

基于正交投影散度的高光谱遥感波段选择算法

苏红军^{1,2}, 盛业华^{1*}, Yang He², Du Qian²

1. 南京师范大学虚拟地理环境教育部重点实验室, 江苏南京 210046
2. 密西西比州立大学电子与计算机工程系, Starkville, MS 39759, USA

摘要 由于高光谱数据的海量高维特征, 对其进行降维处理成为高光谱遥感研究的一个重要问题。波段选择算法由于能够有效地保留原始数据的信息, 在高光谱数据降维及后续的遥感识别与分类等方面具有明显的优越性。文章提出了一种基于正交投影散度(OPD)的波段选择方法, 该方法继承了正交子空间投影(OSP)算法的特点, 通过把原始数据投影到特征空间, 实现感兴趣目标与背景噪声的分离; 通过最大化光谱向量之间的相似性测度以及顺序浮动前向搜索(SFFS)算法, 实现快速的波段选择。利用HYDICE和HYMAP高光谱数据进行实验验证, 并与其他传统波段选择算法, 如光谱角度匹配、欧式距离、光谱信息散度和LCMV-BCC等进行对比, 结果表明该算法在高光谱数据波段选择方面具有较好的适用性和鲁棒性, 能够有效地应用于高光谱遥感数据的降维研究。

关键词 波段选择; OPD; 数据降维; 高光谱影像

中图分类号: TP75 文献标识码: A DOI: 10.3964/j.issn.1000-0593(2011)05-1309-05

引言

高光谱遥感能够获取许多非常窄且光谱连续的图像数据, 包含了丰富的空间、辐射和光谱信息。与常规多光谱遥感相比, 高光谱数据具有数据量大、波段多且窄、波段相关性强、信息冗余多、图谱一体化等特征^[1]。一方面, 数据量的急剧增大增加了处理算法的运算量; 另一方面, 波段之间的相关性和冗余信息降低了分类算法的准确度。如何既有效地利用高光谱数据的丰富信息, 又能高效地对其进行处理成为一个难点问题。传统的多光谱遥感数据处理算法在处理高光谱数据时, 常遇到Hughes现象即“维数灾难”^[2]。因此, 对高光谱数据的“降维”就显得尤为重要; 高光谱数据“降维”能够在保留重要信息的同时对原数据进行压缩处理。降维的方法有两种: 一是对所有波段实施某种数学变换, 找出对分类影响最大的特征, 即特征提取; 二是依据一定的判断标准从全部波段中选择感兴趣的若干波段, 即特征(波段)选择。由于特征提取方法改变了原始数据, 一些重要和关键的信息有可能扭曲或者丢失, 另外降维后的数据维数选择依然是个难题。而波段选择算法由于较好地保留了最原始的数据信息,

因此成为高光谱遥感降维的重要研究方向之一, 本文着重探讨高光谱波段选择的新算法。

虽然波段选择算法较好地保留了数据的原始信息, 但是它也存在两个问题: 一是为了保存必需的信息, 如何确定需要选择的波段数目; 二是采用何种判断标准来选择感兴趣的波段。其中第一个问题在文献[3]中得到了较好地解决, 该文提出了用虚拟维度(virtual dimensionality, VD)作为衡量波段数目的指标, 并在高光谱数据分析方面得到了广泛应用^[4,6]。在波段选择的判断标准方面, 近年来提出了众多的算法, 如基于光谱相似性测度的光谱角度匹配(spectral angle mapping, SAM)算法^[7]、欧式距离(euclidean distance, ED)算法^[8]、基于信息论基础的光谱信息散度(spectral information divergence, SID)算法^[9]及最小能量约束的线性约束最小协方差(linearly constrained minimum variance-band correlation constraint, LCMV-BCC)算法^[10]; 另外, 文献[11]提出了基于分形维数的波段选择方法, 而文献[12, 13]则系统地总结了现有的各种波段选择算法。SAM和ED等类似算法的前提是假设光谱值与光照条件呈现线性变化关系, 但是由于在时间、空间及环境条件显著变化而影响光照条件时, 容易产生“同物异谱”和“异物同谱”等现象, 因此基于角度和距离

收稿日期: 2010-04-14, 修订日期: 2010-07-18

基金项目: 国家自然科学基金项目(40901200), 国家留学基金委公派研究生项目(2009686004)和南京师范大学优秀博士论文培育计划项目(1243211601040)资助

作者简介: 苏红军, 1985年生, 南京师范大学虚拟地理环境教育部重点实验室博士生, 南京师范大学与美国密西西比州立大学联合培养博士生 e-mail: hjsurs@163.com * 通讯联系人 e-mail: shengyehua@njnu.edu.cn

© 1994-2012 China Academic Journal Electronic Publishing House. All rights reserved. http://www.cnki.net

特征的类别区分度大大降低。LCMV 虽然增加了最小能量约束,但是由于其为非监督算法,受光谱背景信息的影响比较大,无法达到理想的效果。

为了解决以上问题,本文提出了基于正交投影散度(orthogonal projection divergence, OPD)的波段选择算法,该算法建立在正交子空间投影(orthogonal subspace projection, OSP)的基础上,通过将原始数据投影到其特征空间,能最大化地分离感兴趣目标和背景及噪声信息,并通过计算两个像元光谱向量之间的正交投影残差来表达不同地物光谱向量之间的相似性。最后,在实验部分验证了本文所提算法的适用性和鲁棒性。

1 理论基础

由于遥感空间分辨率及真实地表的复杂性,影像上的像元往往由几种地物组成,称为混合像元,因此高光谱影像在一定程度上符合线性混合模型;该模型假定地物间没有相互作用,每个光子仅能“看到”一种物质,并将其信号叠加到像元光谱中。因此,假定高光谱影像中每个像元 r 都可以近似认为是图像中各个端元的线性混合,即

$$r = M\alpha + n \quad (1)$$

其中 r 为 l 维光谱向量(l 为图像波段数), $M = [m_1, m_2, \dots, m_p]$ 为 $l \times p$ 维的端元光谱矩阵, $\alpha = (\alpha_1, \alpha_2, \dots, \alpha_p)^T$ 为丰度(混合系数)向量, n 为符合独立随机高斯分布的噪声分量,且满足 $E(n) = 0$ 和 $\text{Cov}(n) = \sigma^2 I$ (I 是单位矩阵)。

不失一般性,假定 M 的第一列为感兴趣目标 $d = m_1$, 其余的列为线性独立的背景信号 $U = [m_1, m_2, \dots, m_p]$, 则公式(1)可转化为

$$r = d\alpha_d + U\alpha_u + n \quad (2)$$

公式(2)将公式(1)中的端元矩阵分离为感兴趣的目标信号和背景信号,背景信号又包括端元信号和噪声信号,而相应的丰度含量 α 分为 α_d 和 α_u 。OSP 的目的是尽可能地减弱 U 信号的影响,而最大化感兴趣目标的信息。因此,将 r 投影到 U 的正交子空间,则剩余的信号将只含有与感兴趣目标 d 和随机噪声相关的信息,即

$$P_U^\perp r = I - UU^# \quad (3)$$

其中 $U^# = (U^T U)^{-1} U^T$ 为 U 的伪逆矩阵。将该投影变换 P_U^\perp 作用于待解混的信号,则有

$$P_U^\perp r = P_U^\perp d\alpha_d + P_U^\perp n \quad (4)$$

其中 U 中的背景信息已经被消除,原始的噪声 n 也被压缩到 $P_U^\perp n$ 中,这就是应用广泛的 OSP 模型^[14]。

2 一种新的监督波段选择算法

2.1 正交投影散度

OPD 的思路来源于 OSP 的理论^[15],其目的是最大程度地分离目标信息和背景噪声信息。因此,为了能够得到最优解,需要在高光谱数据中找到能够使最小二乘估计趋向于最优值的波段,这也是本文高光谱波段选择的理论基础。根据最小二乘估计原理,即最大化端元(代表某一典型的地物类)

与背景之间距离

$$\text{opd} = r_i^T P_{r_j}^\perp r_i \quad (5)$$

由上式可以定义一个对称的光谱测度,即正交投影散度

$$\text{OPD}(r_i, r_j) = (r_i^T P_{r_j}^\perp r_i + r_j^T P_{r_i}^\perp r_j)^{1/2} \quad (6)$$

其中 $P_{r_j}^\perp = I - r_k(r_k^T r_k)^{-1} r_k^T$, $k = i, j$ 。正交投影散度表达了两个像元向量 r_i 和 r_j 之间的正交投影残差的测度,可以用作不同地物光谱向量之间相似性的测度指标。

2.2 波段选择策略

本文将 OPD 作为高光谱数据波段选择的一个指标,并采用顺序浮动前向搜索算法(sequential floating forward search, SFFS)^[16]作为波段选择的策略。该算法首先执行前向添加步骤,然后判断上一步所取得的值是否高于最新值,如果高于则执行后向排除步骤,反之继续执行前向添加过程。该算法只是在需要时才执行后退步骤,它得到的解接近于最优解,而计算速度要快于经典的穷举搜索算法。假定遥感数据的波段数为 l , 所要选择的波段数为 d , 则本文提出的波段选择算法的步骤如下。

Input: $B = \{b_i \mid i = 1, \dots, l\}$

Output: $X_k = \{x_j \mid j = 1, \dots, k; x_j \in Y\}$, $k = 1, \dots, d$

Initialization: $X_1 = \text{initialband}$, $k = 1$

Termination: if $k = d$

Step 1 (Inclusion)

$x^+ = \arg \max J(X_k + x)$

$X_{k+1} = X_k + x^+$; $k = k + 1$

Step 2 (Conditional Exclusion)

$x^- = \arg \max J(X_k - x)$

if $J(X_k - \{x^-\}) > J(X_{k-1})$ then

$X_{k-1} = X_k - x^-$; $k = k - 1$

go to Step 2

else

go to Step 1

end

需要说明的是,为了降低 SFFS 算法的搜索空间,初始波段的选择非常重要;本文的初始波段选择参考了文献[17],此处不再赘述。另外 Step 1 中选择的是能够使判别函数即 OPD 最大的波段,而 Step 2 中排除的是对判别函数影响最小的波段。

3 实验分析

为了验证本文算法(OPD)的性能,选用几种常见的波段选择算法,如基于 SAM, ED, SID 及 LCMV-BCC 的算法,进行对比实验研究。另外,支持向量机(SVM)分类器作为一种新颖的有效的统计分类方法^[18],能够适用于高维特征、小样本与不确定性问题的研究,在高光谱遥感分类方面具有极大的优越性。因此为了评价各种波段选择算法的性能及类别区分度,采用 SVM 分类器作为波段选择算法的性能衡量标准。

为了研究不同波段选择算法在不同波段数目时的性能,实验中所选择的波段数目从 5 变化到 40。同时,本文所研究

的波段选择算法利用了训练样本数据，为监督的波段选择算法；在实验中，取每个类的所有训练样本的均值作为该地物类的典型光谱向量。需要说明的是，LCM V-BCC 算法为非监督波段选择算法。

3.1 实验一：Washington DC Mall I

数据采用由 HYDICE (hyperspectral digital imagery collection experiment) 传感器获取的华盛顿 DC Mall 高光谱影像。该数据覆盖了从 0.4 到 2.5 μm 光谱区间的 210 个波段，其空间分辨率约为 2.8 m；在剔除了水吸收波段和噪声波段后，保留了 191 个波段用于数据分析。本实验数据为从华盛顿 DC Mall 原始影像上切取的一个子图像(见图 1)，该数据大小为 304 \times 301，包括了 6 个类：道路、草地、水体、小径、树木和屋顶。另外，在波段选择过程中，数据的初始波段设置为 95。

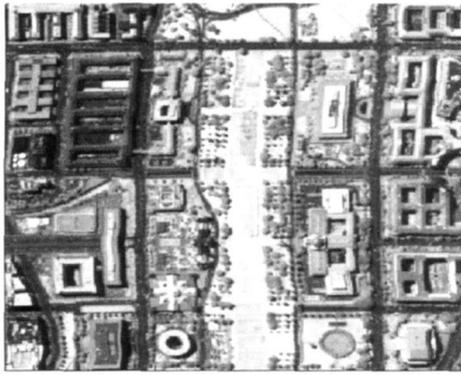


Fig 1 DC Mall image I

由图 2 可以看出，本文所提出的 OPD 算法，明显比 SAM, ED, SID 及 LCMV-BCC 效果更好；其中，SAM, ED 次之，SID, LCMV 算法的效果最差。而非监督的 LCMV 算法由于没能去除背景及噪声信息的影响，效果最差。另外，可以看出，随着波段数目的增加，各种算法的分类精度也在不断提高，其中 OPD 算法提高了 7 个百分点；当波段数目为 40 时，OPD 算法的分类结果比位于次优的 SAM 的结果高了 9 个百分点。

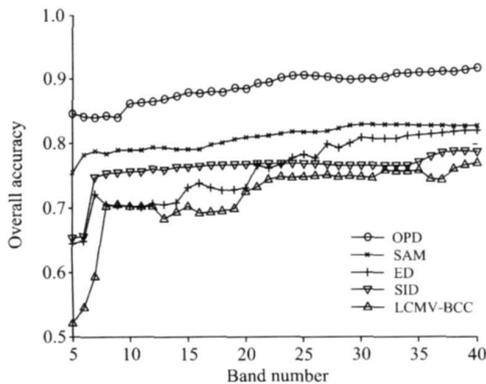


Fig 2 Classification results for DC Mall I

3.2 实验二：Washington DC Mall II

本实验数据为从华盛顿 DC Mall 原始影像上切取的另一

个子图像(见图 3)，该数据大小为 266 \times 304，包括了 7 个类：道路、草地、水体、小径、树木、阴影和屋顶。另外，在波段选择过程中，数据的初始波段设置为 95。

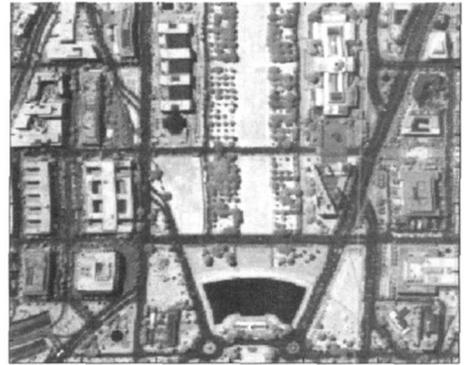


Fig 3 DC Mall image II

由图 4 可以看出，OPD 算法的分类精度在本实验中依然是最好的，其最高精度达 0.945；SAM 算法在 13~38 波段范围内分类精度也高于 0.9，但是依然低于本文所提出的方法。其他如 ED, SID 及 LCMV 等算法的结果依然不高。不同算法在不同波段数目情况下的分类精度走势与实验一的结果类似。本实验证明了本文所提出的波段选择算法具有较好的适用性。

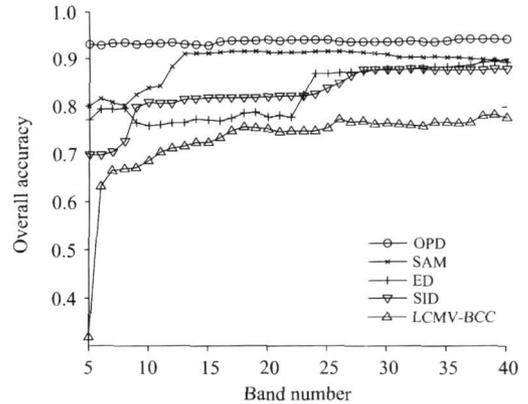


Fig 4 Classification results for DC Mall II

3.3 实验三：Hymap Purdue Campus Data

为了进一步验证本文算法对不同传感器数据的适用性，设计了实验三。本实验数据采用 HYMAP 传感器于 1999 年 9 月 30 日获取的普渡大学西拉法叶校区的高光谱影像(见图 5)。该数据大小为 377 \times 512，覆盖了从 0.4 到 2.4 μm 光谱区间的 126 个波段，其空间分辨率约为 5 m。在本实验中使用了全部的 126 个波段。另外，在波段选择过程中，数据的初始波段设置为 1。

由图 6 可以看出，OPD 算法在 HYMAP 数据上也取得了最优的结果。其中 ED 的分类精度次之，但是在波段数少于 11 时，其分类结果明显较低。SAM, SID 及 LCMV 效果依然不高。可以看出，随着波段数目的增加，各算法的分类精度也随之提高。本实验证明了本文所提出的波段选择算法具有较好的适用性和鲁棒性，能够用于不同传感器获取的高

光谱数据。



Fig 5 Purdue campus image

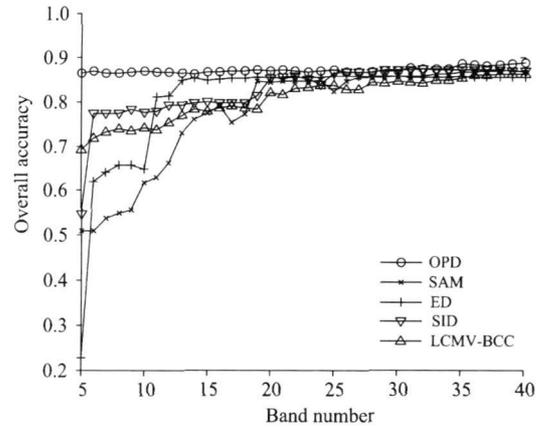


Fig 6 Classification results for Purdue campus data

4 结论

本文根据最大化光谱区分度原则,提出了基于 OPD 的波段选择算法。该算法一方面继承了正交子空间投影的特点,能够有效地分离感兴趣目标与背景信息,提高地物类光谱向量的区分度;另一方面采用顺序浮动前向搜索算法进行

波段选择,避免了高光谱数据的“维数灾难”,这对于高光谱遥感影像的快速分类具有重要的现实意义;第三,该算法的提出扩展了现有的波段选择算法。实验结果表明,与传统的算法相比,该算法是一种非常有效的高光谱波段选择算法,具有较好的性能和鲁棒性。

References

- [1] Chang C I. Hyperspectral Imaging: Signal Processing Algorithm Design and Analysis, NJ: John Wiley & Sons, 2009. 1.
- [2] Hughes G F. IEEE Trans. Information Theory, 1968, IT-14: 55.
- [3] Chang C I, Du Q. IEEE Trans. Geoscience Remote Sensing, 2004, 42(3): 608.
- [4] Nascimento J, Dias J. IEEE Trans. Geoscience Remote Sensing, 2005, 43(4): 898.
- [5] Nadakuditi R R, Edelman A. IEEE Trans. Signal Processing, 2008, 56(7): 2625.
- [6] Bioucas-Dias J M, Nascimento J M P. IEEE Trans. Geoscience Remote Sensing, 2008, 46(8): 2435.
- [7] Debba P, Cho M, Mathieu R. Pro. Whispers, 2009, 5289068: 1.
- [8] Keshava N. IEEE Trans. Geoscience Remote Sensing, 2004, 42(7): 1552.
- [9] Chang C I. IEEE Trans. on Information Theory, 2000, 46(5): 1927.
- [10] Chang C I, Wang S. IEEE Trans. Geoscience Remote Sensing, 2006, 44(6): 1575.
- [11] Su H J, Sheng Y H, Du P J. Proceedings of the ISPRS 2008. Vol. XXXVII. Part B7: 279.
- [12] Bajcsy P, Groves P. Photogrammetric Engineering & Remote Sensing, 2004, 70: 793.
- [13] SU Hong-jun, DU Pei-jun, SHENG Ye-hua(苏红军, 杜培军, 盛业华). Application Research of Computers(计算机应用研究), 2008, 25(4): 1093.
- [14] Harsanyi J C, Chang C I. IEEE Trans. Geoscience Remote Sensing, 1994, 32: 779.
- [15] Chang C I. Hyperspectral Imaging: Techniques for Spectral Detection and Classification. New York: Kluwer, 2003. 15.
- [16] Pudil P, Novovicová J, Kittler J. Pattern Recognition Letters, 1994, 15: 1119.
- [17] Du Q, Yang H. IEEE Geoscience and Remote Sensing Letters, 2008, 5(4): 564.
- [18] Burges C J C. Data Mining and Knowledge Discovery, 1998, 2: 121.

Orthogonal Projection Divergence-Based Hyperspectral Band Selection

SU Hong-jun^{1,2}, SHENG Ye-hua^{1*}, Yang He², Du Qian²

1. Key Lab of Virtual Geographic Environment (Ministry of Education), Nanjing Normal University, Nanjing 210046, China
2. Department of Electrical and Computer Engineering, Mississippi State University, Starkville, MS 39759, USA

Abstract Due to the high data dimensionality of a hyperspectral image, dimensionality reduction algorithm has attracted much attention in hyperspectral image analysis. Band selection algorithm, which selects appropriate bands from the original set of spectral bands, can preserve original information from the data and is useful for image classification and recognition. In the present paper, a novel band selection algorithm based on orthogonal projection divergence (OPD) is proposed, it aims to discriminate the interesting objects from background and noise information, maximize the spectral similarity between different spectral vectors by projecting the original data to feature space. Two HYDICE Washington DC Mall images and an HYMAP Purdue campus image data were experimented, and support vector machine (SVM) classifier was used for classification. The selected band number varies from 5 to 40 in order to study the impacts of different band selection algorithms on different features. For the computation complex, the sequential floating forward search (SFFS) was used to get the appropriate bands. The experiments have proved that our proposed OPD algorithm can outperform other traditional band selection methods such as SAM, ED, SID, and LCM V-BCC for hyperspectral image analysis. It is proven that OPD band selection is effective and robust in hyperspectral remote sensing dimensionality reduction.

Keywords Band selection; OPD; Dimensionality reduction; Hyperspectral imagery

(Received Apr. 14, 2010; accepted Jul. 18, 2010)

* Corresponding author