

基于 direct LDA 的高光谱遥感影像地物分类

刘 敬

(西安邮电学院电子工程学院 西安 710121)

摘 要 针对高光谱遥感影像的降维问题,提出一种高光谱影像地物分类方法:direct LDA 子空间法。先采用直接线性判别分析(direct linear discriminant analysis,direct LDA)进行特征提取,然后在特征子空间中采用最短距离分类器进行地物分类。机载可见光/红外成像光谱仪(airborne visible/infrared imaging spectrometer,AVIRIS)的高光谱影像识别结果表明,该方法相比 LDA 子空间法和原空间法,可显著降低数据维数,提高识别率。

关键词 地物分类,特征子空间,特征提取,高光谱影像

中图分类号 TP391,TP751.1,TP753,TN911.73 **文献标识码** A

Hyperspectral Remote Sensing Image Terrain Classification Based on Direct LDA

LIU Jing

(School of Electronic Engineering,Xi'an University of Post and Telecommunications,Xi'an 710121,China)

Abstract Hyperspectral remote sensing image has the problem of high dimensionality. A new hyperspectral image terrain classification method,i. e. ,direct LDA subspace method,was presented. Firstly,direct linear discriminant analysis (direct LDA) was used to extract features in original high dimensional hyperspectral space,and then shortest distance classifier was used to perform terrain classification in the feature subspace. Recognition results based on airborne visible/infrared imaging spectrometer(AVIRIS) hyperspectral image show that the presented method can remarkably reduce data dimensionality and improve recognition efficiency.

Keywords Terrain classification,Feature subspace,Feature extraction,Hyperspectral image

1 引言

高光谱影像是目前遥感影像地物分类领域的研究热点^[1-4],已广泛应用于生态和环境监测、地质矿产调查、城市建设等国民经济领域。相比多光谱影像,高光谱影像具有高光谱分辨率。通常的多光谱传感器只有几个处于可见光和反射红外区的波段,其光谱分辨率一般大于 100nm;而高光谱传感器能获得整个可见光、近红外、短波红外、热红外波段的多而窄的连续光谱,波段数多达几十甚至数百个,光谱分辨率可达纳米级^[5]。因此,相比多光谱影像,高光谱影像包含了更加丰富的光谱信息,而不同地物间千差万别的光谱特征正是利用高光谱影像实现地物分类的基础。

高光谱影像提供丰富光谱信息的同时也为地物识别带来了新的挑战。为有效进行地物分类,有必要对高光谱影像进行降维,这是因为:(1)从模式识别角度来看高光谱影像地物分类问题,影像的一个像元即为高维光谱空间中的一个样本,样本维数为光谱波段数,地物分类即在高维光谱空间中进行。较低维数据空间,高维空间线性可分性的可靠性低,且分类器的推广能力差。(2)随着波段数的增加,数据量急剧增加。在相同地面分辨率和成像区域的情况下,高光谱影像数据量

比多光谱影像高出 1~2 个数量级。(3)随着波段数的增加,地物识别过程计算量增大、计算复杂度增加。(4)随着波段数增多,样本的统计参数增多,为达到比较精确的参数估计,训练样本数应为所用波段数的 10 倍以上,达到 100 时才能得到满意的效果^[6]。由于遥感影像样本的选择费时且昂贵,难以获得足够的训练样本以保证对参数的精确估计,使得采用统计分类方法的可靠性大为下降。且采用最大似然分类时,在样本数不变的情况下,分类精度随所使用波段数的变化呈现出 Hughes 现象^[7],即在样本数一定的情况下,分类精度随所使用波段数的增加上升到一定程度后开始下降。总之,尽管高光谱数据更多的波段意味着能够区分更多的类别,但受训练样本数的限制,分类器的性能也受到限制,且造成分类器结构庞大、运算量大、存储量大等问题。

数据降维的方法包括特征提取和特征选择两大类。特征提取将原始数据通过某种变换映射到低维空间,特征选择则从原始高维数据空间中依据某种准则选择出若干特征以构成低维空间。特征提取按用途分为基于数据表达和基于分类两种。本文采用基于分类的特征提取对高光谱影像进行降维。基于数据表达的特征提取,在降低数据维数的同时,使原始数据的信息损失最小,多用于数据压缩,如小波变换和主成分分

到稿日期:2011-01-03 返修日期:2011-04-02 本文受国家自然科学基金(61003199),中央高校基本科研业务费专项资金(K50510020015),陕西省教育厅自然科学基金(2010JK821),西安邮电学院博士启动基金(000-1271)资助。

刘 敬(1975-),女,博士,讲师,主要研究方向为智能信息处理(包括遥感影像地物分类、高分辨雷达自动目标识别),E-mail:zyhalj1975@163.com。

析(principle component analysis, PCA)等;基于分类的特征提取,在降低数据维数的同时,使数据映射到特征子空间中后可分性最大,多用于分类识别,如线性判别分析(linear discriminant analysis, LDA)。基于 Fisher 准则的 LDA 是经典的基于分类的特征提取方法,旨在将数据映射到特征子空间中后,使类间散布与类内散布之比最大。LDA 的解为 $S_w^{-1}S_b$ 前 d 个最大特征值对应的特征向量^[8,9], S_w 与 S_b 分别为原始空间数据的类内散布矩阵与类间散布矩阵。直接线性判别分析^[10](direct linear discriminant analysis, direct LDA)是 LDA 的一种改进,最开始提出时用以解决人脸识别中的小样本问题(small sample size problem, SSS)^[8]。LDA 的求解过程是先白化类内散布矩阵,后对角化类间散布矩阵;而 direct LDA 则先白化类间散布矩阵,后对角化类内散布矩阵。

经过分析我们认为,相比 LDA, direct LDA 更适合高光谱影像特征提取,这是因为:(1)direct LDA 先白化类间散布矩阵,在这一步丢弃了不包含分类信息的类间散布矩阵零空间。(2)高光谱影像地物分类也存在小样本问题,在小样本情况下,类内散布矩阵多为奇异矩阵。当类内散布矩阵奇异时, LDA 先白化类内散布矩阵,丢弃了包含重要分类信息的类内散布矩阵零空间;direct LDA 后对角化类内散布矩阵,可避免丢弃类内散布矩阵零空间。(3)LDA 特征子空间维数受样本类别数限制,当地物类别数较多时, LDA 降维的效果将受到影响;direct LDA 特征子空间维数不受样本类别数限制。因此,本文将 direct LDA 应用于高光谱影像特征提取,提出一种基于 direct LDA 的高光谱影像地物分类方法:direct LDA 子空间法,即先采用 direct LDA 提取高光谱影像的线性可分性特征,然后在特征子空间中采用最短距离分类器进行分类识别。采用实测机载可见光/红外成像光谱仪(airborne visible/infrared imaging spectrometer, AVIRIS)的高光谱影像的识别结果表明,相比 LDA 子空间法和高光谱原空间法,本文方法的确可在大大降低数据维数的同时显著提高识别率。

2 direct LDA

2.1 传统 LDA

设 n 维数据空间中有 c 类训练样本,定义类内散布矩阵

$$S_w = \sum_{j=1}^c P_j \left[\frac{1}{n_j} \sum_{k=1}^{n_j} (x_j^{(k)} - m_j)(x_j^{(k)} - m_j)^T \right] \quad (1)$$

式中, n_j 为第 j 类的样本个数, $x_j^{(k)}$ 为第 j 类的第 k 个样本, m_j 和 P_j 分别为第 j 类的均值和先验概率。定义类间散布矩阵

$$S_b = \sum_{j=1}^c P_j (m_j - m)(m_j - m)^T \quad (2)$$

式中, m 为整体均值,且 $m = \sum_{j=1}^c P_j m_j$ 。

LDA 寻找线性变换矩阵 $W \in \mathcal{R}^{m \times d}$,使得采用 $y = W^T x$ 将 n 维原始空间的数据 x 映射到 d 维($d < n$)特征子空间后, Fisher 准则

$$J_F(W) = \max_W \{ \text{tr}[(W^T S_w W)^{-1} (W^T S_b W)] \} \quad (3)$$

最大。式(3)的解 W 的列由 $S_w^{-1}S_b$ 前 d 个最大特征值对应的特征向量组成^[8,9]。由文献[8]知, $S_w^{-1}S_b$ 的特征值分解问题等价于同时对角化 S_w 与 S_b 。为求解 W , LDA 先白化 S_w 矩阵,后对角化 S_b 矩阵;而 direct LDA 先白化 S_b 矩阵,后对

角化 S_w 矩阵。

2.2 direct LDA

为求解 W , direct LDA 先白化 S_b 矩阵,后对角化 S_w 矩阵,具体步骤如下。

步骤1 白化 S_b 。设 U_b 和 Λ_b 分别为 S_b 的特征向量矩阵和特征值矩阵,即 $U_b^T S_b U_b = \Lambda_b$, Λ_b 为对角矩阵,其主对角线元素为 S_b 的所有非零特征值。有 $W_1 = U_b \Lambda_b^{-1/2}$ 满足 $W_1^T S_b W_1 = I$, I 为单位矩阵。

步骤2 对角化 $W_1^T S_w W_1$ 。以 $W_1^T S_w W_1$ 的前 d 个最小特征值对应的特征向量为列构成矩阵 U_w' , 有 $(U_w')^T W_1^T S_w W_1 U_w' = \Lambda_w'$, Λ_w' 为对角矩阵,其主对角线元素为 $W_1^T S_w W_1$ 的前 d 个最小特征值。

步骤3 将 d 维子空间中各类数据分布变换为超球形。有 $W_2 = (U_w') (\Lambda_w')^{-1/2}$ 满足 $W_2^T W_1^T S_w W_1 W_2 = I$ 。

步骤4 线性变换矩阵 $W = W_1 W_2$, n 维原始数据空间的向量 x 经

$$y = W^T x \quad (4)$$

映射到 d 维特征子空间。

经过分析我们认为,相比 LDA, direct LDA 更适合高光谱影像特征提取,这是因为:(1)类间散布矩阵的秩最大为样本类别数减1,当样本类别数减1小于数据维数时,类间散布矩阵是奇异矩阵。对于高光谱遥感影像,地物类别数通常远小于数据维数,因此类间散布矩阵的零特征值较多。相比 LDA, direct LDA 在第一步白化类间散布矩阵时丢弃了类间散布矩阵零空间,即类间散布矩阵零特征值对应的特征向量,由于数据映射到此零空间中后类间散布最小,即各类均值聚集为一点,数据表现为完全不可分,故而此零空间不包含分类信息,是应该丢弃的。(2)高光谱影像数据维数高,由于样本的获取费时且昂贵,在一些地物分类场合,某些地物训练样本个数低于数据维数,即存在所谓的小样本问题。在小样本情况下,类内散布矩阵多为奇异矩阵。当类内散布矩阵奇异时, LDA 先白化类内散布矩阵,丢弃了包含重要分类信息的类内散布矩阵零空间;direct LDA 后对角化类内散布矩阵,可避免丢弃类内散布矩阵零空间。数据映射到类内散布矩阵零空间后类内聚集最大,即各类数据方差为零,因此类内散布矩阵零空间包含重要的可分性信息,不应被丢弃。(3)为保留所有分类信息, LDA 在第二步对角化类间散布矩阵时必须保留所有非零特征值对应的特征向量,这些特征向量数目的上限为样本类别数减1,故而 LDA 特征子空间维数受样本类别数限制,当地物类别数较多时, LDA 降维的效果将受到影响;而 direct LDA 在第二步对角化类内散布矩阵时只需保留前 d 个最小特征值对应的特征向量即可,因此 direct LDA 特征子空间维数不受样本类别数限制。

基于以上分析,本文将 direct LDA 应用于高光谱影像的特征提取,提出一种称为 direct LDA 子空间法的地物分类方法,即先采用 direct LDA 提取高光谱影像的线性可分性特征,然后在特征子空间中采用最短距离分类器进行地物分类。

3 direct LDA 子空间法

direct LDA 子空间地物分类方法步骤如下。

步骤1 特征提取。采用 direct LDA 对训练数据进行特

征提取。以每一类地物的训练数据作为一类,计算类内散布矩阵 S_w 和类间散布矩阵 S_b ,根据 2.2 节中的步骤计算变换矩阵 W 。

步骤 2 建立模板库。将各类训练数据采用式(4)映射到特征子空间,以子空间中各类均值为模板建立模板库 $T_c = \{t_i, i=1, 2, \dots, c\}$,其中 c 为地物类别数, t_i 为第 i 类地物的均值。

步骤 3 地物分类。对任意测试数据 x ,采用式(4)将其映射到特征子空间后记为 y 。采用最短距离分类器进行分类识别,即判决 y 属于 $\arg \min_{i=1, \dots, c} \|t_i - y\|_2$ 所决定的类,其中 $\|t_i - y\|_2$ 表示测试样本 y 与第 i 个地物均值模板之间的欧式距离。

4 实验结果

为验证 direct LDA 子空间法的有效性,在相同训练数据和测试数据的条件下,本文也采用 LDA 子空间法和原空间法进行地物分类。LDA 子空间法在 LDA 子空间采用最短距离分类器分类识别。原空间法在原始数据空间比较测试样本与训练数据各类均值之间的欧式距离,判决其属于欧式距离最小的类。可见,原空间法就是经典的基于光谱匹配的地物分类方法,即将高光谱影像的一个像素看作高维光谱空间的一个样本,两个样本之间的欧式距离即为两个像素的光谱匹配测度,其值越小,两个像素的光谱越相似,它们越有可能是同一类地物。

4.1 实验数据介绍

我们采用 Indian Pines 高光谱影像,该数据是 1992 年 AVIRIS 传感器对印第安那州西北农业区成像所得,具有 400nm~2450nm 波长范围内的 220 个光谱带,空间分辨率为 17m。该数据包括 16 类地物,影像大小为 145×145。

从原始数据中去除易被水吸收的波段,包括 104~108 (1360nm~1400nm)、150~163 (1820nm~1930nm)以及 220 (2500nm),得 200 波段的高光谱数据。同时选取整个影像以及包含 [27-94]×[31-116] 像素的 68×86 影像子区域进行实验。影像子区域中包含 4 类地物,即 Corn-notill、Grass/Trees、Soybeans-notill、和 Soybeans-min,如图 1 所示。




图 1 Indian Pines 影像

4.2 实验结果

从各类样本中随机选择 20% 作为训练样本,其余作为测试样本。表 1 为整体影像的地物类别编号以及各类别测试样本的数目。

表 1 Indian Pines 整体影像类别编号和测试样本

类别名称	Alfalfa	Corn-notill	Corn-min	Corn	Grass/Pasture	Grass/Trees	Grass/pasture-mowed	Hay-windrowed	Oats	Soybeans-notill	Soybeans-min	Soybean-clean	Wheat	Woods	Bldg-Grass-Trees-Drives	Stone-steel towers
类别编号	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
测试样本个数	43	1147	667	187	398	598	21	391	16	774	1974	491	170	1035	304	76
测试样本总数	8292															

表 2 为 Indian Pines 整体影像在 200 维原空间采用最短距离分类器的识别结果。限于篇幅无法给出混淆矩阵,只给出了各类识别率和平均识别率。可见,有 11 类地物的识别率低于 60%,其中 5 类地物的识别率低于 20%,这是不同地物

的光谱相似度很高造成的。

表 3 为 Indian Pines 整体影像在 15 维 LDA 子空间采用最短距离分类器的识别结果。有 4 类地物的识别率低于 60%,其中有 1 类低于 20%。

表 2 Indian Pines 整体影像 200 维原空间的识别结果

类别编号	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
各类识别率 (%)	90.7	55.88	18.59	18.18	3.77	35.45	85.71	49.62	50.0	18.09	15.15	39.51	97.06	78.55	29.61	88.16
平均识别率 (%)	48.38															

表 3 Indian Pines 整体影像 15 维 LDA 子空间的识别结果

类别编号	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
各类识别率 (%)	55.81	70.44	60.57	79.14	78.14	96.99	42.86	99.49	18.75	75.84	54.46	78.21	99.41	85.60	84.87	82.89
平均识别率 (%)	72.71															

表 4 为 Indian Pines 整体影像在 10 维 direct LDA 子空间采用最短距离分类器的识别结果。只有 2 类地物的识别率低于 60%,且此 2 类地物识别率均大于 50%。比较表 3 和表

4,可见数据在 direct LDA 子空间的可行性要高于 LDA 子空间。综比表 2、表 3 和表 4, direct LDA 子空间法相比原空间法和 LDA 子空间法,平均识别率分别提高了 29.6 和 5.27 个

百分点。direct LDA 子空间维数比 LDA 子空间维数低 5,这是因为 LDA 为保留所有分类信息,子空间维数受样本类别数限制,而 direct LDA 子空间维数不受样本类别数限制。

图 2 为 direct LDA 子空间法的平均识别率随子空间维数

变化的示意图。由图可见,当 direct LDA 子空间维数大于 7 时,平均识别率均大于 LDA 的 15 维子空间的平均识别率;当子空间维数等于 10 时平均识别率达到峰值,随着子空间维数的继续增加,平均识别率开始缓慢降低,但始终大于 75%。

表 4 Indian Pines 整体影像 10 维 direct LDA 子空间的识别结果

类别编号	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
各类识别率 (%)	65.12	69.49	52.02	78.07	65.08	95.65	80.95	99.49	100	74.29	50.05	86.56	99.41	84.73	67.76	78.95
平均识别率 (%)	77.98															




图 2 平均识别率随 direct LDA 子空间维数的变化

表 5 为 Indian Pines 影像的 68×86 子区域在 200 维原空间采用最短距离分类器识别结果的混叠矩阵。由表 1 可知,该子区域包含的 4 类地物 Corn-notill, Grass/Trees, Soybeans-notill 和 Soybeans-min 的类别编号为 2,6,10 和 11。为简洁起见,在混叠矩阵中用类别编号代替地物名称。由表 5 可见,第 2、10 和 11 类地物的识别率很低,这是因为 Indian Pines 影像采集于 6 月,这 3 类地物均处于成长的早期,其光谱很相似,它们的样本在原始高光谱空间中混叠在一起。尤其是第 11 类和其余两类的混叠非常严重,以致于该类识别率只有 35.95%。

表 5 Indian Pines 影像的 68×86 子区域 200 维原空间的识别结果

类别编号	2	6	10	11
2	69.98	0	23.54	36.47
6	0.74	100.0	0.17	1.56
10	15.63	0	67.53	26.02
11	13.65	0	8.76	35.95
平均识别率 (%)	68.36			

表 6 为 Indian Pines 影像的 68×86 子区域在 3 维 direct LDA 子空间采用最短距离分类器识别结果的混叠矩阵。比较表 5 和表 6,可见 direct LDA 法相比原空间法,第 2、10、11 类的识别率分别提高了 22.02、26.67 和 47.7 个百分点;平均识别率提高了 24.12 个百分点;数据维数从 200 降到 3。可见,将数据映射到 direct LDA 子空间中后,由于在子空间中类内散布的减小和类间散布的增强,基本消除了 2、10、11 类样本的混叠,提高了识别率。

表 6 Indian Pines 影像的 68×86 子区域 3 维 direct LDA 子空间的识别结果

类别编号	2	6	10	11
2	92.0	0	0.7	8.2
6	0	100.0	0.3	1.0
10	3.5	0	94.2	7.1
11	4.5	0	4.8	83.7
平均识别率 (%)	92.48			

表 7 为 Indian Pines 影像的 68×86 子区域在 3 维 LDA 子空间采用最短距离分类器识别结果的混叠矩阵。比较表 6 和表 7 可见,direct LDA 子空间法相比 LDA 子空间法,除第 2 类识别率降低 0.2 个百分点外,第 6、10、11 类识别率分别提高

0.2、3.1 和 0.77 个百分点;平均识别率提高了 0.98 个百分点。

表 7 Indian Pines 影像的 68×86 子区域 3 维 LDA 子空间的识别结果

类别编号	2	6	10	11
2	92.2	0	1.0	8.31
6	0	99.8	0.3	0.71
10	1.6	0.2	91.1	8.05
11	6.2	0	7.6	82.93
平均识别率 (%)	91.5			

由 Indian Pines 整体影像和 68×86 子区域影像的识别结果可见,direct LDA 在降低高光谱影像数据维数和提高识别率方面均优于 LDA,非常适合高光谱影像特征提取。

结束语 本文针对高光谱影像的降维问题,提出一种新的基于 direct LDA 的高光谱影像地物分类方法,即先采用 direct LDA 提取地物的线性可分性特征,然后在特征子空间中采用最短距离分类器进行地物分类识别。基于 AVIRIS 高光谱影像的识别结果表明,相比原空间法和 LDA 子空间法,本文方法可大大降低数据维数,显著提高识别率,有效地提高高光谱影像的地物识别效率。

参考文献

- [1] Bazi Y, Melgani F. Toward an optimal SVM classification system for hyperspectral remote sensing images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2006, 44(11): 3374-3385
- [2] Fauvel M, Benediktsson J, Chanussot J, 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
- [3] 杨国鹏,余旭初,陈伟,等.基于核 Fisher 判别分析的高光谱遥感影像分类[J]. 遥感学报, 2008, 12(4): 479-585
- [4] 余红伟,张艳宁,袁和金.一种无监督高光谱图像分类算法[J]. 中国图象图形学报, 2008, 13(6): 1123-1127
- [5] 童庆禧,张兵,郑兰芬. 高光谱遥感——原理、技术与应用[M]. 北京:高等教育出版社, 2006
- [6] Swain P H, Davis S M. Remote Sensing: The Quantitative approach[M]. New York: McGrawHill Inc, 1978
- [7] Hughes G. On the mean accuracy of statistical pattern recognition[J]. IEEE Transactions on Information Theory, 1968, IT-14(1): 55-63
- [8] Fukunaga K. Introduction to statistical pattern recognition[M]. Boston: Academic Press, 1990
- [9] Jain A K, Duin R P W, Mao J C. Statistical Pattern Recognition: A Review[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2000, 22(1): 4-37
- [10] Yu H, Yang J. A direct LDA algorithm for high-dimensional data-with application to face recognition[J]. Pattern Recognition, 2001, 34(10): 2067-2070