

半监督邻域保持嵌入在高光谱影像分类中的应用

冯海亮 潘竞文 黄 鸿

(重庆大学光电技术及系统教育部重点实验室 重庆 400044)

摘 要 为了解决高光谱遥感影像的维数约简问题以提高分类算法的分类精度,并针对高光谱影像通常只包含少量标记样本的问题,提出了一种半监督邻域保持嵌入(SSNPE)和改进的 KNN 分类器的高光谱影像分类算法。该算法在 NPE 的基础上同时利用同类标记样本和邻域未标记样本获得数据的邻域嵌入结构,并且通过增加标记近邻样本的权重加大降维数据的鉴别性,进而增加 k 近邻分类器的样本分类精度。在 Urban、Indian 高光谱影像数据集上的实验结果表明,改进的算法的分类精度提高了约 8.7%、3.6% 以上,分类性能有了较明显的改善。

关键词 高光谱影像分类,维数约简,邻域保持嵌入,半监督学习

中图法分类号 TP751.1,TP391.4 文献标识码 A

Hyperspectral Image Classification Based on Semi-supervised Neighborhood Preserving Embedding

FENG Hai-liang PAN Jing-wen HUANG Hong

(Key Laboratory on Opto-Electronic Technique and Systems of Ministry of Education, Chongqing University, Chongqing 400044, China)

Abstract In order to solve the dimension reduction problem of hyperspectral image to improve the classification algorithm's classification accuracy rate and the problem that hyperspectral image usually contains little labeled samples, we proposed a hyperspectral image algorithm based on a semi-supervised neighborhood preserving embedding algorithm and improved k -Nearest Neighborhood classifier. This algorithm uses both the labeled samples and the unlabeled samples of the neighborhood based on Neighborhood Preserving Embedding to get the neighborhood embedding structure, and improve the classification feature through raising weight of the labeled neighboring samples, and thus improving the sample accuracy rate of KNN classifier. The experimental results on the Urban and Indian Pine data sets show that the accuracy rate of the proposed method is improved by more than about 8.7%, 3.6%, respectively, and thus the classification performance has been improved clearly.

Keywords Hyperspectral image classification, Dimension reduction, Neighborhood preserving embedding, Semi-supervised learning

1 引言

遥感是一种与目标保持一定距离,通过非直接接触来分析目标性质的技术。而高光谱遥感影像是通过卫星了解地面物体的光谱特征情况,并由这些图片组成光谱空间。高光谱遥感影像分类的过程是将图像中的区域划分为若干类别中的一类,目的则是将图像空间划分为若干子区域,每个子区域代表一种实际地表物体^[1]。目前,高光谱遥感影像已越来越多地应用于环境监测等诸多领域^[2]。然而,由于高光谱数据相邻波段的相关性强及光谱维数高的问题,传统的分类方法无法获得理想的分类结果,因而容易陷入维数灾难现象^[3]。因此,如何从大量高光谱遥感影像数据中提取出有用信息并提高影像分类精度^[4],成为高光谱影像分类的一个关键。

目前,常用的维数约简方法包括主成分分析(Principal

Component Analysis, PCA)^[5]和线性判别分析(Linear Discriminant Analysis, LDA)^[6],但是 PCA 和 LDA 都是建立在全局线性的前提下。有研究发现高维数据集常常具有一些低维的非线性结构,低维结构数学上称为流形^[7]。如果能够从高维采样数据中发现数据的低维流形结构,就可在维数约简的同时发现高维数据的本质^[8],有利于数据的分类。

自 2000 年以来,出现了很多非线性流形降维算法,例如局部线性嵌入(Local Linear Embedding, LLE)^[9]、等距映射(Isometric Feature Mapping, ISOMAP)^[10]、拉普拉斯特征映射(Laplacian Eigenmap, LE)^[11]等。但是由于其运算复杂,并且无法直接求得测试样本的映射特征,不能直接应用于分类问题,因而制约了这些算法在识别中的应用^[12]。He 等提出的邻域保持嵌入算法(Neighborhood Preserving Embedding, NPE)^[13]和局部保持投影算法(Locality Preserving Projec-

本文受国家自然科学基金(61101168,41371338),重庆市基础与前沿研究计划项目(cstc2013jcyjA40005)资助。

冯海亮(1962—),男,博士,教授,主要研究方向为应用数学、流形学习等;潘竞文(1988—),女,硕士,主要研究方向为流形学习、模式识别, E-mail: pjw1234567890@163.com; 黄 鸿(1980—),男,博士,副教授,主要研究方向为流形学习、遥感影像处理。

tion, LPP)^[14]可以有效地解决新样本问题。其中改进的邻域保持嵌入算法有正交邻域保持嵌入降维方法(Orthogonal Neighborhood-Preserving Embedding, ONPE)^[15], 监督的改进算法有鉴别近邻排列(Discriminative Locality Alignment, DLA)^[16]。但是在实际应用中,对遥感影像全部标记所需的代价很大,因此本文使用半监督算法对遥感影像样本进行处理。

综上所述,为了利用少数标记样本和改进算法性能,本文提出了一种新型的半监督邻域保持嵌入(Semi-Supervised Neighborhood Preserving Embedding, SSNPE)算法。在 Urban、Indian 高光谱影像数据集上的实验结果表明,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

为方便介绍,给定 $X = \{x_1, x_2, \dots, x_N\}$ 是由 D 维向量组成的数据集,寻找一个投影矩阵 A ,将这些数据映射到一个相对低维的特征空间 $R^d (d \ll D)$ 中。数据集在 R^d 中表示为矩阵 $Y = \{y_1, y_2, \dots, y_N\}$,且 $Y = A^T X$ 。

2.1 邻域保持嵌入(NPE)

NPE 算法的目标是在降维中保留局部流形结构,具体计算步骤为:

步骤 1 构造一张具有 N 个节点的邻域图 G ,其中第 i 个节点对应数据点 x_i 。如果向量 x_j 属于向量 x_i 的 k 近邻,则连接两点。其中监督 NPE 算法为若向量 x_j 与向量 x_i 的类别标签相同,则连接两点。

步骤 2 设 W 为权值矩阵,则每条边的权值为 w_{ij} ,并设定没有边连接的 w_{ij} 为 0。利用以下准则求取权值:

$$\min \sum_i \|x_i - \sum_j^K w_{ij} x_j\|^2 \quad \text{s. t.} \quad \sum_j^K w_{ij} = 1 \quad (1)$$

其中, K 是 x_i 的近邻点的个数, x_j 是 x_i 的第 j 个近邻。

步骤 3 NPE 算法认为如果 w_{ij} 能在 D 维空间里重建数据点 x_i ,则假设它同时可以重建该点在 d 维空间中对应的点。因此,线性变换 A 可以通过求解如下最小化问题获得:

$$\begin{aligned} \Phi(y) &= \sum_j^K (y_i - \sum_j^K w_{ij} y_j)^2 \\ &= Y^T (I - W)^T (I - W) Y \\ &= A^T X M X^T A \end{aligned} \quad \text{s. t.} \quad A^T X X^T A = 1 \quad (2)$$

最小目标函数的变换向量求解可以转换为下面广义特征向量的最小特征值的求解问题:

$$X M X^T a = \lambda X X^T a \quad (3)$$

其中, a 是变换矩阵的基向量。 d 个最小的非零特征值所对应的特征向量 a_1, a_2, \dots, a_d 构成变换矩阵 $A = \{a_1, a_2, \dots, a_d\}$ 。

2.2 半监督邻域保持嵌入(SSNPE)

NPE 算法在映射前后保持了数据的局部结构,但算法没

有考虑数据的类别信息,是一种非监督的学习算法。而监督 NPE 算法标记样本的类别标签代价过高。

为了利用部分标记样本和改进 NPE 算法在模式分类中的分类鉴别性,改变 NPE 算法中近邻点选择和权值设置,在保持原始数据点流形结构的基础上从流形结构中提取对分类有用的信息。因此本文提出的半监督邻域保持嵌入只改变 NPE 算法的前两个步骤:

步骤 1 构造一张邻域图 G ;如果向量 x_i 是标记样本,则选择与向量 x_i 类别相同的 $l-1$ 个标记样本连接,其中 l 是训练样本中每类标记样本的个数,再选择 k 个近邻点连接,其中 k 个近邻点中不包括与 x_i 类别不同的标记样本,即连接 $K = l-1+k$ 个近邻点;如果向量 x_i 是未标记样本,则选择 K 个近邻点连接。

步骤 2 设 W 为权值矩阵,则每条边上的权值为 w_{ij} ,并设定没有边连接的 w_{ij} 为 0,依然按照式(1)求得权值。若向量 x_i 是标记样本, x_j 与 x_i 相连且类别相同,则权重

$$w_{ij} = w_{ij} + \beta * 0.1 \quad (4)$$

$$w_{ij} = \beta * w_{ij} \quad (5)$$

决定给予适当的增加;若向量 x_i 是未标记样本,则权重 w_{ij} 保持不变。

步骤 3 保持 NPE 算法步骤 3 不变,依旧取式(3)的 d 个最小的非零特征值所对应的特征向量 a_1, a_2, \dots, a_d 构成变换矩阵 $A = \{a_1, a_2, \dots, a_d\}$ 。

将求出的特征值按照从小到大的顺序排列,根据实验要求或最优结果选择降维的维数 d ,选取前 d 个特征值所对应的特征向量构成映射矩阵 A 。

表 1 半监督邻域保持嵌入算法

输入: N 个训练样本的数据集
$X = \{(x_1, l_1), (x_2, l_2), \dots, (x_L, l_L), x_{L+1}, \dots, x_N\}, x_i \in R^D$, 嵌入特征维数 d
输出: 投影矩阵 A , 嵌入特征 Y
1. 对于部分已知地物类别的标记样本数据,利用 $l-1$ 个同类标记数据和 k 个近邻点数据构建邻域图 G ;
2. 构造 G 的权重矩阵 W ;
3. 对于部分已知地物类别标记样本数据,增加同类近邻点的权重,并确定系数 β ;
4. 计算 d 维嵌入,求解式(4)特征方程中 d 个最大特征值对应的特征向量,构成投影变换矩阵 $A = \{a_1, a_2, \dots, a_d\}$,即可计算嵌入特征 $Y = A^T X$ 。

2.3 半监督 k 近邻分类器(SSKNN)

分类技术的另一个核心问题是构造分类器^[17]。传统的 KNN 算法在解决分类问题中应用广泛,它通过度量新样本与近邻点之间的距离判别样本所属的类别。由于本文使用半监督算法,因此选取测试样本点近邻训练样本点中标记样本点多数为所属类别;若近邻训练样本中无标记样本,则取测试样本近邻点中第一个标记样本为所属类别。

3 实验与分析

为了验证本文算法的有效性,采用了 Urban、Indian Pine 数据进行实验,并将本文算法和 PCA、LDA、LPP、NPE 以及 SSMC (Semi-Supervised Maximum Margin Criterion)^[18]、SSMPE (Semi-Supervised Sub-Manifold Preserving Embedding)^[19] 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 307×307 像素,波谱范围从 400nm 到 2500nm,共包含 210 个波段。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 16(其中 6 个有类别标记,10 个无标记)、18(8 个标记,10 个无标记)、20(10 个有标记,10 个无标记) 个数据点作为训练样本,每类 100 个数据点作为测试样本,分别以 6 labels、8 labels、10 labels 表示,每种方法都重复实验 10 次,最终分类精度取 10 次实验的平均值。

实验设置如下,分别用 PCA、LDA、LPP、NPE、SSMMC、SSMPE 和 SSNPE1、SSNPE2 对 Urban 数据集样本进行降维,其中 SSNPE 方法 1 中 β 取 0.5,方法 2 中 β 取 1.1。然后利用 k 近邻分类器进行数据分类,其中 k 取 10。图 1 给出了采用不同算法对高维数据降维到不同维数下进行分类的分类精度,表 2 给出了利用不同方法降维在各维数下分类精度的最高值。




图 1 采用不同方法在不同维数下对 Urban 数据集进行分类的分类精度

表 2 各种算法对 Urban 数据集样本分类的最高分类精度

算法	6 labels	8 labels	10 labels
	分类精度(%)	分类精度(%)	分类精度(%)
PCA	64.97±0.14	67.87±0.15	69.35±0.11
LDA	67.03±0.31	68.05±0.44	67.67±0.71
LPP	59.48±0.41	62.58±0.20	61.60±0.13
LPP-sup	66.30±0.40	67.77±0.42	68.00±0.46
NPE	64.78±0.20	67.35±0.16	70.77±0.10
NPE-sup	41.60±0.24	52.22±0.91	60.15±0.17
SSMMC	64.60±0.24	68.65±0.45	67.85±0.24
SSMPE	63.62±0.29	66.65±0.20	68.80±0.18
NPE-ss1	74.15±0.19	76.47±0.06	78.27±0.09
NPE-ss2	70.87±0.10	73.30±0.25	75.00±0.06

由图 1、表 2 可知,算法的分类精度一般随着训练样本数量的增加而增加,这是因为训练样本数量越多,数据能够提供的具有代表性的先验信息就越多,就越能表征数据的分布情况,通过各算法得到的样本鉴别特征就更有效,进而提高了分类精度。PCA 和 LDA 分类效果优于 LPP 算法,其原因是对于 Urban 数据来说,LPP 只利用训练样本的局部信息,忽略了数据的整体结构信息。NPE 算法分类效果优于 LPP 算法说明流形的嵌入结构相比于邻域结构更能揭示数据集的原始维数,监督型 NPE 分类效果不如 NPE 的原因是标记样本数过少导致监督 NPE 训练样本选择的标记样本不在其邻域内,而监督型 LPP 由于旨在保持流形的邻域结构,因此不存在这个问题。SSMMC 与 SSMPE 是基于最大类间边缘准则的半监督邻域保持算法,与 LDA 算法相似,但由于考虑了邻域保持而略优于 LDA 算法。本文半监督邻域保持算法增大了同

类样本的权值,而使降维数据在保持嵌入结构的基础上更有鉴别性,因此 SSNPE 算法的分类精度优于 NPE 和其他算法。

在 6、8、10 个样本有类别标记,10 个样本没有类别标记的情况下,SSNPE 算法分类精度比 NPE 和监督 NPE 方法提高了约 8.7%、25.0%,比 LDA、LPP 和监督 LPP 方法提高了约 8.7%、15.1%、8.9%,比其他算法提高了约 8.9%、9.3%、9.9%。

3.2 Indian Pine 数据集

Indian Pine 数据集是美国国家航空航天局通过 AVIRIS 传感器获取的美国 Indiana 州西北区域的高光谱影像,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。本实验从地物数据点较多的类别中选出了 6 类。从这 6 类地物中随机选取 16、18、20 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,最终分类精度取 10 次实验的平均值。其中 SSNPE 方法 1 中 β 取 0.8,方法 2 中 β 取 1.2。然后利用 k 近邻分类器进行数据分类,其中 k 取 1。图 2 给出了不同方法对高维数据降维到不同维数下进行分类的分类精度,表 3 给出了各种方法在各维数下分类精度的最高值。

从图 2 和表 3 可以看出,SSNPE 算法能够充分利用少量有类别标记样本和大量无标记样本,使得其分类效果优于其他算法,在 6、8、10 个样本有类别标记,10 个样本没有类别标记的情况下,其分类精度比 NPE 和监督 NPE 方法提高了约 11.2%、18.4%,比 LDA、LPP 和监督 LPP 方法提高了约

4.5%、21.4%、3.6%，比其他算法提高了约 9.4%、9.5%、10.4%。




图 2 采用不同方法在不同维数下对 Indian 数据集进行分类的分类精度

表 3 各种算法对 Indian 数据集样本分类的最高分类精度

算法	分类精度(%)		
	6 labels	8 labels	10 labels
PCA	74.73±0.08	76.33±0.08	78.62±0.08
LDA	80.92±0.09	81.97±0.09	81.65±0.10
LPP	64.90±0.19	63.95±0.07	65.00±0.05
LPP-sup	83.05±0.10	82.52±0.08	81.65±0.10
NPE	74.18±0.06	74.60±0.08	75.65±0.14
NPE-sup	66.68±0.65	66.63±0.39	69.48±0.14
SSMMC	73.65±0.11	75.22±0.11	77.98±0.08
SSSMPE	74.88±0.09	76.25±0.10	78.83±0.11
NPE-ss1	85.35±0.04	86.25±0.10	86.47±0.09
NPE-ss2	84.60±0.03	85.22±0.13	85.38±0.13

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中 NPE 算法的分析,提出了一种基于 SSNPE 和改进的 KNN 的高光谱遥感影像分类算法。该方法通过设置近邻点及其权值将高维数据投影到低维空间,并利用数据的类别信息使近邻同类数据点权值更大,进而加大降维数据的鉴别性,利用改进的 KNN 分类器进行分类。在 Urban、Indian 数据集上的分类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 6、8、10 个有类别标记的样本和 10 个无类别标记的样本的情况下,本文方法的分类精度比 NPE 方法提高了约 8.7%~11.2%,比 LDA 和监督 LPP 方法提高了约 3.6%~8.9%,比其他算法提高了约 8.9%~25%。

但是本文只考虑了同类样本权值的增大,没有考虑使不同类样本远离,以及如何优化选择,这些都需要进一步研究。

参考文献

[1] 徐庆伶. 基于半监督学习的遥感图像分类研究[D]. 西安: 陕西师范大学, 2010: 1-3

[2] 杨国鹏, 周欣, 余旭初, 等. 基于相关向量机的高光谱影像混合像元分解[J]. 电子学报, 2010, 38(12): 2751-2756

[3] 黄鸿, 秦高峰, 冯海亮. 半监督流行学习及其在遥感影像分类中的应用[J]. 光学精密工程, 2011, 19(12): 3025-3033

[4] 王立志, 黄鸿, 冯海亮. 基于 MFA 与 kNNS 算法的高光谱遥感影像分类[J]. 计算机科学, 2012, 39(6): 261-265

[5] Belhumeur P N, Hefanha J P, Kriegman D J. Eigenfaces vs. Fisherfaces: Recognition Using Class Specific Linear Projection [J]. IEEE Trans on PAMI, 1997, 19(7): 711-720

[6] Swets D L, Weng J. Using Discriminant Eigenfeatures for Image Retrieval [J]. IEEE Trans on PAMI, 1996, 18(8): 831-836

[7] 段志臣, 芮小平, 张立媛. 基于流形学习的非线性维数约简方法[J]. 数学的实践与认识, 2012, 42(8): 230-241

[8] 王立志, 黄鸿, 冯海亮. 基于 SSMFA 与 kNNS 算法的高光谱遥感影像分类[J]. 电子学报, 2012, 40(4): 780-787

[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] 张兴福. 基于流形学习的局部降维算法研究[D]. 哈尔滨: 哈尔滨工程大学, 2011: 4-6

[13] He Xiao-fei, Cai Deng, Yan Shui-cheng, et al. Neighborhood preserving embedding [C]// Proceedings of the 10th IEEE International Conference Computer Vision (ICCV05). Beijing, 2005: 1208-1213

[14] He Xiao-fei, Yan Shui-cheng, Hu Yu-xiao, et al. Face recognition using Laplacian faces [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005, 27(3): 328-340

[15] Liu Xiao-ming, Yin Jian-wei, Feng Zhi-lin, et al. Orthogonal neighborhood preserving embedding for face recognition [C]// 2007 IEEE International Conference on Image Processing, ICIP 2007. New York, USA, 2008: 133-136

[16] Zhang Tian-hao, Tao Da-cheng, Long Li-xue, et al. Patch alignment for dimensionality reduction [J]. IEEE Trans Knowl. Data Eng, 2009, 21(9): 1299-1313

[17] 高志华, 贲可荣. 基于多分类支持向量数据描述的噪声源识别研究[J]. 计算机科学, 2012, 39(11): 233-236

[18] Song Yang-qiu, Nie Fei-ping, Zhang Chang-shui, et al. A unified framework for semi-supervised dimensionality reduction [J]. Pattern Recognition, 2008, 41(9): 2789-2799

[19] Song Yang-qiu, Nie Fei-ping, Zhang Chang-shui. Semi-supervised sub-manifold discriminant analysis [J]. Pattern Recognition Letters, 2008, 29(13): 1806-1813