法开展波段选择等相关试验研究, 同时采用自适应波段选择方法、波段指数法和主成分分析累计贡献率方法进行对比分析, 为 Hyperion 等高光谱数据的进一步处理与研究提供支撑。

1 材料与方法

1.1 实验数据

为了更好地体现和比较不同波段选择方法的优缺点, 我们选择湖南省东洞庭湖作为研究对象, 开展 Hyperion 高光谱数据降维方法比较研究。Hyperion 数据的空间分辨率为 30 m, 所用星载高光谱影像为 Hyperion 影像的 L1G 数据, 影像的成像时间为 2006 年 8 月 14 日。图 1 所示为研究区域的 Hyperion 数据中的一个 256×256 大小的子块影像数据立方体(由 53、150、17 波段的假彩色合成)。

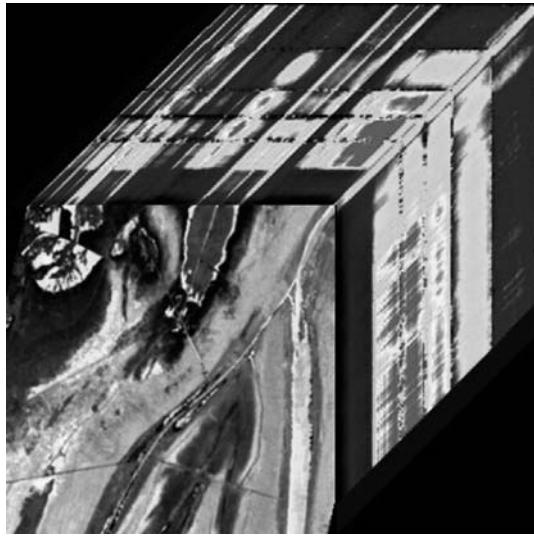


图 1 Hyperion 影像数据立方体

1.2 自适应波段选择方法

自适应波段选择方法充分考虑了各波段的空间相关性和谱间相关性以及每幅图像的信息富集程度与相邻波段的相似性^[8]。波段指数按大小顺序排列。可以根据需要选择排序在前 N 个的波段组合。计算公式如下：

$$I_i = S_i / [(R_{i-1,i} + R_{i,i+1})/2] \quad (1)$$

式中, S_i 为第 i 个波段的标准差; $R_{i-1,i}$ 和 $R_{i,i+1}$ 为第 i 个波段与其前后两个波段之间的相关系数; I_i 为第 i 个波段的指数大小。

1.3 主成分分析累计贡献率方法^[18,21]

用一个 P 维随机变量 (X) 表示原始遥感数据, 那么对于高光谱影像,

$$X = (x_1, x_2, \dots, x_N) = (X_1, X_2, \dots, X_P) \quad (2)$$

式中, N 为高光谱影像的像元数目; P 为波段数目; $x_i (i = 1, 2, \dots, N)$ 为影像的第 i 个像元; $X_k (k = 1, 2, \dots, P)$ 为图像的第 k 个波段。主成分分析累计贡献率方法的具体步骤如下:

(1) 首先计算原始数据的均值向量 (M), 然后依据均值向量求出协方差矩阵:

$$M = \frac{1}{N} \sum_{i=1}^N x_i \quad (3)$$

$$\sum_x = E \{(X - M)(X - M)^T\} \quad (4)$$

式中, 协方差矩阵 \sum_x 的无偏估计为

$$\sum_x = \frac{1}{p-1} \sum_{j=1}^p (X_j - M)(X_j - M)^T \quad (5)$$

(2) 计算协方差矩阵 \sum_x 的特征根 $\lambda_1, \lambda_2, \dots, \lambda_p$ ($\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p$) 以及相应特征根的单位特征向量 $t_1, t_2, t_3, \dots, t_p$ 。

(3) 用 $A = T^T$ 表示变换矩阵, 对原始数据 X 进行主成分变换。变换后的数据用 Y 表示, 则主成分变换的形式为

$$Y = (Y_1, Y_2, \dots, Y_p)^T = AX \quad (6)$$

式中, A 为主成分变换矩阵。 A 的设计必须满足: Y_1, Y_2, \dots, Y_p 之间不相关, 而且它们的方差要尽可能大。 Y 的分量 Y_1, Y_2, \dots, Y_p 依次是矩阵 X 的第一主成分、第二主成分、…、第 P 主成分的充要条件为

$$A = T^T = (t_1, t_2, \dots, t_p) \quad (7)$$

式中, T 为正交矩阵。

(4) 给定阈值 T_d (比如 0.99), 计算满足阈值 T_d 的 m 值, 即确定主成分的维数:

$$V_m = \sum_{i=1}^m \lambda_i / \sum_{i=1}^P \lambda_i \quad \begin{cases} V_m \geq T_d \\ V_{m-1} < T_d \end{cases} \quad (8)$$

式中, V_m 为主成分 Y_1, Y_2, \dots, Y_m 的累计贡献率; λ_i 为协方差矩阵 \sum_x 的特征根。

(5) 计算 m 个主成分 Y_1, Y_2, \dots, Y_m 对于原始第 i 个波段的贡献率 ν_i , 并选择贡献率 ν_i 在 99.5% 以上的波段作为主成分分析累积贡献率方法的最终波段。

$$\nu_i = \sum_{k=1}^m \rho^2(Y_k, X_i) = \sum_{k=1}^m \lambda_k t_{ik}^2 / \delta_{ii} \quad (9)$$

$$t_{ik} = e_i^T t_k \quad (10)$$

式中, δ_{ii} 为协方差矩阵 \sum_x 对角线上的值; λ_k 为协方差矩阵 \sum_x 的第 k 个特征值; $e_i = (0, \dots, 0, 1, \dots, 0)^T$ 为单位特征向量, 其中第 i 个分量为 1, 其余为 0; t_k 为第 k 个特征向量组。

1.4 波段指数法

由于高光谱数据波段多，而且波段间相关系数矩阵分块现象明显，波段指数分析算法综合考虑波段的信息量和波段间的相关性两个因素，通过波段指数计算，选取均方差大且相关系数小的波段作为整体最优的波段。波段指数的定义为

$$P_i = \frac{S_i}{R_i} \quad (11)$$

设 ρ_{ij} 为波段 i 与波段 j 之间的相关系数，高光谱数据被分为 k 组，每组的波段数分别为 n_1 、 n_2 、 \dots 、 n_k 。

$$R_i = R_w + R_\alpha, \quad R_w = \frac{1}{n_k} \sum_{j=1}^{n_k} \rho_{ij} \quad (i \neq j) \quad (12)$$

式中， S_i 为波段图像的亮度标准差； R_w 为第 i 波段与所在组内其他波段相关系数的绝对值之和的平均值； R_α 为第 i 波段与所在组以外的其他波段之间的相关系数的绝对值之和^[11]。

1.5 分段主成分分析与波段指数综合方法

分段主成分分析与波段指数综合方法的思路是，首先按照波段相关性的大小将原始波段的数据划分为不同的波段子集 N_1, N_2, \dots, N_S ；然后给定一个阈值 T_d （比如 0.99），并确定每个波段子集的固有维数 m （见式（8）），即主成分个数；接着计算 m 个主成分 Y_1, Y_2, \dots, Y_m 对于原始第 i 个波段的贡献率（见式（9））。在每个分段内，选择贡献率 ν_i 在 99.5% 以上的波段作为每个分段的波段子集 n_1, n_2, \dots, n_S ，每个波段子集选出的波段可能仍有相关性较大的波段存在；利用式（11）计算每个子集中所有备选波段的波段指数，选择每个子集内的波段指数极大值所对应的波段作为每个子集内的最优波段，从而弥补原始数据在分段时产生的误差。

2 结果与分析

2.1 自适应子空间划分

利用 ENVI 软件的 FLAASH 模块对影像进行大气校正，以尽可能地恢复影像的本来面目。通过大气校正去掉了一些由于受大气等因素的影响而不可使用的波段，最终保留了 150 个波段，

以便用于图像分析。为了更好地从 Hyperion 数据中提取出有效的光谱特征，我们计算了影像的相关系数矩阵图（见图 2）。可以看出，相关系数矩阵存在明显的分块效应。150 个波段影像数据被自动分成了 4 个具有不同维数的子空间。每个子空间内影像数据的相关系数在 0.9 以上，说明它们具有相近的光谱特性。表 1 列出了每个子空间所对应的波段名称。子空间划分完成后，波段特征提取和特征选择处理都将在子区间内完成。

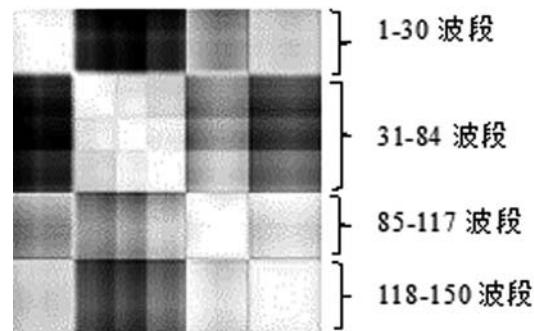


图 2 Hyperion 图像的相关系数矩阵

表 1 子区间自动划分结果

子区间	波段范围	对应原始波段的名称
N1	1 ~ 30	8 ~ 37
N2	31 ~ 84	38 ~ 57, 82 ~ 96, 101 ~ 119
N3	85 ~ 117	134 ~ 164, 183 ~ 184
N4	118 ~ 150	188 ~ 220

2.2 波段选择结果的比较

我们对经过大气校正后的 150 波段 Hyperion 影像进行了波段选择实验。表 2 给出了利用自适应波段选择方法、波段指数法、主成分分析累计贡献率方法以及分段主成分分析与波段指数综合分析法等 4 种方法选出的前 10 个波段所对应的 242 个原始波段中的名称。图 3 所示为利用上述方法选出的前 3 个波段的图像。

从表 2 中可以看出，用自适应波段选择方法选出的前 10 个波段集中在整个波段范围的中间部分，所选波段相对集中，主要分布在 993.17 ~ 1063.79 nm 范围内。这个区间为近红外区间，各波段之间的标准差和信息熵较大。对于 Hyperion 影像的光谱区间来说，光谱特征区间相同，地

表 2 用不同方法选出的波段结果

波段选择方法	选出的前 10 个波段的名称
自适应波段选择法	52, 53, 85, 86, 87, 88, 89, 90, 91, 92
主成分分析累计贡献率方法	42, 43, 44, 45, 49, 50, 51, 82, 119, 219
波段指数法	10, 31, 42, 53, 91, 110, 150, 164, 192, 216
分段主成分与波段指数综合方法	17, 31, 42, 53, 86, 91, 110, 150, 196, 203

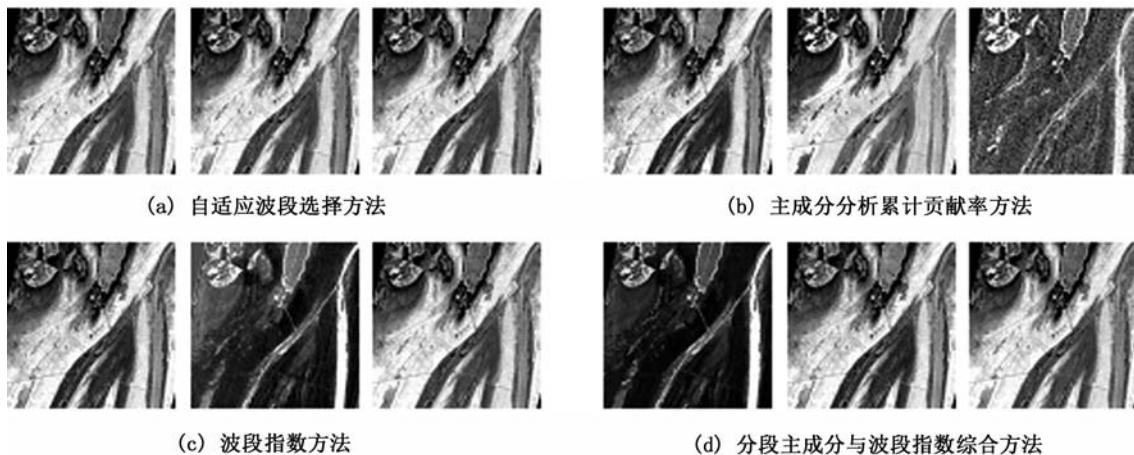


图 3 用不同波段选择方法选出的前 3 个波段的影像

物信息的灰度分布相似, 波段间的冗余信息较多。用主成分分析累计贡献率方法得到的结果与用自适应波段选择法得到的结果相似, 其选出的 10 个波段中有 7 个为相邻的连续波段。波段指数法和分段主成分与波段指数综合方法都考虑了高光谱图像各波段数据之间的局部相关性, 即将整个数据自动划分为若干个具有较强相关性的独立子空间, 然后根据各自的需求在每个子空间内开展波段选择工作。用这两种方法选出的波段分布比较广泛, 远离成像光谱仪工作范围的端点, 因此其数据具有较高的利用价值。它们所选的波段涵盖了可见光、近红外和短波红外范围, 覆盖面较广, 而且这些波段具有较高的相似性, 前 10 个波段中就有 6 个相同的波段。以上结果表明, 这两种方法可以有效抑制由于全局变换造成局部重要光谱被滤除的现象, 同时还可兼顾自适应空间划分后各子区间及区间内波段之间的相关性, 从而有效降低高光谱数据的维度。

从图 3 中可以看出, 用自适应波段选择方法选出的前 3 个波段图像的灰度分布相似, 波段之

间的冗余信息较大, 其原因主要是自适应波段选择方法是一种基于信息量的波段选择法。由于成像光谱仪的工作特性, 在一定光谱范围内的波段除了波段间的相关系数较高之外, 波段间均具有较大的信息量。对于按照波段指数大小排列方法选择波段的自适应波段选择方法来说, 一些信息量小却包含不同地物信息的局部光谱波段被排除在外。用这种方法挑选的波段不利于图像的后续融合与分析。用主成分分析累计贡献率方法选出的前 3 个波段虽然存在较大差异, 但是其图像质量一般, 尤其是第 3 个波段存在噪声干扰现象; 用波段指数法和分段主成分与波段指数综合方法选出的波段相对较好, 尤其是用分段主成分与波段指数综合方法选出的前 3 个波段涵盖了不同的特征范围, 分别对应于原始波段的 band31、band91 和 band196, 而且波段之间的互补性较好, 纹理信息表现丰富。

2.3 地物可分性分析

为了更好地表达 Hyperion 影像的信息, 我们对用 4 种不同波段选择方法筛选出的 10 个波

段进行分析，然后选出最佳波段组合。在确定最佳组合的基础上，利用 Jeffreys-Matusita (简称 J-M) 距离开展地物可分性分析。

选择图像的熵、标准差以及图像清晰度^[22]作为波段信息量的评价指标，并在此基础上通过计算波段间的相关系数、联合熵和最佳指数^[3]来确定 Hyperion 影像(不同) 波段选择方法的最佳波段组合(结果见表 3)。从信息量的角度来看，自适应波段选择方法所对应的波段的信息量最大，波段指数法和分段主成分与波段指数综合方法次之。用自适应波段选择方法得到的 3 个波段的光谱范围相近，波段间的相关系数超过 0.993，其余 3 种波段组合所得波段之间的相关系数较小，均在 0.9 以下。

表 3 Hyperion 影像的最佳波段组合结果

波段选择方法	最佳组合波段
自适应波段选择法	86, 89, 91
主成分分析累计贡献率方法	51, 119, 219
波段指数法	10, 53, 91
分段主成分与波段指数综合方法	31, 91, 196

对于不同的地表特征和研究区域，最佳波段组合也不是绝对的。因此，在实践中，我们应当在基于信息量统计出最佳组合的基础上，针对特定的样本进行地物可分性分析，从而进一步确定波段的最佳组合方式。本文以水、芦苇以及苔草 3 种地类为例，用 J-M 距离判定方法筛选出对 3 种地类均具有最佳分离性质的波段组合。表 4 列出了不同波段组合的 J-M 距离。可以看出，所有波段组合对于水、芦苇和苔草的可分性都比较好，其 J-M 距离均在 1.99 以上。其中，

主成分分析累计贡献率方法与自适应波段选择方法的波段组合对苔草和芦苇的可分性较差一些。总体来讲，band31、band91 和 band196 的波段组合对于苔草-芦苇、水-苔草和水-芦苇的可分性效果最佳。结合表 2 可知，分段主成分与波段指数综合方法在 4 种波段选择方法中是最优的。

表 4 不同波段组合对水、苔草和芦苇的 Jeffreys-Matusita 距离

波段组合	苔草-芦苇	水-苔草	水-芦苇
31, 91, 196	1.999999	2.000000	2.000000
10, 53, 91	1.999853	2.000000	2.000000
86, 89, 91	1.999996	1.994721	1.999275
51, 119, 219	1.999009	1.994702	1.999999

2.4 图像变换效果评价

对上述 4 种波段选择方法得到的 10 个波段分别进行主成分变换分析，以更好地评价不同波段选择方法所选波段对图像变换效果的影响，从而为进一步评价 Hyperion 数据选择方法的有效性提供参考。对主成分变换后的前 3 个分量进行彩色组合(其结果见图 4)。从图 4 中可以看出，分段主成分与波段指数综合方法的前 3 个分量组合图像具有较好的清晰度和对比度，而自适应波段选择方法和主成分分析累计贡献率方法所得的图像组合效果较差，其图像中含有比较明显的噪声干扰。

主成分变换后的前 3 个分量包含了影像的 95% 以上的信息，其中第一分量占据主导地位。为了对变换后的图像质量作进一步对比，我们分别提取 4 种方法主成分变换后的第一分量进



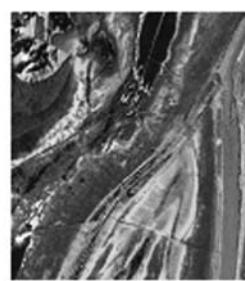
(a) 自适应波段选择方法



(b) 主成分分析累计贡献率方法



(c) 波段指数法



(d) 分段主成分与波段指数综合方法

图 4 不同波段选择方法所选波段的图像变换结果

表 5 不同方法所选波段融合图像的定量评价

评价指标	自适应波段选择法	主成分分析累计贡献率方法	波段指数法	分段主成分与波段指数综合法
标准差	59.1697	59.8191	59.9653	61.0472
熵	0.1306	0.1318	0.1308	0.1501
清晰度	0.0055	0.0056	0.0058	0.0058

行熵、标准差以及清晰度的定量计算。其中，清晰度反映的是图像对微小细节的表达能力，可以用平均梯度变化进行评价；标准差和熵是图像的信息量评价指标。标准差和熵越大，说明图像信息量越大；清晰度越大，说明图像清晰度越高，纹理信息越丰富。从表 5 和图 4 中可以看出，分段主成分与波段指数综合方法所选波段的图像质量最好，变换效果最佳。

3 结论与讨论

本文以洞庭湖 Hyperion 数据为例，计算了影像的相关系数矩阵图。根据相关系数矩阵的块状分布，影像被自动分成了 4 个具有不同维数的子空间。我们用自适应波段选择法、主成分分析累计贡献率方法、波段指数法以及分段主成分与波段指数综合方法等 4 种波段选择方法对 Hyperion 数据进行了特征提取和特征选择，然后分别对 4 种方法所选的波段进行地物可分性分析和图像变换效果评价，得出以下结论：

(1) 自适应子空间的划分可以有效抑制由于全局变换造成局部重要光谱被滤除的现象。自适应波段选择方法和主成分分析累计贡献率方法所选波段的灰度信息分布相似，而且波段间的冗余信息较多。其选出的前 10 个波段主要集中在 Hyperion 数据波段范围的近红外区间，而可见光波段没有入选。波段指数法和分段主成分与波段指数综合方法则考虑了可见光波段的重要性。根据影像的相关系数矩阵分块特征，可以将整个数据划分为 4 个独立子空间，然后在每个子区间的基础上进行波段选择。用这两种方法选出的波段涵盖了可见光、近红外和短波红外范围，有效抑制了由于全局变换造成局部重

要光谱被滤除的现象，同时兼顾了自适应空间划分后各子区间及区间内波段之间的相关性，有效降低了高光谱数据的维度。

(2) 在用 J-M 距离判定方法进行地物可分性分析时，4 种方法所选的波段都具有较好的分离性，其 J-M 距离均在 1.99 以上。分段主成分与波段指数综合方法和波段指数法所选的最佳波段组合对于水、芦苇和苔草 3 种地物的可分性相对较好，其中水 - 苔草和水 - 芦苇的可分性指标为 2.0。

(3) 分段主成分与波段指数综合方法是一种较好的波段选择方法。对于 Hyperion 数据等成像光谱数据来说，开展波段选择研究是为了在不丢失重要波段信息的前提下达到减少数据维数的目的。通过对经波段选择后得到的影像进行图像变换和最佳波段组合，可以进一步减少数据量和改善图像质量，有利于后续分析。本文用分段主成分与波段指数综合方法对 Hyperion 高光谱影像进行了波段选择和降维处理，得到的波段组合在地物可分性、图像的清晰度和信息量分析方面都取得了较好的效果，明显优于其他 3 种波段选择方法。需要指出的是，在具体应用中，应针对需求进行综合考虑，选用合适的波段选择方法对高光谱数据进行降维处理，只有这样才能得到令人满意的结果。

参考文献

- [1] 赵春晖, 胡春梅, 石红. 采用选择性分段 PCA 算法的高光谱图像异常检测 [J]. 哈尔滨工程大学学报, 2011, 32(1): 109–113.
- [2] 白嶙, 何明一, 戴玉超. 采用自适应波段分组的高光谱图像压缩算法 [J]. 计算机科学, 2011, 38(6): 275–278.
- [3] 韩瑞梅, 杨敏华. 一种改进的高光谱遥感数据波段选择方法的研究 [J]. 测绘与空间地理信息, 2010, 33(3): 137–139.

- [4] 刘春红, 赵春晖, 张凌雁. 一种新的高光谱遥感图像降维方法 [J]. *中国图象图形学报*, 2005, **10**(2): 218–222.
- [5] 冯燕, 何明一, 宋江红, 等. 基于独立成分分析的高光谱图像数据降维及压缩 [J]. *电子与信息学报*, 2007, **29**(12): 2871–2875.
- [6] Muhammad A, Sungyoung L, Ihsan U H, et al. Hyperspectral Remote Sensing: Dimensional Reduction and End Member Extraction [J]. *International Journal of Soft Computing and Engineering*, 2012, **2**(2): 170–175.
- [7] 高恒振. 高光谱遥感图像分类技术研究 [D]. 长沙: 国防科技大学, 2011.
- [8] 杨金红, 尹球, 周宁. 一种改进的高光谱数据自适应波段选择方法 [J]. *遥感技术与应用*, 2007, **22**(4): 513–519.
- [9] 苏红军, 杜培军, 盛业华. 高光谱影像波段选择算法研究 [J]. *计算机应用研究*, 2008, **25**(4): 1093–1096.
- [10] 郭雷, 常威威, 付朝阳. 高光谱图像融合最佳波段选择方法 [J]. *宇航学报*, 2011, **32**(2): 374–379.
- [11] 陈桂红, 唐伶俐, 姜小光. 高光谱遥感图像特征选择和提取方法的比较 [J]. *干旱区地理*, 2006, **29**(1): 143–149.
- [12] 田野, 赵春晖, 季亚新. 主成分分析在高光谱遥感图像降维中的应用 [J]. *哈尔滨师范大学自然科学学报*, 2007, **23**(5): 58–60.
- [13] Jing Wang, Cheini Chang. Independent Component Analysis-Based Dimensionality Reduction With Applications in Hyperspectral Image Analysis [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2006, **44**(6): 1586–1600.
- [14] Jimenez, Luis O, Landgrebe, et al. Hyperspectral Data Analysis and Supervised Feature Reduction via Projection Pursuit [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 1999, **37**(6): 2653–2667.
- [15] Kambhatla N, Leen R A. Dimension Reduction by Local Principal Component Analysis [J]. *Neural Computation*, 1997, **9**(7): 1493–1516.
- [16] Mathieu F, Jon A B, Jocelyn C, et al. Spectral and Spatial Classification of Hyperspectral Data Using SVMs and Morphological Profiles [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2008, **46**(11): 3804–3814.
- [17] Rui Huang, Mingyi He. Band Selection Based on Feature Weighting for Classification of Hyperspectral Data [J]. *IEEE Geoscience and Remote Sensing Letter*, 2005, **2**(2): 156–159.
- [18] 杨诸胜, 郭雷, 罗欣, 等. 一种基于主成分分析的高光谱图像波段选择算法 [J]. *微电子学与计算机*, 2006, **23**(12): 72–74.
- [19] 杨诸胜, 郭雷, 罗欣, 等. 基于分段主成分分析的高光谱图像波段选择算法研究 [J]. *测绘工程*, 2006, **15**(3): 15–18.
- [20] Qian Du, Wei Zhu, He Yang, et al. Segmented Principal Component Analysis for Parallel Compression of Hyperspectral Imagery [J]. *IEEE Geoscience and Remote Sensing Letters*, 2009, **6**(4): 713–717.
- [21] 赵选民, 徐伟, 师义民, 等. *数理统计* [M]. 北京: 科学出版社, 2002.
- [22] 赵英时. *遥感应用分析原理与方法* [M]. 北京: 科学出版社, 2003.

(上接第 26 页)

达发射源参数的不确定性所引入的 CO₂ 柱线浓度测量误差。在激光频率稳定性为 0.3 MHz、激光线宽为 40 MHz 和光谱纯度为 99.9% 时, 由系统引入的 CO₂ 柱线浓度测量误差分别为 0.1 ppm、0.137 ppm 和 0.08 ppm。该结果为激光源的参数设计提供了重要的参考依据。最后, 本文介绍了我们研制 IPDA 激光雷达激光器的基本方案以及开展 1.572 μm 光学参量振荡器和放大器研究的初步实验结果。结果表明, 输出激光能量能够满足星载平台要求, 为进一步开展相关研究奠定了基础。

参考文献

- [1] Jerome C, Yannig D. Operating Wavelengths Optimization for a Spaceborne Lidar Measuring Atmospheric CO₂ [J]. *Applied Optics*, 2009, **48**: 5413–5422.
- [2] Caron J, Durand Y, Bezy J L, et al. Performance Modeling for A-SCOPE, a Spaceborne Lidar Measuring Atmospheric CO₂ [C]. *SPIE*, 2009, **7479**: 74790E.
- [3] Ehret G, Kiemle C, Wirth N, et al. Space-borne Remote Sensing of CO₂, CH₄, and N₂O by Integrated Path Differential Absorption Lidar: a Sensitivity Analysis [J]. *Applied Physics B*, 2008, **90**: 593–608.
- [4] Syed I, Edward V B. Airborne and Spaceborne Lidar Measurements of Water Vapor Profiles: a Sensitivity Analysis [J]. *Applied Optics*, 1989, **28**(17): 3603–3615.