

# 核 Direct LDA 子空间高光谱影像地物分类

刘 敬

(西安邮电学院电子工程学院 西安 710121)

**摘 要** 为降低高光谱影像的数据维数,提高地物分类识别效率,提出了一种地物分类方法——核直接线性判别分析(Kernel Direct Linear Discriminant Analysis, KDLDA)子空间法;并推导出类先验概率的一般形式下 KDLDA 的解。KDLDA 子空间法先采用 KDLDA 提取遥感影像的非线性可分特征,然后在 KDLDA 子空间采用最小距离分类器进行分类识别。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,相比原空间法、LDA 子空间法、直接线性判别分析(Direct Linear Discriminant Analysis, DLDA)子空间法、核线性判别分析(Kernel Linear Discriminant Analysis, KLDA)子空间法, KDLDA 子空间法可显著提高识别效率。

**关键词** 地物分类,非线性可分性特征,核直接线性判别分析,高光谱影像

**中图分类号** TP391.4, TP751.1, TP753 **文献标识码** A

## Kernel Direct LDA Subspace Hyperspectral Image Terrain Classification

LIU Jing

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

**Abstract** In order to reduce the data dimensionality of hyperspectral image and improve recognition efficiency, a new terrain classification method, i. e., KDLDA subspace method, was presented. Firstly, kernel direct linear discriminant analysis (KDLDA) was used to extract nonlinear discriminant features, and then shortest distance classifier was used to perform terrain classification in the KDLDA feature subspace. The solution of KDLDA under the ordinary form of class prior possibility was also deduced. Recognition results based on airborne visible/infrared imaging spectrometer (AVIRIS) hyperspectral image show that, comparing with original space method, LDA subspace method, direct linear discriminant analysis (DLDA) subspace method, and kernel linear discriminant analysis (KLDA) subspace method, the presented KDLDA subspace method can remarkably improve recognition efficiency.

**Keywords** Terrain classification, Nonlinear discriminant feature, Kernel direct linear discriminant analysis (KDLDA), Hyperspectral image

## 1 引言

高光谱影像为遥感影像地物分类带来了丰富的光谱信息,是目前遥感影像地物分类领域的研究热点<sup>[1-4]</sup>,已广泛应用于生态和环境保护、地质矿产调查、城市建设等领域。高光谱影像的一个像素即是高维数据空间中的一个样本,数据维数为光谱波段数,样本个数等于像素个数。高光谱影像地物分类存在如下几个问题:(1)数据维数高。相比多光谱影像,高光谱影像包含更丰富的光谱信息,但数据维数大幅增长,多光谱影像维数通常小于 10,而高光谱影像从几十维到几百维不等。(2)样本个数少。由于遥感地物影像的样本选择费时且昂贵,某些地物的样本个数会低于样本维数。数据维数高、样本个数少,造成高光谱影像地物分类中的小样本问题(Small Sample Size Problem, SSS)<sup>[5,6]</sup>。(3)数据非线性可分。数据空间中样本的散布由各类地物的光谱特性决定,通常呈现非线性可分,因此很难通过线性特征提取方法找到合适的

特征子空间,使得数据映射到子空间中后可分性强。总之,高光谱影像地物分类中存在小样本问题和非线性可分问题。

线性判别分析(Linear Discriminant Analysis, LDA)是经典的线性特征提取方法,旨在提取一组线性可分特征,使得数据采用该组特征表达后,可分性增强。LDA 无法提取数据的非线性可分特征,且不能解决小样本问题。核线性判别分析<sup>[7]</sup>(Kernel Linear Discriminant Analysis, KLDA)为非线性特征提取方法,先用核方法将数据映射到高维核空间,然后在核空间中采用 LDA 提取特征。KLDA 可提取数据的非线性可分特征,但是无法解决小样本问题。直接线性判别分析(Direct Linear Discriminant Analysis, DLDA)<sup>[8]</sup>是 LDA 的一种改进,是为解决人脸识别中的小样本问题而提出的。但是,DLDA 是线性方法,无法提取数据的非线性可分特征。核直接线性判别分析<sup>[9]</sup>(Kernel Direct Linear Discriminant Analysis, KDLDA)是非线性特征提取方法,采用核方法将数据映射到高维核空间,使得呈非线性可分的原始数据在核空间中

到稿日期:2011-08-26 返修日期:2011-12-11 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、遥感影像地物分类、高分辨雷达自动目标识别, E-mail: zyhalj1975@163.com.

线性可分,然后在核空间中采用 DLDA 提取特征,所得特征即为原空间中的非线性可分特征。相比 LDA、KLDA、DLDA、KDLDA 既可有效提取数据的非线性可分特征,又解决了小样本问题。

为解决高光谱影像地物分类中存在的小样本问题和非线性可分问题,本文首次将 KDLDA 应用于高光谱影像地物分类,并提出一种基于 KDLDA 的高光谱影像地物分类方法——KDLDA 子空间法,即:先采用 KDLDA 提取数据的非线性可分特征,然后在 KDLDA 特征子空间中采用最小欧式距离分类器进行分类识别。文献[9]在 KDLDA 的求解过程中,采用各类样本数目与样本总数之比来估计各类先验概率,但许多情况下,类先验概率并不仅由各类样本数目决定。本文推导出类先验概率的一般形式下 KDLDA 的解。采用实测机载可见光/红外成像光谱仪(Airborne Visible/Infrared Imaging Spectroradiometer, AVIRIS)的高光谱影像识别结果表明,相比原空间法、LDA 子空间法[1]、DLDA 子空间法[2]、KLDA 子空间法[4],本文所提 KDLDA 子空间法可显著提高高光谱影像地物识别效率。

## 2 KDLDA

### 2.1 KDLDA 的原理

设  $N$  维原始数据空间中有  $C$  类样本,训练样本集  $\{x_i\}_{i=1}^L$  包含  $L$  个训练样本,即  $x_i \in \mathbf{R}^N$ ,  $\mathbf{R}^N$  为  $N$  维实数空间。非线性映射  $\phi$  将  $N$  维原始数据  $x$  映射到高维核空间  $\mathbf{F}$  后,记为  $\phi(x)$ ,在高维核空间  $\mathbf{F}$  中,数据线性可分。尽管  $\phi(x)$  的显式表达无法得到,但核空间中两个向量  $\phi(x_i)$  和  $\phi(x_j)$  的内积可用核函数  $k(x_i, x_j) = \phi(x_i) \cdot \phi(x_j)$  计算,任何满足 Mercer 条件的函数均可作为核函数,常用核函数有多项式函数、径向基函数(Radial Basis Function, RBF)和 Sigmoid 函数。

核线性判别分析(KLDA)在核空间  $\mathbf{F}$  中实现经典 LDA,核直接线性判别分析(KDLDA)即是在核空间  $\mathbf{F}$  中实现 DLDA。令  $\mathbf{S}_B$  和  $\mathbf{S}_W$  分别表示核空间  $\mathbf{F}$  中数据的类间散布矩阵和类内散布矩阵,则有

$$\mathbf{S}_B = \sum_{i=1}^C P_i (\bar{\phi}_i - \bar{\phi}) (\bar{\phi}_i - \bar{\phi})^T \quad (1)$$

$$\mathbf{S}_W = \sum_{i=1}^C \frac{P_i}{C_i} \sum_{j=1}^{C_i} (\phi_{ij} - \bar{\phi}_i) (\phi_{ij} - \bar{\phi}_i)^T \quad (2)$$

式中,  $P_i$  为第  $i$  类的先验概率;  $\phi_{ij} = \phi(x_{ij})$ ;  $C_i$  为第  $i$  类的样本数,且有  $L = \sum_{i=1}^C C_i$ ;  $\bar{\phi}_i = (1/C_i) \sum_{j=1}^{C_i} \phi(x_{ij})$  为第  $i$  类的均值;  $\bar{\phi} = \sum_{i=1}^C P_i \bar{\phi}_i$  为整体均值。LDA 在高维核空间  $\mathbf{F}$  中寻找一组最优可分基向量  $\{w_k\}_{k=1}^M$ ,使得数据映射到该组基向量支撑的子空间后,类间散布与类内散布之比最大。即寻找线性变换矩阵  $\mathbf{W} = [w_1, \dots, w_M]$ ,使得 Fisher 准则最大,即

$$\mathbf{W} = \arg \max_{\mathbf{W}} \{ \text{tr}[(\mathbf{W}^T \mathbf{S}_W \mathbf{W})^{-1} (\mathbf{W}^T \mathbf{S}_B \mathbf{W})] \} \quad (3)$$

式(3)的解为  $\mathbf{S}_W^{-1} \mathbf{S}_B$  前  $M$  个最大特征值对应的特征向量。 $\mathbf{S}_W^{-1} \mathbf{S}_B$  的特征值分解问题等价于同时对角化  $\mathbf{S}_B$  与  $\mathbf{S}_W$ 。

为求解式(3)中的  $\mathbf{W}$ ,KLDA 先白化  $\mathbf{S}_W$  矩阵,后对角化  $\mathbf{S}_B$  矩阵[10];而 KDLDA 先白化  $\mathbf{S}_B$  矩阵,后对角化  $\mathbf{S}_W$  矩阵。

### 2.2 KDLDA 的求解步骤

文献[9]在 KDLDA 的求解过程中,采用各类样本数目与总体样本数之比来估计各类先验概率,但许多情况下,类先验概率并不仅由各类样本数目决定。本文推导出类先验概率的

一般形式下 KDLDA 的解。KDLDA 的求解步骤为:

步骤 1 在核空间  $\mathbf{F}$  中白化  $\mathbf{S}_B$ 。可将  $\mathbf{S}_B$  重写为

$$\begin{aligned} \mathbf{S}_B &= \sum_{i=1}^C (\sqrt{P_i} (\bar{\phi}_i - \bar{\phi})) (\sqrt{P_i} (\bar{\phi}_i - \bar{\phi}))^T \\ &= \sum_{i=1}^C \tilde{\phi}_i \tilde{\phi}_i^T = \tilde{\Phi}_b \tilde{\Phi}_b^T \end{aligned} \quad (4)$$

式中,  $\tilde{\phi}_i = \sqrt{P_i} (\bar{\phi}_i - \bar{\phi})$ ,  $\tilde{\Phi}_b = [\tilde{\phi}_1, \dots, \tilde{\phi}_C]$ 。设核空间  $\mathbf{F}$  的维数为  $N'$ ,则  $N'$  可以很大,甚至为无穷大,从而很难直接计算  $N' \times N'$  矩阵  $\mathbf{S}_B$  的特征向量。所幸的是,可通过计算  $C \times C$  矩阵  $\tilde{\Phi}_b^T \tilde{\Phi}_b$  的特征向量来计算  $\mathbf{S}_B$  前  $m$  ( $m \leq C-1$ ) 个非零特征值对应的特征向量[11]。采用核函数,对任意两类,类  $l$  和类  $h$ ,可定义一个  $C_l \times C_h$  内积矩阵  $\mathbf{K}_{lh}$ 。

$$\mathbf{K}_{lh} = (k_{ij})_{\substack{i=1, \dots, C_l \\ j=1, \dots, C_h}} \quad (5)$$

式中,  $k_{ij} = k(x_{li}, x_{hj}) = \phi_{li} \cdot \phi_{hj}$ 。对于所有的  $C$  类,可定义一个  $L \times L$  的核矩阵  $\mathbf{K}$

$$\mathbf{K} = (\mathbf{K}_{lh})_{\substack{l=1, \dots, C \\ h=1, \dots, C}} \quad (6)$$

可将  $\tilde{\Phi}_b^T \tilde{\Phi}_b$  表达为

$$\begin{aligned} \tilde{\Phi}_b^T \tilde{\Phi}_b &= \mathbf{B} \cdot [\mathbf{A}_{1C}^T \cdot \mathbf{K} \cdot \mathbf{A}_{1C} - \frac{1}{L} (\mathbf{A}_{1C}^T \cdot \mathbf{K} \cdot \mathbf{1}_{1C}) - \\ &\quad \frac{1}{L} (\mathbf{1}_{1C}^T \cdot \mathbf{K} \cdot \mathbf{A}_{1C}) + \frac{1}{L^2} (\mathbf{1}_{1C}^T \cdot \mathbf{K} \cdot \mathbf{1}_{1C})] \cdot \mathbf{B} \end{aligned} \quad (7)$$

式中,  $\mathbf{B} = \text{diag}[\sqrt{P_1}, \dots, \sqrt{P_C}]$ ;  $\mathbf{1}_{1C}$  是各分量全为 1 的  $L \times C$  矩阵;  $\mathbf{A}_{1C} = \text{diag}[a_{c_1}, \dots, a_{c_C}]$  为  $L \times C$  的分块对角阵,  $a_{c_i}$  为各分量全为  $(1/C_i)$  的  $C_i \times 1$  向量。

令  $\lambda_i$  和  $e_i$  ( $i=1, \dots, C$ ) 分别为  $\tilde{\Phi}_b^T \tilde{\Phi}_b$  的第  $i$  个最大特征值及其对应的特征向量。由于

$$(\tilde{\Phi}_b \tilde{\Phi}_b^T) (\tilde{\Phi}_b e_i) = \lambda_i (\tilde{\Phi}_b e_i) \quad (8)$$

因此  $v_i = \tilde{\Phi}_b e_i$  为  $\mathbf{S}_B$  的特征向量。只保留  $\mathbf{S}_B$  前  $m$  个非零特征值对应的特征向量,即  $\mathbf{V} = [v_1 \dots v_m] = \tilde{\Phi}_b \mathbf{E}_m$ ,其中  $\mathbf{E}_m = [e_1 \dots e_m]$ 。显然,  $\mathbf{V}^T \mathbf{S}_B \mathbf{V} = \Lambda_b$ ,  $\Lambda_b = \text{diag}[\lambda_1^2 \dots \lambda_m^2]$ 。则令  $\mathbf{U} = \mathbf{V} \Lambda_b^{-1/2}$ , 有  $\mathbf{U}^T \mathbf{S}_B \mathbf{U} = \mathbf{I}$ ,  $\mathbf{I}$  为单位矩阵,从而实现白化  $\mathbf{S}_B$ 。

步骤 2 在核空间  $\mathbf{F}$  中对角化  $\mathbf{U}^T \mathbf{S}_W \mathbf{U}$ 。 $\mathbf{U}^T \mathbf{S}_W \mathbf{U}$  可展开为

$$\mathbf{U}^T \mathbf{S}_W \mathbf{U} = (\mathbf{E}_m \Lambda_b^{-1/2})^T (\tilde{\Phi}_b^T \mathbf{S}_W \tilde{\Phi}_b) (\mathbf{E}_m \Lambda_b^{-1/2}) \quad (9)$$

采用核矩阵  $\mathbf{K}$ ,  $\tilde{\Phi}_b^T \mathbf{S}_W \tilde{\Phi}_b$  可表达为

$$\tilde{\Phi}_b^T \mathbf{S}_W \tilde{\Phi}_b = \frac{1}{C} (\mathbf{J}_1 - \mathbf{J}_2) \quad (10)$$

$$\begin{aligned} \mathbf{J}_1 &= \mathbf{B} \cdot [\mathbf{A}_{1C}^T \cdot \mathbf{K} \cdot \mathbf{D} \cdot \mathbf{K} \cdot \mathbf{A}_{1C} - \frac{1}{L} (\mathbf{A}_{1C}^T \cdot \mathbf{K} \cdot \\ &\quad \mathbf{D} \cdot \mathbf{K} \cdot \mathbf{1}_{1C}) - \frac{1}{L} (\mathbf{1}_{1C}^T \cdot \mathbf{K} \cdot \mathbf{D} \cdot \mathbf{K} \cdot \mathbf{A}_{1C}) + \\ &\quad \frac{1}{L^2} (\mathbf{1}_{1C}^T \cdot \mathbf{K} \cdot \mathbf{D} \cdot \mathbf{K} \cdot \mathbf{1}_{1C})] \cdot \mathbf{B} \end{aligned} \quad (11)$$

$$\begin{aligned} \mathbf{J}_2 &= \mathbf{B} \cdot [\mathbf{A}_{1C}^T \cdot \mathbf{K} \cdot \mathbf{D}' \cdot \mathbf{K} \cdot \mathbf{A}_{1C} - \frac{1}{L} (\mathbf{A}_{1C}^T \cdot \mathbf{K} \cdot \mathbf{D}' \cdot \\ &\quad \mathbf{K} \cdot \mathbf{1}_{1C}) - \frac{1}{L} (\mathbf{1}_{1C}^T \cdot \mathbf{K} \cdot \mathbf{D}' \cdot \mathbf{K} \cdot \mathbf{A}_{1C}) + \\ &\quad \frac{1}{L^2} (\mathbf{1}_{1C}^T \cdot \mathbf{K} \cdot \mathbf{D}' \cdot \mathbf{K} \cdot \mathbf{1}_{1C})] \cdot \mathbf{B} \end{aligned} \quad (12)$$

式中,  $\mathbf{D} = \text{diag}[d_1 \dots d_c]$  为  $L \times L$  对角矩阵,  $d_i$  为对角线元素均等于  $1/C_i$  的  $C_i \times C_i$  对角矩阵;  $\mathbf{D}' = \text{diag}[d'_1 \dots d'_c]$  为  $L \times L$  分块对角矩阵,  $d'_i$  为所有元素均等于  $1/C_i$  的  $C_i \times C_i$  矩阵。

设  $\mathbf{U}^T \mathbf{S}_W \mathbf{U}$  前  $M$  ( $M \leq m$ ) 个最小特征值为  $\lambda_1', \dots, \lambda_M'$ , 对应的特征向量为  $\mathbf{P} = [p_1 \dots p_M]$ , 则矩阵  $\mathbf{Q} = \mathbf{U} \mathbf{P}$  满足  $\mathbf{Q}^T \mathbf{S}_W \mathbf{Q} = \Lambda_w$ ,  $\Lambda_w = \text{diag}[\lambda_1' \dots \lambda_M']$ 。

步骤3 在  $M$  维核子空间中,将各类数据分布变为超球形。令  $\Gamma = Q\Lambda_w^{-1/2}$ , 有

$$\Gamma^T S_w \Gamma = I \quad (13)$$

式中,  $\Gamma$  各列为一组最优非线性可分基向量,即数据映射到由该组基向量支撑的子空间后, Fisher 准则最大。

步骤4 将数据映射到 KDLDA 子空间。将任意原始数据  $x$  采用下式映射到 KDLDA 子空间

$$y = \Gamma^T \phi(x) = (E_m \Lambda_b^{-1/2} \cdot P \cdot \Lambda_w^{-1/2})^T (\Phi_b^T \phi(x)) \quad (14)$$

其中

$$\Phi_b^T \phi(x) = B \cdot [A_{1C}^T \cdot \gamma(\phi(x)) - \frac{1}{L} 1_{1C}^T \cdot \gamma(\phi(x))] \quad (15)$$

式中,  $\gamma(\phi(x)) = [\varphi_{11}^T \phi(x) \quad \varphi_{12}^T \phi(x) \quad \dots \quad \varphi_{1C}^T \phi(x)]^T$  为  $L \times 1$  的核向量。根据式(14)和式(15)有

$$y = \Psi \cdot \gamma(\phi(x)) \quad (16)$$

其中

$$\Psi = (E_m \Lambda_b^{-1/2} \cdot P \cdot \Lambda_w^{-1/2})^T [B \cdot (A_{1C}^T - \frac{1}{L} 1_{1C}^T)] \quad (17)$$

为  $M \times L$  矩阵,可通过离线方式计算。

### 2.3 KDLDA 的优势

KDLDA 非常适合于高光谱遥感影像的特征提取,这是因为:

(1) 高光谱遥感数据通常呈现非线性可分,而 LDA、DLDA 为线性方法,很难有效提取非线性可分特征。

(2) 在高光谱遥感影像地物分类中,训练样本个数通常小于数据维数,在高维核空间中更是如此,因而存在较为严重的小样本问题,造成类内散布矩阵  $S_w$  奇异。

(3) 当  $S_w$  奇异时, KLDA 先白化  $S_w$  矩阵,并在白化  $S_w$  时取其前  $m$  个最大特征值对应的特征向量,从而丢弃  $S_w$  的零空间,而  $S_w$  零空间包含重要的分类信息<sup>[12]</sup>。KDLDA 先白化  $S_B$  矩阵,后对角化  $S_w$  矩阵,并在对角化  $S_w$  时取其前  $M$  个最小特征值对应的特征向量,从而避免丢弃  $S_w$  零空间,解决了小样本问题。

总之,相比 LDA、DLDA、KLDA, KDLDA 既可有效提取高光谱影像的非线性可分特征,又解决了高光谱影像地物分类中的小样本问题。

## 3 KDLDA 子空间法

KDLDA 子空间高光谱地物分类方法步骤如下:

表 1 类别编号和测试样本数目

| 类别名称   | Alfalfa | Cornnotill | Commim | Corn | Grass/Pasture | Grass/Trees | Grass/pasture-mowed | Hay-windrowed | Oats | Soybeans-notill | Soybeans-min | Soybean-clean | Wheat | Woods | Bldg-Grass-Tree-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 2 200 维原空间的识别结果

| 类别编号     | 1     | 2     | 3     | 4     | 5    | 6     | 7     | 8     |
|----------|-------|-------|-------|-------|------|-------|-------|-------|
| 各类识别率(%) | 90.7  | 55.88 | 18.59 | 18.18 | 3.77 | 35.45 | 85.71 | 49.62 |
| 类别编号     | 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 |
| 平均识别率(%) | 48.38 |       |       |       |      |       |       |       |

步骤1 特征提取。采用 KDLDA 对训练数据进行特征提取,根据 2.2 节中的步骤计算变换矩阵  $\Psi$ 。

步骤2 建立模板库。将各类训练数据采用式(16)映射到 KDLDA 子空间,以子空间中各类均值为模板建立模板库  $T_C = \{t_i, i=1, 2, \dots, C\}$ ,  $t_i$  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(16)将其映射到 KDLDA 子空间后记为  $y$ 。采用最小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

为验证核 KDLDA 子空间法的有效性,在相同训练数据和测试数据的条件下,本文也采用原空间法、LDA 子空间法、DLDA 子空间法、KLDA 子空间法进行地物分类。本文采用 RBF 核函数,即  $k(x_i, x_j) = \exp\{-\|x_i - x_j\|^2 / \sigma^2\}$ 。

### 4.1 实验数据介绍

本文采用 Indian Pines 高光谱影像,它于 1992 年由 AVIRIS 传感器对印第安那州西北农业区成像所得,具有从 400~2450nm 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。

从原始数据中去除了易被水吸收的波段,包括 104-108 (1360~1400nm), 150-163 (1820~1930nm), 以及 220 (2500nm), 得 200 波段的高光谱数据。选取整个影像进行实验,如图 1 所示。

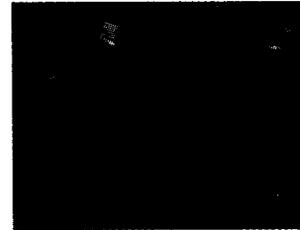


图 1 Indian Pines 影像

### 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 Indian Pines 影像的地物类别编号,以及各类测试样本的数目。

表 2 为 Indian Pines 影像在 200 维原空间,采用最小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%,这是由于 Indian Pines 影像采集于 6 月,这 5 类地物均处于成长的早期,它们

的光谱相似度很高,从而呈现非线性可分。

表3为 Indian Pines 影像在 15 维 LDA 子空间,采用最小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3 15 维 LDA 子空间的识别结果

|          |       |       |       |       |       |       |       |       |
|----------|-------|-------|-------|-------|-------|-------|-------|-------|
| 类别编号     | 1     | 2     | 3     | 4     | 5     | 6     | 7     | 8     |
| 各类识别率(%) | 55.81 | 70.44 | 60.57 | 79.14 | 78.14 | 96.99 | 42.86 | 99.49 |
| 类别编号     | 9     | 10    | 11    | 12    | 13    | 14    | 15    | 16    |
| 各类识别率(%) | 18.75 | 75.84 | 54.46 | 78.21 | 99.41 | 85.60 | 84.87 | 82.89 |
| 平均识别率(%) | 77.71 |       |       |       |       |       |       |       |

表4为 Indian Pines 影像在 10 维 DLDA 子空间,采用最小距离分类器的识别结果。各类地物识别率最低为 50.05%。

表4 10 维 DLDA 子空间的识别结果

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

表5为 Indian Pines 影像在 15 维 KLDA 子空间,采用最小距离分类器的识别结果。RBF 核函数的参数  $\sigma=10$ 。各类地物识别率最低为 50.66%。

表5 15 维 KLDA 子空间的识别结果

|          |       |       |       |       |       |       |       |       |
|----------|-------|-------|-------|-------|-------|-------|-------|-------|
| 类别编号     | 1     | 2     | 3     | 4     | 5     | 6     | 7     | 8     |
| 各类识别率(%) | 81.4  | 62.6  | 63.57 | 55.08 | 89.95 | 91.64 | 90.48 | 90.03 |
| 类别编号     | 9     | 10    | 11    | 12    | 13    | 14    | 15    | 16    |
| 各类识别率(%) | 56.25 | 73.64 | 58.61 | 73.32 | 98.82 | 94.11 | 50.66 | 73.68 |
| 平均识别率(%) | 75.24 |       |       |       |       |       |       |       |

表6为 Indian Pines 影像在 10 维 KDLDA 子空间,采用最小距离分类器的识别结果。RBF 核函数的参数  $\sigma=800$ 。各类地物识别率最低为 55.57%。将表6与表2—表5相比可见,KDLDA 子空间法平均识别率比原空间法提高了 32.68 个百分点,比 LDA 子空间法提高了 8.35 个百分点,比 DLDA 子空间法提高了 3.08 个百分点,比 KLDA 子空间法提高了 5.82 个百分点。

表6 10 维 KDLDA 子空间的识别结果

|          |       |       |       |       |       |       |       |       |
|----------|-------|-------|-------|-------|-------|-------|-------|-------|
| 类别编号     | 1     | 2     | 3     | 4     | 5     | 6     | 7     | 8     |
| 各类识别率(%) | 79.07 | 72.28 | 60.87 | 83.96 | 64.82 | 96.99 | 95.24 | 98.21 |
| 类别编号     | 9     | 10    | 11    | 12    | 13    | 14    | 15    | 16    |
| 各类识别率(%) | 87.5  | 82.04 | 55.57 | 85.95 | 99.41 | 80.1  | 73.36 | 81.58 |
| 平均识别率(%) | 81.06 |       |       |       |       |       |       |       |

这是因为原空间中数据的表达存在大量冗余,数据可分性差;LDA 只能提取数据的线性可分特征,且不能解决小样本问题;DLDA 能解决小样本问题,但是不能提取数据的非线性可分特征;KLDA 能提取数据的非线性可分特征,但不能解决小样本问题;而 KDLDA 既可提取数据的非线性可分特征,又能解决小样本问题。以上的实验结果对比,证明了提出的 KDLDA 子空间法的有效性。

图2示出 KDLDA 与 DLDA 的平均识别率随子空间维数变化的情况。由图2可知,仅当子空间维数等于 1 和 4 时,KDLDA 平均识别率低于 DLDA,其余情况下,KDLDA 平均识别率均明显高于 DLDA。这是由于相比 DLDA 而言,KDLDA 能提取数据的非线性可分特征。可见,对于高光谱遥感影像地物分类,KDLDA 子空间法要优于 DLDA 子空间法。

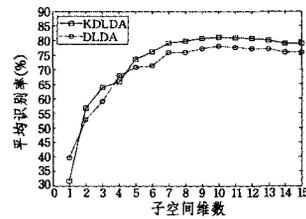


图2 平均识别率随子空间维数的变化

**结束语** 为对高光谱影像进行特征提取,以降低数据维数、提高识别效率,本文推导出类先验概率的一般形式下 KDLDA 的解;并提出了一种新的遥感影像地物分类方法——KDLDA 子空间法,即先采用 KDLDA 提取影像的非线性可分特征,然后在 KDLDA 子空间中采用最小距离分类器进行地物分类。实测高光谱影像的识别结果表明,相比原空间法、LDA 子空间法、DLDA 子空间法、KLDA 子空间法,KDLDA 子空间法能有效地提取数据的非线性可分特征,提高地物分类效率。如何提出更有效的高光谱影像可分性特征提取方法,是值得今后研究的内容。

### 参考文献

- [1] Du Q, Younan N H. Dimensionality reduction and linear discriminant analysis for hyperspectral image classification [J]. Lecture Notes in Computer Science, 2008, 5179: 392-399
- [2] 刘敬. 基于 direct LDA 的高光谱遥感影像地物分类 [J]. 计算机科学, 2011, 38(12): 274-277
- [3] Bandos T V, Bruzzone L, Camps-Valls G, et al. Classification of hyperspectral images with regularized linear discriminant analysis [J]. IEEE Transactions on geoscience and remote sensing, 2009, 47(3): 862-873
- [4] 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
- [5] Liu J, Chen S, Tan X. A study on three linear discriminant analysis based methods in small sample size problem [J]. Pattern Recognition, 2008, 41(1): 102-116
- [6] Das K, Nenadic Z. An efficient discriminant-based solution for small sample size problem [J]. Pattern Recognition, 2009, 42(5): 857-866
- [7] Baudat G, Anouar F. Generalized discriminant analysis using a kernel approach [J]. Neural Computation, 2000, 12(10): 2385-2404
- [8] 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
- [9] Lu J, Plataniotis K N, Venetsanopoulos A N. Face recognition using kernel direct discriminant analysis algorithms [J]. IEEE Transactions on Neural Networks, 2003, 14(1): 117-126
- [10] 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
- [11] Turk M A, Pentland A P. Eigenfaces for recognition [J]. Journal of cognitive neuroscience, 1991, 3(1): 71-86
- [12] Chen L F, Liao H Y M, Ko M T, et al. A new LDA-based face recognition system which can solve the small sample size problem [J]. Pattern Recognition, 2000, 33(10): 1713-1726