

文章编号: 1007-4619(2006)02-0204-07

小波变换在高光谱决策树分类中的应用研究

许卫东, 尹 球, 匡定波

(中国科学院 上海技术物理研究所, 上海 200083)

摘 要: 近几年来, 离散小波变换在遥感图像压缩、消噪和融合中得到了广泛的应用。利用航空飞行的高光谱图像数据, 先后进行了主成分分析及 10 种小波变换, 并应用分类回归树对其进行分类处理。将小波变换的分类结果与主成分分析的结果及不同的小波变换方法之间进行了对比。结果表明, 在样本数相同的条件下, 小波变换的分类精度均高于主成分分析, 其中 Haar 小波的分类精度最高; 小波变换后的分类对样本数量的要求要小于主成分分析。在样本数足够的情况下, 主成分分析数据压缩率要高于小波变换。但小波变换在压缩的情况下, 仍保留了原光谱的大部分信息, 而主成分分析只保留了原图像的方差而无法保留波形。

关键词: 小波变换; 决策树分类; 主成分分析; 高光谱遥感

中图分类号: TP79 文献标识码: A

Decision Tree Classification of Hyperspectral Image Based on Discrete Wavelet Transform

XU Weidong, YIN Qiu, KUANG Dingbo

(Shanghai Institute of Technical Physics, Chinese Academy of Science, Shanghai 200083, China)

Abstract: Discrete Wavelet Transform (DWT) was widely used in the application of Remote sensing image compression, noise reduction and image fusion recently. Principal Component Analysis (PCA) and DWT are performed separately with airborne hyperspectral data before a classification and regression tree are applied. The classification results of DWT are compared with PCA and with different mother wavelet DWT themselves. The results indicate that when the number of the training samples is equal, the classification accuracy of DWT is higher than PCA, among them Haar wavelet performs best. The demanding number of samples of classification after DWT is less than PCA, but when the samples are enough, the compression ratio of PCA is higher than DWT. However, when DWT compression is performed, the most of the spectral information is preserved while PCA keeping the variance of the image only.

Key words: DWT; decision tree classification; PCA; hyperspectral remote sensing

1 引 言

高光谱遥感技术是连接遥感数据处理、地面测量、光谱模型和应用的强有力工具, 其显著特点是在特定光谱区域以高光谱分辨率同时获取连续的地

物光谱图像, 从而使得遥感应用着重于在光谱维上进行空间信息展开, 定量分析地球表层生物物理化学过程和参数^[1]。但是高光谱遥感带来了精细光谱分辨率的同时, 也带来了海量的数据。一方面由于波段多达数百个, 波段间的相关性很高, 数据的冗余非常大; 另一方面, 对单一波段来说, 获取的能量

收稿日期: 2004-11-12; 修订日期: 2005-01-15

基金项目: 国家自然科学基金项目(40271084); 国家 863 计划(2002AA130010-1-4); 上海市科技攻关计划(035115006)。

作者简介: 许卫东(1975—), 男, 中国科学院上海技术物理所在读博士生, 主要研究方向为高光谱遥感, 已发表论文 6 篇。

有限,导致信噪比下降。当利用监督分类处理高光谱数据时,常常会发生 Hughes现象^[2],降维处理能够解决这一问题,并有可能提高分类精度。降维处理通常有两种方法,一种是选择少数信息量大的波段进行处理,另一种是进行数据变换降维。主成分分析和小波变换是人们在数据变换降维处理中最为常用的两种算法。

小波分析诞生于 20 世纪 80 年代,被认为是现代 Fourier 分析发展的一个崭新阶段。众多高新技术以数学为基础,而小波分析被誉为“数学显微镜”,显示了其在高科技研究领域的重要地位。由于其内在的多尺度分辨率特性,离散小波分析在遥感图像特征提取上具有特殊的优越性,可以将光谱信号分解为不同大小尺度上的信息。离散小波分析在遥感领域被成功应用于图像压缩、纹理分析、特征提取和融合^[3]。

本文应用离散小波对高光谱图像进行特征提取,然后应用分类回归树对高光谱图像进行分类。分类回归树作为一种决策树分类方法,由于其结构较为简单,且不以任何统计分布为假设前提,在遥感图像分类中得到了广泛应用^[4,5]。然而据 Pal 等人的研究结果^[6],分类回归树在使用所有波段对高光谱图像分类时并不能取得比传统分类方法更高的精度。因此,本文先对高光谱图像进行特征提取与变换,然后再进行分类。

本文的目的有:一是比较离散小波变换与主成分分析对高光谱图像进行分类及特征提取效果;二是比较不同的离散小波算法;三是考查训练样本数量对特征提取后分类精度的影响。效果评价指标采用决策树算法的分类精度。

2 试验区域

2.1 试验地区简介

试验区域选择在上海市南浦广场公园,南浦广场公园位于南浦大桥浦东下闸段环形高架内,中心为一大草坪,前面有一喷泉,四周为竹林及松林。内有多种城市植被,灌木有龙柏、黄杨、杜鹃、紫叶小檗,草有高羊牧草、麦冬等,并有樱花、梧桐等树种(图 1)。高光谱传感器采用中国科学院上海技术物理研究所研制 PHI 推帚式遥感器。光谱范围为 400—1000 nm,光谱分辨率 4—5 nm,124 波段,IFOV 为 0.6 m rad 飞行高度为 2000 m。在获取遥感数据的同时,用中国科学院上海技术物理研究所研制的




图 1 PH I 图像(2003-10-05)

Fig 1 Image of PH I(2003-10-05)

集成式地物光谱仪 PHS 进行了同步地物测量,其光谱范围为 350—1050 nm,光谱分辨率 1.4 nm,视场角 3°,测量高度为 30 cm。

2.2 数据处理

首先对 PH I 遥感器进行定标,将原始图像转换为辐射值,根据飞行参数进行几何粗校正,然后用 1:2000 的航片进行几何精校正。由于飞行高度较低且数据获取当天天气较好,我们直接使用同步获取的地面光谱数据用经验线性法将辐射值转换成反射率。选择训练区对 3K×2K 航片进行分类,在分类结果的基础上参照航片及地形图进行了目视解译,最后进行野外调绘得到最终解译图。

2.3 样本选择

鉴于城市植被的复杂度,我们选取了试验区内分布规则且有一定规模的植被进行了分类研究,选取了梧桐、蒿草、草坪、麦冬、龙柏、黄杨、杜鹃、紫叶小檗 8 种植被进行试验研究,其中梧桐是街道两边人行道树最常见的树种,龙柏、黄杨、杜鹃、紫叶小檗是绿化中最常用的灌木,麦冬常分布于林下,蒿草则常见于城市湿地中。然后从每个训练区中随机提取 2000 个训练点,这样得到 8×2000 个数据,将这些数据分成两部分,一半作为训练数据,一半作为验证数据,这样保证了验证数据的独立性。

3 算法简介

主成分分析又叫 K-L 变换,该变换的主要特点是:变换前后方差总和不变;第一组分取得方差的绝大部分,其余各组分所得很少,且依次减少;各组分

之间互不相关。主成分变换的目的是要把原来多个波段中的有用信息集中到数目尽可能少的新组分图像中,并使这些组分图像之间互不相关,从而大大减少数据量。

小波分析既保持了傅里叶分析的优点又克服了傅里叶分析的缺点,也优于作为过渡的加窗傅里叶分析,它的优良性能主要表现在它是一种时频分析且其“窗口”能随频率发生变化。它在反映信号高频成分时会给出窄的时间窗,而在反映低频成分时会给出宽的时间窗,换句话说,就是小波分析在高频处的时间分辨率高,在低频处的频率分辨率高,具有“变焦”特性^[7,8]。它的这种性质使得人们能够对信号的任一细节加以分析,在信号分析中有着重要意义。连续小波变换在计算机上不易实现,而主要用于理论分析与论证。在实际问题及数值计算中更重要的是其离散形式,离散形式可以通过对其尺度因子和平移因子采用离散化而得到。

离散小波变换在数学上可以看作一个有限长的序列与离散小波基的内积。每一个内积产生一个离散小波转换系数。在数学上可以表达为:

$$Wf(j, k) = \sum_{i=1}^{N-1} f(n) \times \psi_{jk}^*(n) \quad (1)$$

式中, $Wf(j, k)$ 表示离散小波转换系数,上标 * 号表示离散小波基。 $f(n)$ 表示有限长序列,表达式为:

$$\psi_{jk}(n) = \frac{1}{\sqrt{s_j}} \psi \left(\frac{n - s_j \cdot k}{s_j} \right) \quad (2)$$

s_j 和 $s_j \cdot k$ 是离散化尺度及转换参数^[8]。对二进制离散小波变换而言, $s_j = 2^j$ 。在本项应用中, $f(n)$ 代表了一个高光谱信号, n 表示波段或波段号,假定各波段的宽度相等且采样间隔相同。由于小波基都是

由可缩放的母函数转换而来, $\psi(n)$, 离散小波变换可以提供更为详细的全局高光谱信号。


人们通常并不使用尺度函数或小波函数来进行运算,而是直接利用双通道滤波器组进行一维离散时间序列或二维离散图像的小波变换。即利用一组高通和低通的滤波器组来代替小波基。分解的一般步骤为:首先分别用低通滤波器 H 和高通滤波器 G 对输入信号 A_j 做滤波,低通滤波后的信号称为原信号的剩余系数 A_j ,高通后的部分是原信号的小波系数 D_j ,这样依次分解直到所能达到的最大尺度。最大尺度取决于信号及小波基的长度。双通道滤波器组可由下式实现:

$$D_{j+1}(i) = \sum_{l=0}^{L-1} G(l) \cdot A_j(2 \cdot i + l) \quad (3)$$

$$A_{j+1}(i) = \sum_{l=0}^{L-1} H(l) \cdot A_j(2 \cdot i + l) \quad (4)$$

式中, $j=0, 1, 2, \dots, M$ 是小波分解水平 ($s=2^j$ 是尺度)。字母 G 和 D 分别是高通和低通滤波器的有限脉冲响应,有限脉冲响应因母函数的不同而不同。一开始 A_0 ($j=0$ 时) 等于原始信号 $f(n)$ 。就像傅里叶变换一样,离散小波变换也可以通过快速算法来实现。滤波器组根据不同的母函数来选择高通和低通滤波器。当信号通过不同水平的滤波器组,由于输入信号的长度不同,分别产生不同水平的近似和细节系数。

本文主要使用了以下几种小波母函数: Haar 小波, Daubechies² 小波 (Db2), Daubechies⁵ 小波 (Db5), Daubechies¹⁵ 小波 (Db15), Symlet² 小波 (Sym2), Symlet⁵ 小波 (Sym5), Symlet⁸ 小波 (Sym8), Coiflet¹ 小波 (Coif1), Coiflet³ 小波 (Coif3) 和 Coiflet⁵ 小波 (Coif5)。不同小波的形态如图 2。



4 结果讨论

4.1 分类精度

先将训练数据进行主成分变换,对变换后的样本进行训练得出分类决策树,其结构如图 3.运用此决策树对主成分分析后的测试样本进行分类,分别

得出其训练样本和验证样本分类精度。也就是说,主成分分析过程相对训练样本及验证样本是独立的,而决策树则是统一的。同样,我们对训练样本及验证样本分别进行了 10 种小波变换,并得出其训练样本分类精度和验证样本分类精度。主成分变换及小波变换均保留了所有的 124 个波段,其结果如图 4。





图 3 分类回归树结构示意图

Fig 3 Flowchart of CART



注: All是指用所有原始波段,PCA指主成分分析,Haar指小波变换,其他表示相应的小波变换

图 4 主成分分析及小波变换分类精度

Fig 4 Illustration of classification accuracy of PCA and DW T

由图 4 可见,所有小波变换后的决策树分类精度要高于主成分分析。训练样本分类中, Haar Db2, Sym2 小波都有较高精度,分别达到了 0.942, 0.943, 0.943;而测试数据集中 Haar 小波的分类精度最高,达 0.898,说明 Db2 和 Sym2 小波都发生了不同程度的过度拟合现象。所有变换(包括主成分

变换和小波变换)后的决策树分类精度都高于原有所有波段分类的结果。

究其原因,对不同的地物而言,由于其组分的不同,在反射率上也呈现出不同的形态。比如植被的“红边”现象就是由于植被中的叶绿素对红光的吸收及在近红外的高反射坪造成的。小波变换

的优点在于变换过程中所有尺度和平移因子都得以保存,因而地物光谱特征信息也得以保存,局部和全局的信号都可以在同一空间中进行分析。而反射率的局部变化(如反射峰和吸收谷)正反映了不同地物的光谱特征,小波变换将这些特征或放大或分解为不同水平的尺度和平移系数,因此有

利于地物光谱特征的深入分析。而主成分分析只保留了原图像的方差,光谱信息则无法保留。图 5 是一植被的光谱经 Haar小波 5级变换后的结果,左边是剩余系数 A_j ,右边是小波系数 D_j ,从图中可以看出,即便是在第 5 级别上,仍保留了大部分的植被特征。

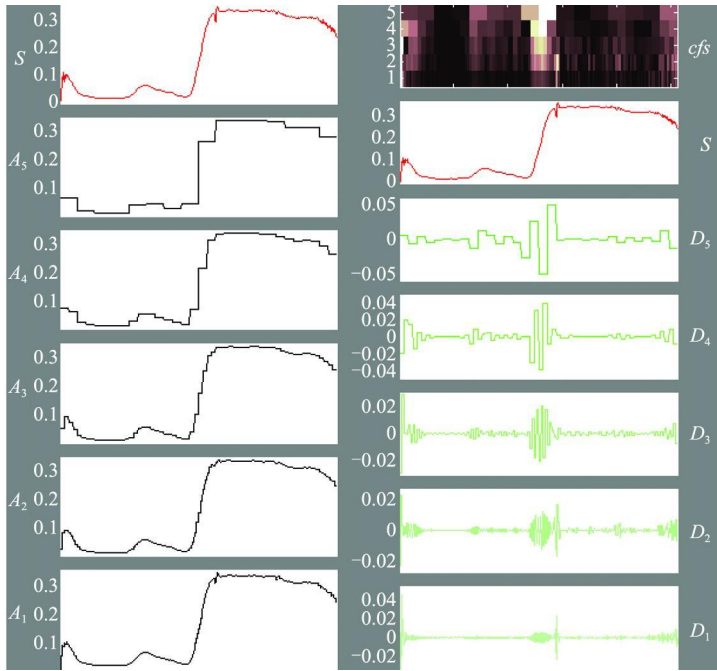


图 5 小波分解

Fig 5 Decomposition of wavelet

4.2 样本数量的影响

对监督分类而言,样本数量是一个非常重要的影响因素,特别是对高光谱图像来讲,获取足够的样本数是非常困难的。为了分析样本数对决策树分类结果的影响,我们分别从训练样本中依次按比例制取了 10%, 20%, 30%, 40%, 50%, 60%, 70%, 80%, 90%, 100%的样本量,对这些样本进行训练分类得出决策树,用这一决策树对整个验证样本进行分类得出验证样本分类精度。将这一方法分别应用于主成分分析及小波变换,分别得到训练分类精度和验证分类精度结果。

图 6 是主成分分析及 Haar小波的验证分类精度随抽样比例变换的曲线图,由图可见,随着样本数的增加,主成分分析及小波变换的分类精度都呈上升趋势,小波变换的分类精度普遍要高于主成分分析 5 个百分点。在 10%—30% 之间,小波变换后的分类精度上升速度很快; 30%—70% 之间,上升趋势较缓; 70%

以后趋平。而主成分分析在整个抽样空间中都在上升,尤其在 20%—50% 之间。在 30% 样本的时候, Haar小波分析的精度已达到主成分分析 100% 的精度。小波变换本身不依赖于样本数的多少,它只与信号本身的长度及小波基有关,小波变换后的决策树分类精度受样本的影响的原因在于决策树的训练受样本大小的影响。而主成分分析中的均值和方差的计算都是建立在大样本的基础上,变换后的决策树分类精度受样本数量的影响较大也是必然的。

4.3 数据压缩率

主成分分析及小波变换引入的一个重要目的,就是进行图像的压缩。为最大程度地保留原有图像的信息,我们在主成分分析中取了前八个主分量,占原图像方差的 99.98%。对小波变换分别取 64, 32, 16, 8 个波段进行分类,在此过程中训练样本和验证样本仍旧各自独立,得出其验证分类精度。表 1 为 Haar小波和主成分分析对高光谱数据压缩后的分类精度比较表。




图 6 样本数量对分类精度的影响
Fig 6 The influence of samples

表 1 小波与主成分分析压缩效果比较表 (Haar小波)
Table 1 PCA and DW T for data compression (Haar)

| 压缩波段 | 训练样本精度 | 验证样本精度 |
|------|--------|--------|
| 124 | 0.9389 | 0.8959 |
| 64 | 0.9404 | 0.9006 |
| 32 | 0.9284 | 0.8910 |
| 16 | 0.8900 | 0.8470 |
| 8 | 0.8454 | 0.8049 |
| PCA8 | 0.9143 | 0.8684 |

由表 1 可见, Haar小波将光谱数据压缩为 16, 8 个波段后, 分类精度分别为 0.847 及 0.8049, 低于主成分变换取 8 个主分量的 0.8694, 但如前言所述, 小波分析保留了大部分的光谱信息, 而主成分分析则只是保留了原图像的方差; 压缩为 64 及 32 波段后, 分类精度与原图像相当, 64 波段有时还稍高

于 124 波段的分类精度, 这说明在样本数一定的情况下, 随着波段的增加, 分类精度出现了下降, 即 Hughes 现象。为进一步考查这一现象和小波压缩后样本数量与分类精度之间的关系, 我们首先将训练样本和验证样本用小波变换压缩为 64, 32, 16, 8 个波段, 然后按比例分别抽取 30%, 40%, 50%, 60%, 70%, 80%, 90%, 100% 的样本量, 如前文所述, 对这些样本进行训练分类得出决策树, 用这一决策树对整个验证样本进行分类得出验证样本分类精度。

图 7 为 Haar小波变换压缩后验证分类精度与样本比例之间的关系图。从图中可以看出, 随着样本数的增加, 分类精度总体呈上升趋势, 在 10%—30% 之间, 分类精度上升速度很快, 30%—70% 之间, 上升趋势较缓, 70% 以后趋平。随着波段数的增加, 分类精度总体也呈上升趋势, 但随着波段的增加, 分类精度增长速率递减, 64 波段时的分类精度基本与 124 波段持平甚至更高。小波变换波段取

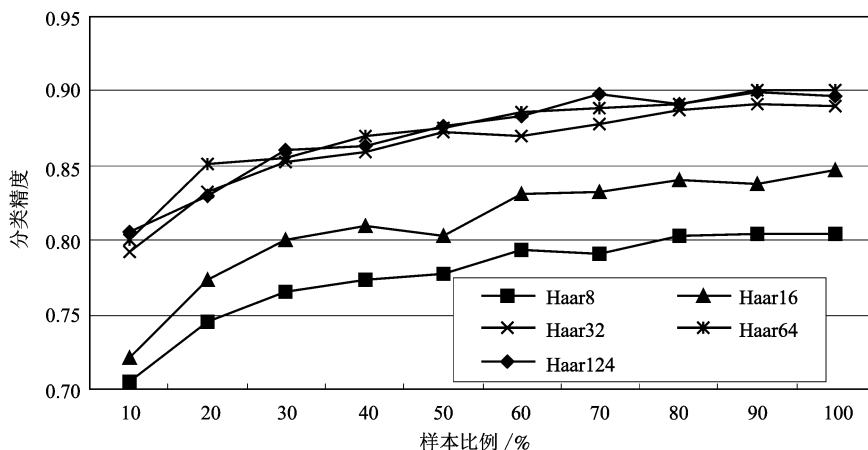


图 7 样本数量及压缩比对分类精度的影响
Fig 7 The influence of samples and compress ratio

32以上,样本取 40%以后的分类精度均高于主成分分析取 8个主分量。说明小波变换压缩后在保留了大部分的光谱信息的同时,降低了分类对样本数量的依赖,在样本数较小的情况下,选择先进行小波压缩再进行分类可以提高精度。

5 结 论

本文利用航空飞行的 PHI高光谱图像数据,先后进行了主成分分析及 10种小波变换,并应用分类回归树对其进行分类处理。将小波变换的分类结果与主成分分析的结果及不同的小波变换方法之间进行了对比。结果表明,在样本数相同的条件下,小波变换的分类精度均高于主成分分析,其中 Haar小波的分类精度最高;小波变换后的分类对样本数量的要求要小于主成分分析,也就是说在样本数较小的情况下,小波压缩的分类精度要明显高于主成分分析;但在样本数足够的情况下,主成分分析数据压缩比要高于小波变换。需要进一步指出的是,小波变换在压缩的情况下,仍保留了原光谱的大部分信息,而主成分分析只保留了原图像的方差而无法保留波形,这对利用光谱信息进行植被生化参数和反演尤其重要。在样本数较小的情况下,可以考虑也进行小波压缩后再进行分类处理,这样一方面可以节省时间,另一方面也可以提高分类精度。

参 考 文 献 (References)

[1] Tong Q X, Zheng L F, Wang J N, et al. Study on Imaging

Spectrometer Remote Sensing Information for Wetland Vegetation [J]. Journal of Remote Sensing, 1997, 1 (1): 50- 57. [童庆禧,郑兰芬,王晋年等. 湿地植被成像光谱遥感研究 [J]. 遥感学报, 1997, 1 (1): 50- 57.]

[2] Hughes G F. On the Mean Accuracy of Statistical Pattern Recognizers [J]. IEEE Transactions on Information Theory, 1968, 14: 55- 63.

[3] Bruce L M, Koger C H, Li J. Dimensionality Reduction of Hyperspectral Data Using Discrete Wavelet Transform Feature Extraction [J]. IEEE Transactions on Geoscience and Remote Sensing, 2002, 40: 2331- 2338.

[4] Li S, Ding S Y, Qian L X. The Decision Tree Classification and Its Application Research in Land Cover [J]. Remote Sensing Technology and Application, 2002, 17 (1): 6- 11. [李爽,丁圣彦,钱乐祥. 决策树分类法及其在土地覆盖分类中的应用 [J]. 遥感技术与应用, 2002, 17 (1): 6- 11.]

[5] Zhao P, Feng X Z, Ling G F. The Decision Tree Algorithm of Automatically Extracting Residential Information from SPOT Images [J]. Journal of Remote Sensing, 2003, 7 (4): 309- 315. [赵萍,冯学智,林广发. SPOT卫星影像居民地信息自动提取的决策树方法研究 [J]. 遥感学报, 2003, 7 (4): 309- 315.]

[6] Pal M, Mather P M. An Assessment of the Effectiveness of Decision Tree Methods for Land Cover Classification [J]. Remote Sensing of Environment, 2003, 86: 554- 565.

[7] Dong W H, Liu M Y. Research and Programming Implementation of Image Compression Using Wavelet Analysis [J]. Application Research of Computers, 2003, (6): 57- 60. [董文辉,刘明业. 应用小波分析进行图像压缩的研究及实现 [J]. 计算机应用研究, 2003, (6): 57- 60.]

[8] Burrus S, Gopinath R, Guo H. Introduction to Wavelets and Wavelet Transforms: A Primer [M]. NJ: Prentice Hall, 1998.