

# 基于 MFA 与 $k$ NNS 算法的高光谱遥感影像分类

王立志 黄 鸿 冯海亮

(重庆大学光电技术及系统教育部重点实验室 重庆 400044)

**摘 要** 为了研究高光谱影像数据的维数约简和分类问题,提出了一种基于边际费希尔分析(MFA)和  $k$ NNS 的高光谱遥感影像数据分类算法。该方法利用数据的类别信息,通过 MFA 将高光谱数据从高维观测空间投影到低维流形空间,然后利用邻域内多个近邻点的信息通过  $k$ NNS 分类器对低维空间中的数据进行分类。在 Urban, Washington 和 Indian Pine 数据集上的分类识别实验表明,该方法能够较为有效地发现高维空间中数据的内蕴结构,在每类随机选取 4, 6, 8 个训练样本的情况下,该方法的总体分类精度能够比其他算法提高 3.7%~8.5%,分类精度有了明显的提高。

**关键词** 高光谱影像,地物分类,图嵌入框架,最近邻

中图分类号 TP751.1, TP391.4 文献标识码 A

## Hyperspectral Remote Sensing Image Classification Based on MFA and $k$ NNS

WANG Li-zhi HUANG Hong FENG Hai-liang

(Key Lab. on Opto-electronic Technique and Systems, Ministry of Education, Chongqing University, Chongqing 400044, China)

**Abstract** In order to explore dimensionality reduction and classification in hyperspectral remote sensing image, an algorithm based on marginal Fisher analysis(MFA) and  $k$ -nearest-neighbor simplex( $k$ NNS) was proposed in this paper. First, the data were projected from a high-dimensional space onto low-dimensional space by MFA combined with the information of different classes. Then, classification was performed under the  $k$ NNS classifier by using a few neighbors from each class. The experimental results on the Urban data set, Washington DC Mall data set and Indian Pine hyperspectral data set show the effectiveness of the proposed algorithm. When  $i(i=4, 6, 8)$  samples of each class are randomly selected for training and 100 samples of each class for testing, the overall accuracy of our proposed algorithm is improved by 3.7%~8.5% compared with other methods.

**Keywords** Hyperspectral images, Land cover classification, Graph embedding framework, Nearest neighbor

## 1 引言

高光谱遥感技术是 20 世纪末遥感领域的重大成就之一。高光谱影像分辨率高,且地物光谱曲线是连续的,能够区分同一种地物的不同类别,为研究地物的细微特征提供了有效的途径。目前高光谱遥感技术已被广泛应用于环境监测、海洋遥感、生态调查、精准农业、地质矿岩识别等诸多领域<sup>[1,2]</sup>。然而,高光谱数据的采样间距一般在纳米级,使得相邻波段的相关性很强,并且光谱维数很高,传统的分类识别方法容易陷入维数灾难现象而无法获得理想的分类结果<sup>[3,4]</sup>。因此,如何对高光谱数据实现有效的维数约简,并建立合适的分类模型,成为高光谱遥感影像分类的关键。

国内外学者在对高维数据进行维数约简的研究中,已产生了一系列算法。经典技术主要有主成分分析(Principal Component Analysis, PCA)<sup>[5]</sup>、线性鉴别分析(Linear Discriminant Analysis, LDA)<sup>[6]</sup>等。PCA 和 LDA 都是建立在

“全局线性”这一基本假设基础上的,它们不能发现隐藏在高维数据中的低维流形,无法揭示高光谱数据的内蕴结构<sup>[7,8]</sup>。而用于非线性数据分析的算法有局部线性嵌入(Local Linear Embedding, LLE)<sup>[9]</sup>、等距映射(Isometric Feature Mapping, ISOMAP)<sup>[10]</sup>、拉普拉斯特征映射(Laplacian Eigenmap, LE)<sup>[11]</sup>等。但是上述算法只能得到训练样本的低维嵌入,没有明晰的投影矩阵,不能直接处理新样本,因此难以直接用于分类。He 等提出的邻域保持嵌入算法(Neighborhood Preserving Embedding, NPE)<sup>[12]</sup>和局部保持投影算法(Locality Preserving Projection, LPP)<sup>[13]</sup>可以有效地解决新样本问题。但 NPE 与 LPP 等方法并没有利用数据的类别信息,属于非监督学习算法。Yan 等提出了边际费希尔分析算法(Marginal Fisher Analysis, MFA)<sup>[14]</sup>,将其引入数据的类别作为监督信息,能够提供显式的线性映射,在提取高光谱数据的特征时能够达到较好的效果。

在遥感影像分类研究中已产生一系列理论和算法,如支

到稿日期:2011-08-28 返修日期:2011-12-24 本文受国家自然科学基金(61101168),重庆市科技攻关重点项目(CSTC2009AB2231),重庆市自然科学基金(CSTC2009BB2195)资助。

王立志(1984—),男,硕士,主要研究方向为模式识别、图像处理,E-mail:wanglz@cqu.edu.cn;黄 鸿(1980—),男,博士,主要研究方向为遥感图像处理、模式识别、流形学习,E-mail:hhuang@cqu.edu.cn(通信作者);冯海亮(1962—),男,博士,教授,主要研究方向为应用数学、流形学习、人脸识别等。

持向量机(Support Vector Machine, SVM)<sup>[15]</sup>。SVM是在线性分类器的基础上,引入结构风险最小化原则、最优化理论和核函数演化而成的,但它是线性分类器,且计算量大。径向基函数(Radial Basis Function, RBF)<sup>[16]</sup>等神经网络算法具有较好的自适应性,但在进行分类时,内存占用非常大,对于内存小的计算机会出现内存异常。传统的最近邻分类算法(Nearest-Neighbor, NN)已被广泛应用于解决图像分类的问题中。在特征空间里,它通过度量新样本与每个已知类别的训练样本之间的距离(一般利用欧氏距离或马氏距离等)或相似度进行判别分析,以确定查询对象所属的类别。但是面对多分类问题时,数据的分布特征不确定,使得仅通过搜索到的单个最近邻点所获得的分类结果常常不准确。针对这个问题, Fu 等提出了  $k$ NNS 算法( $k$ -Nearest-Neighbor Simplex,  $k$ NNS)<sup>[17,18]</sup>。该算法利用同类别邻域内多个数据点的信息进行分类鉴别,在 ORL 和 PIE 人脸数据集上进行的实验取得了较好的识别效果。

针对上述问题,本文提出了一种基于 MFA 和  $k$ NNS 的高光谱遥感影像分类算法。该方法利用 MFA 将高光谱数据从高维观测空间投影到低维空间,以提取高光谱数据的鉴别特征,然后通过  $k$ NNS 分类器对低维空间的数据实现分类鉴别。在 Urban、Washington 和 Indian Pine 数据集上的实验结果验证了本文算法能够较为有效地解决高光谱遥感影像的分类问题。

## 2 算法介绍

### 2.1 边际费希尔分析算法(MFA)

MFA 算法以图嵌入框架为基础,对数据点的分布不作任何假设,通过近邻数据点之间的几何关系挖掘数据分布的统计特性,因此 MFA 可以看作是基于局部几何关系的线性鉴别分析算法。MFA 重新定义了描述类内数据紧密性和类间数据分离性的准则,类内紧密性利用同类别数据点与其近邻点之间的距离之和描述;类间分离性利用不同类别的边际数据点与其近邻点之间的距离描述。

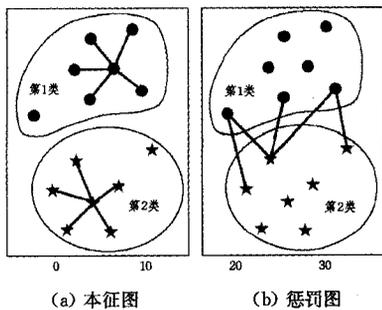


图1 MFA 算法的本征图和惩罚图

结合高光谱数据的特性,将高光谱遥感影像数据生成  $m \times n \times b$  的数据集  $X$ , 其中  $m \times n$  表示影像的空间尺寸,  $b$  表示波段数。然后将影像的每个像素根据其波段生成一个向量,从而将  $X$  转换为  $N \times b$  的二维矩阵  $X = \{x_1, \dots, x_N\}$ , 其中  $N = m \times n$  表示总像素个数。高光谱影像的波段数非常大,所以  $X$  处于高维欧氏空间  $R^D$  中, MFA 方法希望找到一个映射函数  $Y = X^T A$  将  $X$  投影到低维空间  $R^d$  ( $d \ll D$ ) 中,得到低维构造点  $Y = \{y_1, \dots, y_N\}$ , 并揭示隐藏在  $X$  中的低维流

形结构。如图 1 所示, MFA 构建了两类图, 在  $k_1$  的邻域内如果两个样本点属于同类, 则连接起来构成本征图  $G_i$ , 以保持样本点的类内关系; 在  $k_2$  的邻域内如果两个样本点属于不同的类, 则连接起来构成惩罚图  $G_p$ , 以保持样本点的类间关系。MFA 的可分性准则是将同类数据中邻近的数据点拉近, 同时将不同类数据中邻近的数据点推远。

(1) 通过以下函数使同类地物的数据点更加紧密

$$\begin{aligned} \arg \min \sum_i \sum_{i \in N_{k_1}^+(j) \text{ 或 } j \in N_{k_1}^+(i)} \|y_i - y_j\|^2 W_{ij}^I \\ = \arg \min \sum_i \sum_{i \in N_{k_1}^+(j) \text{ 或 } j \in N_{k_1}^+(i)} \text{tr}(y_i^2 + y_j^2 - 2y_i y_j) W_{ij}^I \\ = \arg \min \text{tr}(2Y^T D^I Y - 2Y^T W^I Y) \\ = \arg \min \text{tr}\{2Y^T (D^I - W^I) Y\} \\ = \arg \min \text{tr}\{2a^T X (D^I - W^I) X^T a\} \\ = \arg \min \text{tr}(2a^T X L^I X^T a) \end{aligned} \quad (1)$$

$$W_{ij}^I = \begin{cases} 1, & i \in N_{k_1}^+(j) \cup j \in N_{k_1}^+(i) \\ 0, & \text{其他} \end{cases} \quad (2)$$

式中,  $N_{k_1}^+(i)$  表示样本点  $x_i$  的  $k_1$  最近邻,  $W^I$  是本征图  $G_i$  对应的权重矩阵,  $D^I$  是对角矩阵,  $D_i^I = \sum_j W_{ij}^I$ ,  $L^I = D^I - W^I$  是 Laplacian 矩阵,  $a$  为待求的投影向量。

(2) 通过以下函数使不同地物的数据点保持远离

$$\begin{aligned} \arg \max \sum_i \sum_{(i,j) \in P_{k_2}(c_i) \text{ 或 } (i,j) \in P_{k_2}(c_j)} \|y_i - y_j\|^2 W_{ij}^P \\ = \arg \max \sum_i \sum_{(i,j) \in P_{k_2}(c_i) \text{ 或 } (i,j) \in P_{k_2}(c_j)} \text{tr}(y_i^2 + y_j^2 - 2y_i y_j) W_{ij}^P \\ = \arg \max \text{tr}(2Y^T D^P Y - 2Y^T W^P Y) \\ = \arg \max \text{tr}\{2a^T X (D^P - W^P) X^T a\} \\ = \arg \max \text{tr}(2a^T X L^P X^T a) \end{aligned} \quad (3)$$

$$W_{ij}^P = \begin{cases} 1, & (i,j) \in P_{k_2}(c_i) \cup (i,j) \in P_{k_2}(c_j) \\ 0, & \text{其他} \end{cases} \quad (4)$$

式中,  $P_{k_2}(c)$  表示属于不同地物样本点的  $k_2$  最近邻,  $W^P$  是惩罚图  $G_p$  对应的权重矩阵,  $D^P$  是对角矩阵,  $D_i^P = \sum_j W_{ij}^P$ ,  $L^P = D^P - W^P$  是 Laplacian 矩阵。

MFA 算法的目标函数定义为:

$$a^* = \arg \min_a \frac{a^T X L^I X^T a}{a^T X L^P X^T a} \quad (5)$$

利用 Lagrange 乘子法, 上述最优化问题可以转化为以下方程的特征值求解:

$$X L^P X^T a = \lambda X L^I X^T a \quad (6)$$

解得上式的  $d$  个最大特征值  $\lambda = \{\lambda_0, \lambda_1, \dots, \lambda_{d-1}\}$  所对应的特征向量  $\{a_0, a_1, \dots, a_{d-1}\}$ , 即为所求的将高光谱遥感影像从高维空间投影到低维空间的映射函数  $A = \{a_0, a_1, \dots, a_{d-1}\}$ 。

### 2.2 $k$ NNS 算法

传统的 NN 算法在解决分类问题中应用广泛, 它通过度量新样本与单独的最近邻点之间的距离判别样本所属的类别。对于多分类问题, 数据分布不规则, 仅依靠单个近邻点得到的分类结果, 其准确性下降。而在样本数据充足的情况下, 每个数据点与其近邻点可以构成或近似构成一个局部线性的欧氏空间。由此, Roweis 和 Saul 在《科学》杂志中提出了用近邻点的线性重构系数表征数据点邻域内的几何结构。在此基础上得出了  $k$ NNS 算法, 其利用样本与其邻域内多个近邻点

的重构误差衡量样本与对应类别的吻合程度,减少了因单个不同类近邻点引起的误分,比 NN 算法有更好的鲁棒性。

在光谱遥感影像分类的应用中,对于数据集  $Y = \{y_i; y_i \in R^d\}_{i=1}^N$ ,在局部空间内, $k$ NNS 用数据点  $y_0$  的  $k$  个局部近邻点的线性重构描述  $y_0$ :

$$S(y_1, y_2, \dots, y_k) = \left\{ \sum_{i=1}^k \omega_i y_i \mid \sum_{i=1}^k \omega_i = 1, \omega_i \geq 0 \right\} \quad (7)$$

式中, $S(y_1, y_2, \dots, y_k)$  表示  $y_0$  的重构函数, $\omega_i$  表示近邻点  $y_i$  的权重系数。则数据点  $y_i$  与其近邻重构结果之间的重构误差  $d_{kNNS}$  可通过如下目标函数获得:

$$d_{kNNS} = \operatorname{argmin} \| y_i - \sum_{j=1}^k \omega_{N(j)}^i y_{N(j)}^i \| \quad (8)$$

式中, $\{N(j)\}_{j=1}^k$  表示与  $y_i$  近邻的  $k$  个数据点的集合。重构误差包含了待分类样本与同类或非同类样本在分布上的距离关系。重构误差越小,表明样本与该类数据的距离越近,与该类数据的相似程度也越高,其属于此类别的可能性就越大。由此解决多分类问题。

假设  $L = \{l_i; l_i \in \{1, 2, \dots, q\}\}_{i=1}^N$  为光谱影像  $Y$  对应的类别标签,共含有  $q$  种地物类别。对于新样本数据  $y_i$ ,首先从每类地物数据中通过计算获得与之近邻的  $k$  个数据点的集合  $\{y_{N(j)}^i; l \in \{1, 2, \dots, q\}\}_{j=1}^k$ ,然后利用式(8)计算样本  $y_i$  与每类  $k$  近邻数据集之间的重构误差(或“距离”)  $\{d_{kNNS}^i; l \in \{1, 2, \dots, q\}\}$ ,最后利用以下目标函数即可获得样本  $y_i$  所属的地物类别  $l_i$ :

$$l_i^* = \operatorname{arg} \min_l d_{kNNS}^i \quad (9)$$

相比传统的 NN 算法, $k$ NNS 分类方法的优越性以二分类为例进行说明。如图 2 所示,位于两个三角形中间的点  $P$  属于圆点类。 $k$ NNS 方法分别用两类中与  $P$  点近邻的数据点线性重构点  $P$ 。 $P$  点与方块类的距离(或“重构误差”)为  $a$ ,与圆点类的重构误差为  $b$ 。因为  $b < a$ ,所以将  $P$  归为重构误差小(或“距离近”)的圆点类。而在利用欧氏距离分类的 NN 方法中, $P$  与方块类近邻点的最短距离为  $a$ ,与圆点类近邻点的最短距离为  $c$ , $a < c$ ,导致将  $P$  误分成方块类。

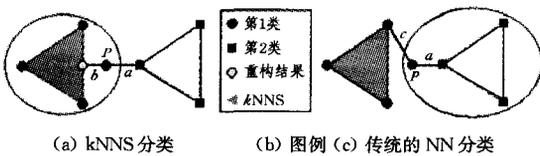


图 2  $k$ NNS 与传统 NN 方法的对比

### 2.3 算法步骤

表 1 列出了本文所提算法的具体实现步骤。

表 1 本文算法的实现步骤

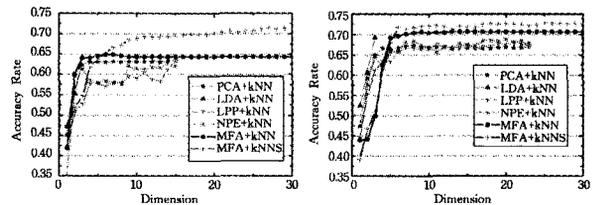
输入: 高维数据集 $X$ 和对应的类别标签 $L$
输出: 从高维观测空间到低维空间的映射函数 $A$ , 低维空间构造点 $Y$
1) 从数据集中随机选取一定数量的训练样本和测试样本;
2) 构建类内近邻图和类间远邻图;
3) 利用式(6)边缘鉴别准则计算从高维观测空间到低维空间的映射函数;
4) 利用映射函数计算训练样本和测试样本的低维空间构造点;
5) 利用 $k$ NNS 方法对测试样本数据进行分类。

## 3 实验与分析

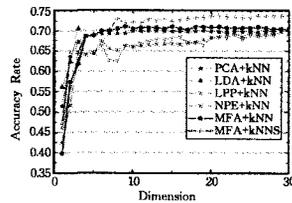
为了验证本文算法的有效性,采用 Urban、Washington 和 Indian Pine 数据集进行实验,并将提出的算法和 PCA、LDA、LPP 以及 NPE 进行比较。

### 3.1 Urban 数据集

Urban 数据集是由 HYDICE 传感器获取的高光谱影像,空间分辨率为 3m,覆盖了某城郊居住区。该影像大小为  $307 \times 307$  像素,波谱范围从 400nm 到 2500nm,共包含 210 个波段。剔除 48 个(1-4, 76, 87, 101-111, 136-153, 198-210)受大气吸收影响的波段,将剩下的 162 个波段用于实验研究。本实验分别从“道路”、“建筑”、“树木”和“草地”等 4 类已知地物中随机选取 4, 6, 8 个数据点作为训练样本,100 个数据点作为测试样本,分别以 4 train、6 train、8 train 表示,每种方法都重复实验 10 次,最终的分精度取 10 次实验的平均值。实验设置如下:分别用 PCA、LDA、LPP、NPE 以及 MFA 对 Urban 数据集进行降维,然后利用传统的  $k$  近邻分类器进行分类。为了对比  $k$ NNS 和传统  $k$  近邻分类器的分类效果,同时采用 MFA 降维,并用  $k$ NNS 进行分类。图 3 给出了采用各种方法对高维数据降维到不同维数下进行分类的总体分类精度。表 2 列出了各种方法在各维数下总体精度的最高值。



(a) 每类选取 4 个训练样本和 100 个测试样本 (b) 每类选取 6 个训练样本和 100 个测试样本



(c) 每类选取 8 个训练样本和 100 个测试样本

图 3 采用不同的方法在不同的维数下对 Urban 数据集进行分类的总体分类精度

表 2 各种方法分类的最高总体精度(%)

算法	最高总体精度(%)		
	4 train	6 train	8 train
PCA+kNN	63.3	67.3	70.0
LDA+kNN	64.3	69.3	70.5
LPP+kNN	63.5	68.5	68.8
NPE+kNN	62.8	68.8	69.8
MFA+kNN	64.8	70.8	71.0
MFA+kNNS	71.3	73.0	74.5

由图 3 和表 2 可得,所有算法随着训练样本数量的增加,其总体分类精度也随之增加,因为训练样本的数量越多,就越能表征数据的整体分布情况,通过各种算法学习得到的样本鉴别特征就越有效,进而越能提高分类精度。PCA 和 LDA 的分类效果优于 LPP 和 NPE 算法,其原因是 LPP 和 NPE 只利用了训练数据的局部近邻结构信息,忽略了数据的整体结构信息。而 PCA 算法利用了所有训练样本的整体分布信息,而 LDA 算法为监督算法,利用了所有训练样本的类别信息提取鉴别特征,所以这两种方法的分类效果反而更好。

MFA 通过近邻样本之间的几何关系表征数据的分布特征,利用样本的类别信息,在拉近同类样本的同时推远不同类

样本,在一定程度上克服了LDA无法解决的样本多模分布问题,因此在都采用传统 $k$ 近邻分类的情况下,MFA算法的分类精度高于其他算法。但是 $k$ 近邻分类仅利用单个最近邻点的信息,而 $k$ NNS度量样本点与其邻域内多个数据点的相似度减少了因少数不同类数据点引起的误分,因此采用MFA降维和 $k$ NNS分类的算法在各种情形下的分类效果都明显优于其他算法。在4个训练样本的情况下,本文算法的总体分类精度比MFA+kNN提高了约6.5%,比其他算法提高了约7.0%;在6个训练样本的情况下,MFA+kNNS的总体分类精度比MFA+kNN提高了约2.2%,比其他算法提高了约3.7%;在8个训练样本的情况下,本文算法比MFA+kNN的总体分类精度提高了约3.5%,比其他算法提高了约4.0%。

### 3.2 Washington 数据集

Washington数据集也是由HYDICE传感器获取的高光谱影像,获取时间为1995年8月23日,空间分辨率为4m,覆盖了华盛顿特区国家广场的局部。该影像大小为1280×307像素,波谱范围从400nm到2400nm,共包含210个波段,覆盖了建筑、道路、小路(广场中的砾石小径)、草地、树木和水体等6类确定类别的地物。剔除19个(103-106,138-148,207-210)受大气吸收影响的波段,将剩下的191个波段用于实验研究。本实验分别从6类已知地物中随机选取4,6,8个数据点作为训练样本,100个数据点作为测试样本,每种方法都重复实验10次,最终的分类精度取10次实验的平均值。图4给出了采用各种方法对高维数据降维到不同维数下进行分类的总体分类精度。表3列出了各种方法在各维数下总体精度的最高值。

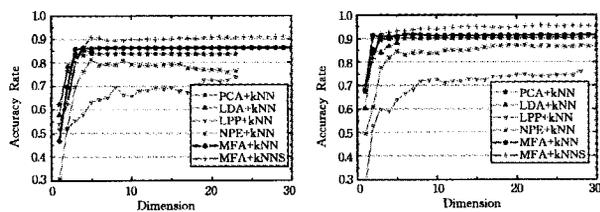


图4 采用不同的方法在不同的维数下对华盛顿国家广场数据集进行分类的总体分类精度

(a) 每类选取4个训练样本和100个测试样本

(b) 每类选取6个训练样本和100个测试样本

(c) 每类选取8个训练样本和100个测试样本

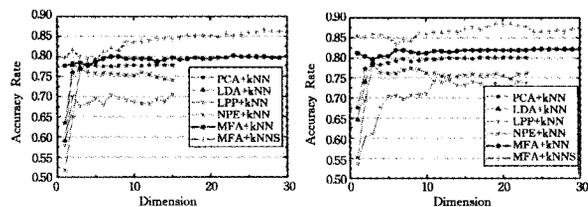
算法	最高总体精度(%)		
	4 train	6 train	8 train
PCA+kNN	84.0	90.3	92.8
LDA+kNN	85.3	88.0	90.8
LPP+kNN	73.8	76.0	79.0
NPE+kNN	81.3	87.3	90.3
MFA+kNN	86.3	91.5	94.0
MFA+kNNS	91.0	95.5	98.3

从图4和表3可以看出,各算法的总体分类精度随训练

样本数量的增加而增加。而MFA+kNNS算法的分类效果优于其他算法,在4,6,8个训练样本的情况下,其总体分类精度比MFA+kNN分别提高了约4.7%,4.0%,4.3%,比其他算法分别提高了约5.7%,5.2%,5.5%。

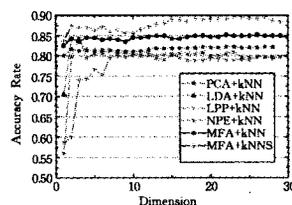
### 3.3 Indian Pine 数据集

Indian Pine数据集是由美国国家航空航天局在1992年6月12日通过AVIRIS传感器获取的美国Indiana州西北100km<sup>2</sup>区域的高光谱影像,其影像大小为145×145像素,波谱范围从400nm到2450nm,共包含220个波段,覆盖了16类确定类别的地物。将第104至108、第150至163以及第220波段等20个波段剔除,以消除大气吸收的影响,剩下的200个波段用于实验研究。本实验从地物数据点较多的类别中随机选择4类地物,再从这4类地物中随机选取4,6,8个数据点作为训练样本,100个数据点作为测试样本,每种方法都重复实验10次,最终的分类精度取10次实验的平均值。图5给出了采用各种方法对高维数据降维到不同维数下分类的总体分类精度。表4列出了各种方法在各维数下总体精度的最高值。



(a) 每类选取4个训练样本和100个测试样本

(b) 每类选取6个训练样本和100个测试样本



(c) 每类选取8个训练样本和100个测试样本

图5 采用不同的方法在不同的维数下对Indiana数据集进行分类的总体分类精度

表4 各种方法分类的最高总体精度(%)

算法	最高总体精度(%)		
	4 train	6 train	8 train
PCA+kNN	78.0	80.0	82.3
LDA+kNN	77.8	79.0	84.5
LPP+kNN	70.5	74.5	80.8
NPE+kNN	76.8	77.3	84.5
MFA+kNN	80.5	82.3	85.3
MFA+kNNS	86.5	88.5	89.8

由图5和表4可得,MFA+kNNS算法的总体分类精度最高,比MFA+kNN分别提高了约6.0%,6.2%,4.5%,比其他算法分别提高了约8.5%,8.5%,5.3%。

**结束语** 本文通过对高光谱数据的维数约简和分类模型中常用算法的分析,提出了一种基于MFA和 $k$ NNS的高光谱遥感影像分类算法。该方法将高维数据投影到低维空间,充分利用数据的类别信息,使同类数据点更加紧密而不同类数据点更加稀疏,并利用 $k$ NNS分类模型,通过度量新样本与

各类别邻域之间的距离来判定其所属类别。在 Urban、Washington 和 Indian Pine 数据集上的分类识别实验,说明了本文的方法能够较为有效地解决高光谱遥感影像分类的问题。在随机选取 4,6,8 个训练样本的情况下,本文方法的总体分类精度能够比其他算法提高 3.7%~8.5%。

但是本文的算法需要计算新样本与每个邻域的欧氏距离,计算复杂度偏大。而且当已知样本数量很少时,这种欧氏距离度量标准也可能会失效。如何解决这些问题,需要进一步研究。

## 参 考 文 献

- [1] 梁亮,杨敏华,李英芳. 基于 ICA 与 SVM 算法的高光谱遥感影像分类[J]. 光谱学与光谱分析,2010,30(10):2724-2728
- [2] 梁亮,刘志霄,杨敏华,等. 基于可见/近红外反射光谱的稻米品种与真伪鉴别[J]. 红外与毫米波学报,2009,28(5):353-356
- [3] 王志辉,丁丽霞. 基于叶片高光谱特性分析的树种识别[J]. 光谱学与光谱分析,2010,30(7):1825-1829
- [4] 余旭初,杨国鹏,冯伍法,等. 基于简约集支持向量机的高光谱影像分类[J]. 计算机科学,2010,37(11):268-270
- [5] Turk M, Pentland A. Eigenfaces for recognition[J]. Journal of Cognitive Neuroscience, 1991, 3(1):71-86
- [6] Belhumeur P, Hespanha J, Kriegman D. Eigenfaces vs. Fisherfaces: Recognition using class specific linear projection[J]. IEEE Trans. on Pattern Analysis and Machine Intelligence, 1997, 20(7):711-720
- [7] Ma Li, Crawford M M, Tian Jin-wen. Local manifold learning-based k-nearest-neighbor for hyperspectral image classification [J]. IEEE Trans. on Geoscience and Remote Sensing, 2010, 48(11):4099-4109
- [8] Ma Li, Crawford M M, Tian Jin-wen. Generalized supervised lo-

cal tangent space alignment for hyperspectral image classification[J]. Electronics Letters, 2010, 46(7):497-498

- [9] Roweis S, Saul L. Nonlinear dimensionality reduction by locally linear embedding[J]. Science, 2000, 290(5500):2323-2326
- [10] Tenenbaum J, Silva V D, Langford J C. A global geometric framework for nonlinear dimensionality reduction[J]. Science, 2000, 290(5500):2319-2323
- [11] Belkin M, Niyogi P. Laplacian eigenmaps for dimensionality reduction and data representation[J]. Neural Computation, 2003, 15(6):1373-1396
- [12] He Xiao-fei, Cai Deng, Yan Shui-cheng, et al. Neighborhood preserving embedding[C] // Proceedings of the 10th IEEE Int'l Conf. Computer Vision (ICCV'05), 2005. Beijing, 2005: 1208-1213
- [13] He Xiao-fei, Yan Shui-cheng, Hu Yu-xiao, et al. Face recognition using laplacianfaces[J]. IEEE Trans. on Pattern Analysis and Machine Intelligence, 2005, 27(3):328-340
- [14] Yan Shui-cheng, Xu Dong, Zhang Ben-yu, et al. Graph Embedding and Extensions: A General Framework for Dimensionality Reduction[J]. IEEE Trans. on Pattern Analysis and Machine Intelligence, 2007, 29(1):40-51
- [15] 沈照庆,王建宾,陶建斌. 基于光谱相关性的 SVM 高光谱遥感影像分类[J]. 地理空间信息, 2009, 7(4):88-91
- [16] 谭琨,杜培军. 基于径向基函数神经网络的高光谱遥感图像分类[J]. 光谱学与光谱分析, 2008, 28(9):2009-2013
- [17] Fu Yun, Yan Shui-cheng, Huang T S. Classification and Feature Extraction by Simplexization[J]. IEEE Trans. on Information Forensics and Security, 2008, 3(1):91-100
- [18] Fu Yun, Yan Shui-cheng, Huang T S. Discriminant Simplex Analysis[C] // Proceedings of the IEEE Conf. ICASSP, 2008. Las Vegas, NV, 2008:3333-3336

(上接第 246 页)  
实际应用问题。

## 参 考 文 献

- [1] 张雄伟,陈亮,杨吉斌. 现代语音处理技术及应用[M]. 北京:国防工业出版社,2003
- [2] 刘华平,李昕,徐柏龄,等. 语音信号端点检测方法综述及展望[J]. 计算机应用研究, 2008, 25(8):2278-2283
- [3] 严剑峰,付宇卓. 一种新的基于信息熵的带噪语音端点检测方法[J]. 计算机仿真, 2005, 22(11):117-119
- [4] 朴春俊,马静霞,徐鹏. 带噪语音端点检测方法研究[J]. 计算机应用, 2006, 26(11):2685-2690
- [5] Andreeut M, Este R A, Kauffman S A. Competitive optimization of compressed sensing[J]. Journal of Physics A: Mathematical and Theoretical, 2007(40):299-305
- [6] Zhao H, Zhao X, Zhao K, et al. Voice activity detection based on distance entropy in noisy environment[C] // 5<sup>th</sup> International Joint Conference on INC, IMS and IDC. Seoul, Korea; IEEE Computer Society, 2009:1364-1367
- [7] 乔峰. 基于信息熵和神经网络的语音端点检测算法研究[D]. 太

原:太原理工大学,2007

- [8] 董恩清,赵鹤鸣,周亚同,等. 支持向量机在语音激活检测中的应用研究[J]. 通信学报, 2003, 24(3):70-77
- [9] Giacobello D, Christensen M G, Murthi M N, et al. Retrieving Spame Patterns Using a Compressed Sensing Framework: Applications to Speech Coding Based on Spame Linear Prediction [J]. Signal Processing Letters, IEEE, 2010, 17(1):103-106
- [10] 向昌盛,周子英,张林峰. 相空间重构和支持向量机参数联同步优化研究[J]. 湖南科学大学学报, 2010, 25(4):81-85
- [11] 陈宝远,梁伟明. 基于小波分析的语音端点检测算法研究与仿真[J]. 哈尔滨理工大学学报, 2009(1):51-59
- [12] Krishnamoorthy P, Prasanna S R M. Application of combined temporal and spectral processing methods for speaker recognition under noisy, reverberant or multi-speaker environment [J]. Indian Academy of Sciences, 2009, 10(34):729-754
- [13] 隋海峰,曲武,钱文彬,等. 基于混合 SVM 方法的蛋白质二级结构预测算法[J]. 计算机科学, 2011, 38(10):169-174
- [14] 郑继明,邢峰,吴渝,等. 基于小波变换和支持向量机的音频分类[J]. 重庆邮电大学学报:自然科学版, 2008, 20(2):212-216