

文章编号:1001-9014(2013)05-0450-06

DOI:10.3724/SP.J.1010.2013.00450

## 基于图像欧氏距离的高光谱图像流形降维算法

陈宏达<sup>1</sup>, 普晗晔<sup>1</sup>, 王斌<sup>1,2\*</sup>, 张立明<sup>1</sup>

(1. 复旦大学电子工程系, 上海 200433;  
2. 复旦大学波散射与遥感信息重点实验室, 上海 200433)

**摘要:** 提出两种基于图像欧氏距离的非线性降维方法。该方法利用高光谱图像物理特性, 将图像欧氏距离引入到传统的流形降维算法中。与其它应用于高光谱图像的降维算法相比, 该算法具有诸多优点。图像欧氏距离的引入, 在考虑高光谱图像本身的空间关系的同时, 很好地保持了数据点之间的局部特性, 可以实现有效地去除原始数据集光谱维和空间维的冗余信息。实际高光谱数据的实验结果表明, 该算法应用于高光谱图像分类时, 与其它常见的方法相比具有更高的分类精度。

**关键词:** 高光谱遥感图像; 非线性降维; 图像欧氏距离; 分类

中图分类号: TP751 文献标识码: A

### Image Euclidean distance-based manifold dimensionality reduction algorithm for hyperspectral imagery

CHEN Hong-Da<sup>1</sup>, PU Han-Ye<sup>1</sup>, WANG Bin<sup>1,2\*</sup>, ZHANG Li-Ming<sup>1</sup>

(1. Dept. of Electronic Engineering, Fudan University, Shanghai 200433, China;  
2. The Key Laboratory of Wave Scattering and Remote Sensing Information, Fudan University, Shanghai 200433, China)

**Abstract:** Two nonlinear dimensionality reduction methods were proposed based on image Euclidean distance. Considering the physical characters of hyperspectral imagery, the methods introduced image Euclidean distance into traditional manifold dimensionality reduction. Compared with other methods, our methods have several advantages. The introduction of image Euclidean distance not only considers hyperspectral image's spatial relationship, but also preserves the local feature of datasets well. Thus the proposed methods can discard efficiently the redundant information from both the spectral and spatial dimensions. The experiment results demonstrated that the proposed methods have higher classification accuracy than other methods when applied to hyperspectral image classification.

**Key words:** hyperspectral imagery; nonlinear dimensional reduction; image Euclidean distance; classification

**PACS:** 80.40. Xb

## 引言

高光谱遥感是指成像光谱仪在电磁波谱的紫外、可见光、近红外和中红外(甚至热红外)区域中的数十至数百个非常窄且连续的光谱段上获取图像数据的技术。高光谱图像的每一个像元都可以提取出一条完整连续的光谱曲线, 为地物信息的提取和分析提供了极其丰富的信息, 有助于更加精细的地

物分类和目标识别。然而, 波段数的增多必然导致了信息的冗余和数据处理复杂性的增加。

高光谱图像的较高的光谱分辨率在增强地物细微差别分辨能力的同时, 也带来了维数灾难(Hughes 现象), 这种现象严重影响了高光谱图像的分类精度。解决这种现象的方法通常有两种, 一种方法是增加训练样本, 另一种方法是对原始高光谱图像进行特征降维处理。然而在实际情况下, 并不能提

收稿日期: 2012-06-15, 修回日期: 2012-10-08

Received date: 2012-06-15, revised date: 2012-10-08

基金项目: 国家自然科学基金(No. 61071134); 上海市教委科研创新项目(No. 13ZZ005); 高等学校博士学科点专项科研基金(20110071110018)

Foundation items: Supported by the National Natural Science Foundation of China (Grant No. 61071134); the Innovation Program of Shanghai Municipal Education Commission (Grant No. 13ZZ005); and the Research Fund for Doctoral Program of Higher Education of China (Grant No. 20110071110018)

作者简介(Biography): 陈宏达(1987-), 男, 浙江温州人, 复旦大学电子工程系硕士研究生, 主要研究领域为高光谱遥感图像处理。E-mail: 10210720029@fudan.edu.cn

\* 通讯作者(Corresponding author): E-mail: wangbin@fudan.edu.cn

供大量的训练样本以满足高光谱图像高维数的需求,因此人们多采用高光谱图像特征降维这一方法。高光谱数据的降维对于高光谱图像分类等应用具有特殊的意义,在高光谱图像处理中具有十分重要的作用<sup>[1]</sup>。

高光谱数据降维技术是以图像特征提取为目的,利用低维数据来有效地表达高维数据特征的数据处理技术。它在有效地保留了图像信息的同时也压缩了数据量,更有利于信息的快速提取。常见的降维算法可以分为线性和非线性两大类。主成分分析(Principal Component Analysis, PCA)<sup>[2]</sup>是一种最基本的高维数据线性降维方法。它的主要目标是通过线性变换寻找一组最优的单位正交向量基,并用它们的线性组合来重构原样本,以使重建后的样本和原样本的误差最小。其它代表性的线性降维算法还有独立成分分析(Independent Component Analysis, ICA)<sup>[3]</sup>,线性判别分析(Linear Discriminant Analysis, LDA)<sup>[4]</sup>等。

非线性降维方法主要分为核函数算法<sup>[5]</sup>和流形降维方法<sup>[6-7]</sup>。前者的通常做法是将核函数方法引入线性降维算法中,而后者则将高维数据看作一种局部具有欧几里得空间性质的空间,即认为高维观测空间中的点位于一个由少数独立变量的共同作用而张成的流形上。流形降维算法能够利用数据集的局部几何结构来揭示其内在的流形结构,从而发现内在的主要变量,实现对空间“卷曲”的数据集进行降维。代表性算法有局部线性嵌入(Locally Linear Embedding, LLE)算法<sup>[6]</sup>,等距映射(Isometric Feature Mapping, ISOMAP)算法<sup>[7]</sup>等。LLE是一种利用流形的局部线性性将高维度空间流形展开到低维度空间的算法。它是基于这样的流形假设:流形空间中,数据点可以通过其邻域完全重建。于是可以通过在降维空间中尽可能保持其局部线性特征来实现降维。ISOMAP算法是一种在经典的MDS算法的基础上,通过保持流形上两点间的测地线距离来展开流形的全局算法。ISOMAP算法保证了降维结果的稳健性和全局最优性,但是其运算复杂度较高。邻接点个数 $k$ (或者邻域距离 $\epsilon$ )和预置的内在维度是LLE和ISOMAP算法的两个主要参数。

高光谱图像在提供了巨大的信息量的同时也会产生大量的冗余信息。PCA就是从信息量入手以降低波段相关性为目的对原始高光谱数据进行降维处理的,但是,这样的变换使得高光谱图像中的一些感兴趣的小目标有可能在做主成分分析时被忽略掉。

从物理意义上讲,空间上很近的像素在很大程度上属于同类地物。高光谱图像反映的是空间中地物的复杂程度,因此在对高光谱数据做降维处理时,既要考虑去除光谱维的冗余信息,也要考虑到空间维的冗余信息,以提高后续处理如分类等的精度和效率。此外,线性降维算法(如PCA等)用线性变换的方法找到一个新的投影空间来减少信息的冗余。然而,在高光谱数据中存在大量的非线性现象,如:由太阳-冠层-传感器几何效应产生的辐射非线性变化、单个像素中地物之间的多次散射以及作为吸收介质的水的存在使得海岸湿地处呈现较强的非线性混合现象等<sup>[8]</sup>,简单地采用线性变换的降维方法无法很好地处理这一情况,从而导致在实际应用中产生较大的误差。因此,有必要使用非线性方法处理高光谱数据中的非线性现象,其中,流形降维算法(如LLE和ISOMAP算法)已经被理论和实验证明其较为符合高光谱数据结构特征A<sup>[8]</sup>,可以很好地保持原始数据集的局部几何特性,对原始数据集中的非线性现象也有较好的处理结果。然而流形算法没有兼顾到高光谱数据集的物理特征,而只是仅仅从数据本身的几何结构出发处理数据。

为了克服上述算法的弱点,提出了两种新的基于图像欧氏距离的非线性降维算法,它们是对LLE算法和ISOMAP算法的改进版本。所提议算法将图像欧氏距离(IMage Euclidean Distance, IMED)<sup>[9]</sup>应用到高光谱图像中,结合高光谱图像的物理特性,在流形算法的基础之上实现高光谱数据集的降维。在降维过程中它综合考虑到了高光谱数据集的几何结构和像素点的空间关系,有效地去除原始数据集中的冗余信息。与其它降维算法(如PCA、LLE、ISOMAP)相比,所提出的算法得到的降维结果应用于高光谱图像分类时,具有更高的分类精度。

## 1 算法描述

### 1.1 基于图像欧氏距离的高光谱图像距离矩阵算法

在介绍算法之前,我们首先介绍图像欧氏距离。IMED是Wang等于2005年提出的<sup>[9]</sup>,它的核心思想是将空间关系引入图像块距离计算之中。与欧氏距离相比,图像欧氏距离是一种直观的且鲁棒性很好的距离算法,可以较好地应用于模式识别以及分类中。

对于大小均为 $M \times N$ 的灰度图像 $X \in R^{M \times N}$ 和 $Y \in R^{M \times N}$ 来说,它们之间的图像欧氏距离定义为:

$$d_{IMED}(X, Y) =$$

$$\sqrt{\sum_{m=1}^3 \sum_{n=1}^3 \left[ \sum_{i=1}^M \sum_{j=1}^N g_{ij,mn}(X_{ij} - Y_{ij})(X_{mn} - Y_{mn}) \right]} \quad (1)$$

其中,  $X_{ij}$  和  $Y_{ij}$  分别表示图像  $X$  和  $Y$  中第  $i$  行、第  $j$  列的灰度值,  $g_{ij,mn}$  为相应空间乘子.

空间关系是通过空间乘子  $g_{ij,mn}$  引入的, 它被定义为

$$g_{ij,mn} = \exp\left(-\frac{|i-m|^2 + |j-n|^2}{2t}\right) \quad (2)$$

其中  $t$  是空间因子, 表征了空间关系的影响程度. 该空间因子的物理意义是: 空间上离的较“近”的像素点之间的影响也较“大”, 反之亦然. 由于空间因子只是表明了一种相对的远近关系, 因此图像欧式距离对其并不敏感, 一般可取 3~6 之间的实数.

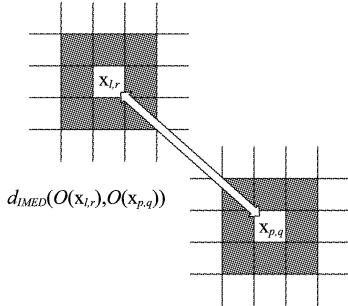


图 1 高光谱图像中的图像欧式距离  
Fig. 1 Image Euclidean distance in hyperspectral images

与文献[9]中的图像欧式距离的应用不同, 本文将其应用到高光谱图像块之间的距离计算, 即将观测像素之间的欧式距离转化为以观测像素为中心的图像块之间的图像欧式距离, 如图 1 所示. 对于水平宽度、垂直宽度和波段数分别为  $W$ 、 $H$  和  $L$  的高光谱数据集  $X \in R^{W \times H \times L}$  来说, 当使用  $3 \times 3$  的图像块时, 数据点  $x_{e,r} \in R^{L \times 1}$  和  $x_{p,q} \in R^{L \times 1}$  之间的图像欧式距离定义为:

$$d_{\text{IMED}}(O(x_{l,r}), O(x_{p,q})) = \sqrt{\sum_{m=1}^3 \sum_{n=1}^3 \left[ \sum_{i=1}^3 \sum_{j=1}^3 g_{ij,mn} (x_{l-2+i,r-2+j} - x_{p-2+i,q-2+j})^T \right]} \quad (3)$$

其中  $O(x_{l,r})$  和  $O(x_{p,q})$  分别表示  $x_{l,r}$  和  $x_{p,q}$  的八邻域, 空间因子  $g_{ij,mn}$  构成  $9 \times 9$  的方阵  $G$ , 其计算公式同式(2).

由图 1 和式(3)可以看出, 图像欧式距离很好地引入了以观测像素为中心的八邻域之间的距离关系. 而且这种将图像欧式距离引入高光谱图像的做

法也符合该距离本身的定义<sup>[9]</sup>. 在实际应用中, 空间因子的选择要根据图像中地物的实际分布情况具体选择. 通常的做法是: 对于地物分布较为集中或呈大片分布的数据, 选择较小的  $t$ , 因为此时图像块中的像素之间的空间关系较为显著; 而对于地物分布较为零散的数据, 则需要选择较大的  $t$  以表征较为弱的空间关系.

需要说明的是, 图像的边缘像素也可以成为图像块中心来应用图像欧式距离. 在初始化阶段首先要做的是镜像扩展图像, 即将大小为  $X \in R^{W \times H \times L}$  的高光谱图像扩充为  $X' \in R^{(W+2) \times (H+2) \times L}$ , 得到图像欧式距离矩阵 (IMage Euclidean Distance Matrix, IMEDM)  $D_{\text{IMED}} \in R^{N \times N}$ , 其中  $N = W \times H$  为总像素个数. 对于  $X'$  来说, 需要计算的是第  $(2, 2)$  个像素点到第  $(W+1, H+1)$  个像素点之间图像的欧式距离, 即不包括边缘的像素点, 因此可以得到  $N \times N$  的距离矩阵. 对于使用大小为  $(2P+1) \times (2P+1)$ , ( $P=1, 2, 3, \dots$ ) 的图像块的情况, 图像的镜像扩展具体步骤如下: 1) 创建全零矩阵  $X' \in R^{(W+2P) \times (H+2P) \times L}$ , 将原图像数据  $X$  复制到从  $X'(P+1, P+1)$  到  $X'(W+P, H+P)$  的矩形区域. 2) 对于  $i=1, 2, 3, K, P$  的每个  $i$ , 执行下面的运算. 复制  $X'$  的第  $(P+1+i)$  行到第  $(P+1-i)$  行, 复制  $X'$  的第  $(W+P-i)$  行到第  $(W+P+i)$  行. 复制  $X'$  的第  $(P+1+i)$  列到第  $(P+1-i)$  列, 复制  $X'$  的第  $(W+P-i)$  列到第  $(W+P+i)$  列. 这样得到的图像数据  $X'$  就是图像数据  $X$  的镜像扩展.

下面, 我们给出算法的流程.

算法 I 基于图像欧式距离的 LLE 算法 (IMED-based LLE Algorithm, IMED-LLE)

输入: 水平宽度、垂直宽度和波段数分别为  $W$ 、 $H$  和  $L$  的高光谱图像数据矩阵  $X \in R^{W \times P \times L}$ , 邻接点个数  $k$ , 数据集内在维数  $d$

输出: 低维映射空间数据集  $Y = (y_1, y_2, \dots, y_N)$

步骤 1: 镜像扩充图像, 将数据扩充为  $X' \in R^{(W+2) \times (H+2) \times L}$  图像, 使得处于边缘的像素也可以应用 IMED.

步骤 2: 根据式(2) 计算空间关系矩阵  $G$  的所有元素.

步骤 3: 对于原始数据集上的任意两个观测像素点  $x_{i,r}$  和  $x_{p,q}$ , 根据式(3) 计算  $d_{\text{IMED}}(O(x_{i,r}), O(x_{p,q}))$ , 得到图像欧式距离矩阵  $D_{\text{IMED}} \in R^{N \times N}$ , 并在全样本点中寻找每个样本点的  $k$  个邻近点.

步骤 4: 与原始 LLE 算法类似, 通过求解最小化

问题得到约束的权值矩阵。然后,通过求解一个特征值分解问题得到最优嵌入结果  $Y = (y_1, y_2, \dots, y_s) \in R^{N \times d}$ 。具体算法参见参考文献 [6]。

算法 II 基于图像欧氏距离的 ISOMAP 算法 (IMED-based ISOMAP Algorithm, IMED-ISOMAP)

输入: 高光谱图像数据矩阵  $X \in R^{W \times H \times L}$ , 邻接点个数  $k$ , 数据集内在维数  $d$

输出: 低维映射空间数据集  $Y = (y_1, y_2, \dots, y_N) \in R^{N \times d}$

步骤 1~2: 同算法 I.

步骤 3: 对于原始数据集上的任意两个观测像素点  $x_{l,r}$  和  $x_{p,q}$ , 根据式(3)计算图像欧氏距离  $d_{\text{IMED}}(O(x_{l,r}), O(x_{p,q}))$ , 得到图像欧氏距离矩阵  $D_{\text{IMED}} \in R^{N \times N}$ .

步骤 4: 基于  $D_{\text{IMED}}$  构建邻域图、计算最短路径矩阵和执行 MDS 算法得到最优嵌入结果  $Y = (y_1, y_2, \dots, y_N) \in R^{N \times d}$ .

由算法流程可以看出, 引入 IMED 可以影响到 LLE 算法的邻域选择, 而对于 ISOMAP 算法来说, IMED 的引入则还可以影响到求解低维嵌入坐标的过程。

## 1.2 算法复杂度

算法复杂度包括运算复杂度和空间复杂度。通常, 算法中涉及的浮点操作次数 (floating-point operations, flops) 被用来作为衡量算法复杂度。由于乘法消耗资源要远大于加法或者减法, 在计算复杂度时只计算算法中涉及的乘法操作的次数 (包括除法以及开方运算)。空间复杂度则由算法执行时所需要的内存空间大小来衡量。通常是以所涉及的矩阵大小来衡量。

本文提出的算法的复杂度主要取决于计算图像欧氏距离矩阵 (IMEDM)。以使用  $3 \times 3$  图像块为例, 由公式(3)可知, 计算两个像素对之间的图像欧氏距离共需要  $8L + 8L$  次乘法。对于一个具有  $N$  个像素的高光谱图像来说, 总的复杂度为  $O(LN^2)$ 。空间复杂度主要取决于一个  $N \times N$  的矩阵和一个  $N \times 9$  的矩阵。由此可知, 较大的数据量, 即较大的  $N$  将带来较高的运算复杂度和空间复杂度。

## 2 实验验证

在本节中, 我们采用实际的高光谱数据测试算法的性能。我们将本文提出的算法与 PCA、LLE 和 ISOMAP 算法进行比较, 它们都是应用于高光谱数据降维的常见的且性能较优的算法。我们在降维基

础之上, 利用分类算法对降维结果执行分类操作。通过分析分类的精度评价这 3 种算法的性能。采用的分类算法为支撑向量机 (Support Vector Machine, SVM)<sup>[10]</sup> 和最近邻分类法 (K-Nearest Neighborhood, KNN)<sup>[11]</sup>。SVM 算法的重要参数有  $c$  和  $g$ 。 $c$  是 SVM 算法中的惩罚参数,  $c$  越大表明离群点对目标函数影响越大。 $g$  是影响 SVM 算法中 RBF 核函数的参数。实验中我们使用交叉验证方法 (Cross Validation) 选择较优的统一的 SVM 算法参数, 具体采用的参数在每个实验中说明。KNN 算法的参数为用于判定对象所属类别所需要的邻近点个数  $K$ , 我们统一采用参数 1。评价分类结果的指标为分类精度。

### 2.1 Indiana 农业区数据

实验数据为 1992 年 6 月拍摄于印第安纳州西部城市西拉斐特西北方向的一片农田的高光谱遥感数据。该数据有 220 个波段, 波长范围从 0.4~2.5  $\mu\text{m}$ , 光谱分辨率为 10 nm, 空间分辨率为 17 m, 图像大小为  $145 \times 145$  像素。覆盖该区域的主要是一些农作物 (包括玉米、小麦、大豆、干草堆) 和天然植被 (树林、草地等)。除此之外, 还有一些人工用地。该数据已被广泛地用于遥感图像的分类研究。Purdue 大学给出一份关于该区域的实地调查报告<sup>[12]</sup>。在进行处理之前, 该数据的波段 104~108、150~163 和 220 由于信噪比太低或为水吸收波段而被移除, 剩下 200 个波段被用于进一步处理。

在下面的试验中, 我们首先对一块大小为  $36 \times 36$  的子图做降维分类实验, 以比较 5 种算法, 即 IMED-ISOMAP、IMED-LLE、ISOMAP、LLE 和 PCA 算法的性能, 然后对整幅图像做测试。在执行分类时, 我们随机选取 1/4 数据作为训练样本, 剩下的作为测试样本。空间因子选择和分类算法参数选择将在以下各节中介绍。

### 2.2 分块数据实验

该分块数据的大小为  $36 \times 36 \times 200$ 。这个子图包含 8 种地物: 3 种玉米, 两种草地, 干草, 两种大豆。该区域的特点是, 地物分布零散且类别较多, 各类之间的影响较大。而且存在不同状态的同种地物, 如 3 种玉米: Corn-notill、Corn-min 和 Corn。

首先在该分块数据上测试邻域大小对 4 种算法即 IMED-ISOMAP、IMED-LLE、ISOMAP 和 LLE 算法的分类精度的影响。然后在该分块数据上测试空间因子  $t$  对两种改进的算法即 IMED-ISOMAP、IMED-LLE 的分类精度的影响。最后对算法中图像块大小的选择做出分析说明。采用的分类算法是 SVM 和

KNN 算法,其中 SVM 的参数为:  $c = 32$ ,  $g = 1$ , KNN 的参数为:  $K = 1$ .

邻域个数  $k$  对分类精度的影响如图 2 所示,其中降维维度为 15, 空间因子  $t = 2$ . 由图 2 可见, 邻域大小对 ISOMAP 和 IMED-ISOMAP 的影响较小, 而对 LLE 和 IMED-LLE 算法的影响则相对较大. 这是因为 LLE 算法对邻域的选择较为敏感.

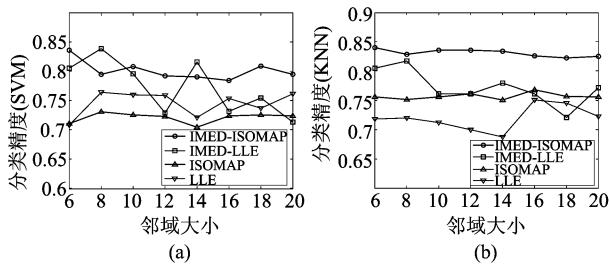


图 2 五种算法在不同邻域大小下的分类结果:(a) SVM, (b) KNN

Fig. 2 Classification accuracy of different algorithms with different neighborhood  $k$ , (a) SVM, and (b) KNN

空间因子  $t$  对分类精度的影响如图 3 所示, 其中降维维度为 15, 邻域大小为 8. 图中可以看出 IMED-LLE 算法对空间因子  $t$  的选择更为敏感.

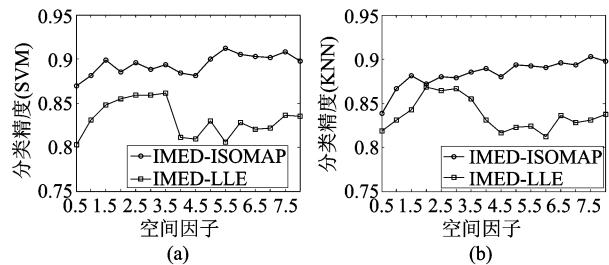


图 3 5 种算法在不同空间因子下的分类结果:(a) SVM, (b) KNN

Fig. 3 Classification accuracy of different algorithms with different space parameter  $t$ , (a) SVM, and (b) KNN

根据图 2 和图 3, 我们可以确定适合该数据的邻域大小为 8, 这是因为一方面  $k = 8$  时已经可以得到较好的分类精度, 另一方面较大的邻域将造成运算的迅速增加, 在精度基本保证的前提下, 选择较小的邻域更合理. 而由图 5, 我们可以确定适合该数据的空间因子范围为<sup>2,4</sup>, 在这个范围内 IMED-ISOMAP 和 IMED-LLE 两种算法都可以达到较高的精度.

接下来我们测试不同的降维维度下以上 5 种算法对应的分类精度. 本次实验中流形降维参数为: 邻域个数  $k = 8$ , 空间因子  $t = 3$ . SVM 的参数为:  $c = 32$ ,

$g = 1$ , KNN 的参数为:  $K = 1$ . 对于不同的降维维度(1 ~ 50), 两种分类方法的得到曲线图如图 4 所示.

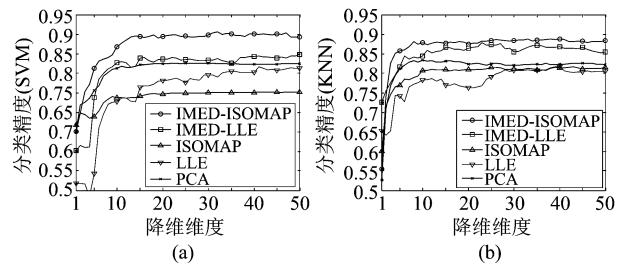


图 4 5 种算法在不同降维维度下的分类结果:(a) SVM, (b) KNN

Fig. 4 Classification accuracy of different algorithms with different dimensions, (a) SVM, and (b) KNN

可以看出我们提出的两种算法的结果要优于其它三种算法: PCA、LLE 和 ISOMAP. 这表明引入图像欧氏距离之后, 高光谱图像的降维效果有了很大提升. 其中, 提升效果最明显的地物类别是玉米和大豆. 而且, 还可以看出: 引入 IMED 对 ISOMAP 的改善程度要大于 LLE 算法. 这是由于对于 LLE 算法来说, IMED 的引入只是影响到其邻域选择部分, 而 ISOMAP 算法中邻接矩阵、最短距离矩阵以及低维坐标的嵌入都涉及到图像欧氏距离, 从而更好地保持原始数据集中的几何结构, 由此也可以得到更好的地结果.

另外, 这里还测试了计算图像欧式距离时, 分别使用  $5 \times 5$  和  $7 \times 7$  的图像块距离的情况. 当图像块为  $7 \times 7$  时, 由于引入太多周围数据, 中心像素的作用不明显, 距离计算有较大偏差, 导致分类精度下降. 当图像块为  $5 \times 5$  时, 其结果与  $3 \times 3$  的结果相当. 鉴于运算复杂度的考虑, 我们采用  $3 \times 3$  图像块. 在实际应用中, 图像块大小的选择最终取决于图像数据. 对于分辨率低, 地物类别交叉多的图像, 使用过大的图像块会引入错误信息, 导致结果变差. 由于  $3 \times 3$  已经引入了相当多的图像空间信息, 我们考虑在通常情况下, 使用  $3 \times 3$  图像块是较为合理可靠的选择.

### 2.3 全图分类

在这一部分, 我们对整个 Indiana 数据进行降维分类, 研究 5 种算法的性能. 根据地物真实报告, 全图中确定存在的地物有 16 类. 本次实验中流形降维参数为: 邻域个数  $k = 8$ , 空间因子  $t = 4$ . SVM 的参数为:  $c = 16$ ,  $g = 1/4$ , KNN 的参数为:  $K = 1$ . 为了更精确地说明分类的效果, 表 1 给出了降维维度为 25

时,16类地物的KNN具体分类结果.

**表1 5种算法对应的KNN分类结果( $d=25$ )**

**Table1 Comparisons of five algorithms for classification accuracy by KNN classifier ( $d=25$ )**

Algorithms	PCA	LLE	ISOMAP	IMED-LLE	IMED-ISOMAP
Alfalfa	0.71	0.35	0.53	0.38	0.94
Corn-notill	0.60	0.45	0.49	0.64	0.71
Corn-min	0.60	0.40	0.49	0.64	0.69
Corn	0.49	0.34	0.37	0.47	0.66
Grass/Pasture	0.86	0.74	0.80	0.91	0.94
Grass/Tress	0.92	0.87	0.90	0.92	0.99
Grass/pasture-mowed	0.57	0.62	0.57	0.86	0.86
Hay-windrowed	0.96	0.94	0.97	0.98	1.00
Oats	0.47	0.20	0.27	0.60	0.93
Soybeans-notill	0.74	0.60	0.62	0.76	0.84
Soybeans-min	0.71	0.59	0.64	0.79	0.81
Soybeans-clean	0.47	0.31	0.38	0.47	0.58
Wheat	0.93	0.85	0.91	0.98	0.99
Woods	0.90	0.87	0.90	0.94	0.96
Bldg-Grass-Tree-Drives	0.45	0.33	0.38	0.47	0.77
Stone-steel towers	0.91	0.93	0.86	0.90	0.96
Accuracy(average%)	72.13	60.77	65.10	75.86	82.19

在16种地物的分类结果中,所提出算法得到的结果绝大多数是优于PCA的,这和子图实验结果是一致的.但对于个别地物,如IMED-LLE算法中的Alfalfa和Corn,我们的算法提升了LLE中特别弱的这两类分类精度,但是还不如PCA,这主要是因为地物分布的区域非线性表现不明显,而且空间关系的影响也较弱.总体上来说,我们提出的两个算法的分类精度要优于PCA和所对应的原算法,具有较为重要的实际应用价值.而对于IMED-LLE和IMED-ISOMAP的比较,IMED-ISOMAP有明显的分类精度优势,但是计算复杂度相对较高.

### 3 结论

提出了两种基于图像欧氏距离的高光谱遥感图像非线性降维方法.该方法结合高光谱数据的物理特性,将图像欧氏距离引入非线性降维算法中以更好地去除高光谱数据集中冗余的空间信息和光谱维度信息.实际高光谱数据实验表明,所提出的方法在

应用到高光谱图像的分类时能够取得良好的效果,并且性能优于其它已有的高光谱图像降维方法.因此该算法具有较大的实际意义.

同时,还可以看到,由于图像欧氏距离计算的引入,使得整个算法的复杂度提高.如何降低运算复杂度,以实现算法的实时性是我们将来需要解决的工作之一.

### REFERENCES

- [1] Chang C I. Hyperspectral imaging: techniques for spectral detection and classification [M]. New York: Plenum, 2003.
- [2] Jolliffe I T. Principal Component Analysis [M]. Springer, 2nd ed. 2002.
- [3] Hyvärinen, Karhunen J, Oja E. Independent Component Analysis [M]. New York: Wiley, 2001.
- [4] Belhumeur P N, Hespanha J P, Kriegman D J. Eigenfaces vs. Fisherfaces: Recognition Using Class Specific Linear Projection [J]. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 1997, **19**(7):711–720.
- [5] Müller K R, Mika S, Ratsch G, et al. An introduction to kernel-based learning algorithms [J]. *IEEE Trans. on Neural Networks*, 2001, **12**(2):181–201.
- [6] Sam T R, Lawrence K S. Nonlinear Dimensionality Reduction by Locally Linear Embedding [J]. *Science*, 2000, **290**(5500):2323–2326.
- [7] Tenenbaum J B, de Silva V, Langford J C. A global geometric framework for nonlinear dimensionality reduction [J]. *Science*, 2000, **290**(5500):2319–2323.
- [8] Bachmann C M, Ainsworth T L, Fusina R A. Improved Manifold Coordinate Representations of Large-Scale Hyperspectral Scenes [J]. *IEEE Trans. on Geosci. Remote Sens.*, 2006, **44**(10):2786–2802.
- [9] Wang L, Zhang Y, Feng J. On the Euclidean distance of images [J]. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 2005, **27**(8):1334–1339.
- [10] Melgani F, Bruzzone L. Classification of hyperspectral remote sensing images with support vector machines [J]. *IEEE Trans. on Geosci. Remote Sens.*, 2004, **42**(8):1778–1790.
- [11] Cover T, Hart P. Nearest neighbor pattern classification [J]. *IEEE Trans. on Inf. Theory*, 1967, **13**(1):21–27.
- [12] Landgrebe D. Multispectral data analysis: A signal theory perspective [M]. West Lafayette: School of Electrical & Computer Engineering, Purdue University, 56–89, 1998.