

基于 Gabor 特征与局部保护降维的 高光谱图像分类算法

叶 珍¹ 白 璘¹ 粘永健^{2*}

¹长安大学电子与控制工程学院, 陕西 西安 710064

²第三军医大学生物医学工程系, 重庆 400038

摘要 提出了两种基于 Gabor 特征与局部保护降维的高光谱图像分类算法。该算法利用嵌入主成分分析的 Gabor 变换对高光谱图像进行特征提取。为了保护相邻特征的局部信息, 利用局部 Fisher 判别分析或局部保护非负矩阵分离对 Gabor 特征进行降维, 并采用高斯混合模型分类器对降维后的特征进行分类。两组高光谱数据的实验结果表明, 本文算法不但能充分挖掘高光谱图像的谱间-空间特征, 而且有效保护了高光谱图像的局部特征信息与多模型结构。与现有的几种算法相比, 本文算法能得到更高的分类精度和 Kappa 系数, 在高斯噪声环境中也具有更强的稳健性。

关键词 遥感; 高光谱图像分类; Gabor 特征; 局部保护降维; 高斯混合模型

中图分类号 TP751.1 **文献标识码** A

doi: 10.3788/AOS201636.1028003

Hyperspectral Image Classification Algorithm Based on Gabor Feature and Locality-Preserving Dimensionality Reduction

Ye Zhen¹ Bai Lin¹ Nian Yongjian²

¹*School of Electronics and Control Engineering, Chang'an University, Xi'an, Shaanxi 710064, China*

²*School of Biomedical Engineering, Third Military Medical University, Chongqing 400038, China*

Abstract Two hyperspectral image classification algorithms based on Gabor features and locality-preserving dimensionality reduction are proposed. The Gabor transform is studied and implemented to extract features for hyperspectral image in the principal component analysis-projected domain. To protect locality information of neighbor features, locality Fisher discriminant analysis or locality-preserving non-negative matrix factorization is employed to reduce the dimensionality of Gabor-based feature space. The Gaussian mixture model classifier is used for classification results. Experimental results obtained from two hyperspectral datasets show that the proposed algorithms not only extract spectral-spatial features effectively, but also preserve local-feature information and multi-model structure of hyperspectral image. Compared with several existing algorithms, the proposed algorithms can obtain high classification accuracy and Kappa coefficient, and has strong robustness in Gaussian noise environment.

Key words remote sensing; hyperspectral image classification; Gabor features; locality-preserving dimensionality reduction; Gaussian mixture model

OCIS codes 280.4750; 100.3008; 110.2960

1 引 言

高光谱遥感成像光谱仪能够在许多相邻和重叠的狭窄光谱波段上同时收集地面的辐射数据, 因此, 利用高光谱图像分析地表物质能得到更多的细节信息, 从而细致地对遥感地物进行分类^[1]。但是, 高光谱遥感图像具有数据量大、数据维数高和数据冗余性强等特点, 容易降低统计分类器的泛化能力, 从而无法获得理想

收稿日期: 2016-04-21; 收到修改稿日期: 2016-06-26

基金项目: 国家自然科学基金(41201363, 41601344)、中央高校基本科研业务费专项资金(310832163402、310832161001)

作者简介: 叶 珍(1983—), 女, 博士, 讲师, 主要从事高光谱图像处理方面的研究。E-mail: yezhen525@126.com

* 通信联系人。E-mail: yjnian@126.com

的分类结果^[2]。因此,对高光谱遥感图像分类常常需要先进行降维等预处理操作^[3]。线性判别分析(LDA)^[4]传统降维法在高光谱图像分类应用中具有一定的局限性:1) LDA 是一种最大化类间散布矩阵的变换方法,不能很好地保护输入空间相邻像素的局部特征;2) LDA 假设类条件分布是高斯分布,而高光谱数据往往是非高斯分布的,甚至有可能是多模型的^[5]。

为了克服 LDA 降维法的缺陷,文献[6]在 LDA 和局部保护投影(LPP)^[7]的基础上提出了基于局部保护降维的局部 Fisher 判别分析(LFDA)。文献[8]将 LFDA 与高斯混合模型(GMM)^[9]分类器相结合,提出了 LFDA-GMM 分类算法,在挖掘高光谱图像谱间局部特征的同时,保护了高光谱图像潜在的多模型结构。文献[10]在研究局部保护非负矩阵分离法(LPNMF)^[11]的同时,提出了两种光谱微分特征与局部保护降维的决策融合分类算法,即 D-LFDA-GMM-Fusion 算法和 D-LPNMF-GMM-Fusion 算法,这两种算法的分类性能相比 LFDA-GMM 算法有较大程度地提高。

对高光谱图像进行降维,实则通过线性变换或非线性变换对高光谱图像的光谱特征进行提取。以上几种算法都是通过光谱特征对高光谱图像进行分类,忽略了像元间空间信息的相关性。本文在以上几种算法的基础上,提出了两种基于 Gabor 特征与局部保护降维的分类算法,命名为 Gabor-LFDA-GMM 算法和 Gabor-LPNMF-GMM 算法。这两种算法首先针对高光谱图像的谱间-空间特征进行了研究,发现将嵌入主成分分析的 Gabor 变换与局部保护降维相结合,不但能充分提取高光谱图像的谱间-空间特征,而且能保护相邻特征的局部信息和高光谱图像的多模型结构,从而能在较大幅度上提高分类精度和 Kappa 系数,尤其在高斯噪声环境中,具有优良的分类性能。

2 局部保护降维

2.1 局部 Fisher 判别分析

与传统的降维法 LDA 所不同的是,LPP 通过寻找一个合适的线性图谱 W ,使得原始图像的相邻像素在投影空间具有较近的距离,从而保护了局部邻域内的相关信息。假定原始数据的训练样本为 $\{x_i\}_{i=1}^n$,类标记为 $y_i \in \{1, 2, \dots, c\}$,其中 c 代表类的个数, n 代表训练样本的总数。若 n_l 表示第 l 个类的训练样本数,则有 $\sum_{l=1}^c n_l = n$ 。定义样本 x_i 与样本 x_j 之间的亲和关系为

$$A_{i,j} = \exp\left(-\frac{\|x_i - x_j\|^2}{\gamma_i \gamma_j}\right), \quad (1)$$

式中 $\gamma_i = \|x_i - x_i^{(m)}\|$ 代表样本 x_i 的局部标度, $x_i^{(m)}$ 是像素 x_i 的第 m 个相邻样本。通过实验测试可知参数 m 对分类结果影响不大,根据参考文献[8],在后续实验中取 $m = 7$ 。

LFDA 作为一种有监督局部保护降维技术,适用于非高斯分布和多模型数据的降维。LFDA 在 LDA 的基础上,通过 LPP 得到一个线性图谱,来保护相邻像素间的局部信息。LFDA 在投影域不但能将类与类进行很好地分离,而且可以保护类内局部信息。与 LDA 相似,在 LFDA 中的局部类间散布矩阵 $S^{(lb)}$ 和类内散布矩阵 $S^{(lw)}$ 定义为

$$S^{(lb)} = \frac{1}{2} \sum_{i,j=1}^n W_{i,j}^{(lb)} (x_i - x_j) (x_i - x_j)^T, \quad (2)$$

$$S^{(lw)} = \frac{1}{2} \sum_{i,j=1}^n W_{i,j}^{(lw)} (x_i - x_j) (x_i - x_j)^T, \quad (3)$$

式中 $W^{(lb)}$ 和 $W^{(lw)}$ 为 $n \times n$ 维的矩阵,即

$$W_{i,j}^{(lb)} = \begin{cases} A_{i,j} (1/n - 1/n_l), & \text{if } y_i = y_j = l \\ 1/n, & \text{if } y_i \neq y_j \end{cases}, \quad (4)$$

$$W_{i,j}^{(lw)} = \begin{cases} A_{i,j} / n_l, & \text{if } y_i = y_j = l \\ 0, & \text{if } y_i \neq y_j \end{cases}. \quad (5)$$

根据(1)式可以得到同类相邻像素的权值。而同类非相邻像素几乎不受类间散布矩阵 $S^{(lb)}$ 和类内散布矩阵 $S^{(lw)}$ 的影响。在 LFDA 的应用中,用局部散布矩阵来估计降维投影。由局部散布矩阵得到最大化的

Fisher 比为

$$\mathbf{S}^{(lb)} \mathbf{T} = \lambda \mathbf{S}^{(lw)} \mathbf{T}, \quad (6)$$

式中 λ 为对角线特征值矩阵, 则 LFDA 的变换矩阵为

$$\mathbf{T}_{\text{LFDA}} = \operatorname{argmax}_{\mathbf{T} \in \mathbb{R}^{d \times r}} \operatorname{tr} [(\mathbf{T}_{\text{LFDA}}^{\text{T}} \mathbf{S}^{(lw)} \mathbf{T}_{\text{LFDA}})^{-1} \mathbf{T}_{\text{LFDA}}^{\text{T}} \mathbf{S}^{(lb)} \mathbf{T}_{\text{LFDA}}]. \quad (7)$$

LFDA 意在寻找一个变换矩阵 \mathbf{T} , 使同类相邻数据彼此靠近, 而不同类的相邻数据彼此分离, 比 LPP 更适用于对非高斯分布和多模型数据的降维。

2.2 局部保护非负矩阵分离

将具有 d 个光谱波段和 n 个像素的高光谱数据表示为 $\mathbf{X} = \{x_{i,j}\} \in \mathbb{R}^{d \times n}$ 。非负矩阵分离(NMF)将 \mathbf{X} 分为 \mathbf{U} 和 \mathbf{V} 两个矩阵, 有 $\mathbf{X} \approx \mathbf{UV}^{\text{T}}$, 其中 \mathbf{U} 的维数为 $d \times t$, \mathbf{V} 的维数为 $n \times t$, 且它们的秩至少为 t , 它们的乘积为较低的秩。通过乘数更新算法^[12]进行迭代, 即

$$u_{i,q} \leftarrow u_{i,q} \frac{\sum_j (x_{i,j} v_{j,q}) / \sum_q (u_{i,q} v_{j,q})}{\sum_j v_{j,q}}, \quad (8)$$

$$v_{j,q} \leftarrow v_{j,q} \frac{\sum_i (x_{i,j} u_{i,q}) / \sum_q (u_{i,q} v_{j,q})}{\sum_i u_{i,q}}, \quad (9)$$

在迭代过程中, 每一个像素可表示为 $x_j \approx \sum_{q=1}^t u_q v_{j,q}$ 。实际 $t \ll d$, 意味着 NMF 可被看作是无监督降维法。

高光谱图像每个像素的谱像均有可能为多个端元谱像的混合。对于高光谱图像分类算法来说, 希望找到一个低维子空间, 使所含像素代表单一端元, 表示一种地物特征。NMF 与 LPP 相结合的局部保护非负矩阵分离(LPNMF)可用来解决这个问题。LPNMF 的目标函数为

$$\mathbf{O} = \sum_{i=1}^d \sum_{j=1}^n \left[x_{i,j} \log \left(\frac{x_{i,j}}{y_{i,j}} \right) - x_{i,j} + y_{i,j} \right] + \lambda \mathbf{R}, \quad (10)$$

式中 $\mathbf{Y} = \{y_{i,j}\} = \mathbf{UV}^{\text{T}}$, λ 是正则化参数。(10)式的第一项由 \mathbf{X} 和 \mathbf{Y} 的交叉熵^[11]获得, 为 NMF 的常规目标函数。用 \mathbf{R} 约束降维子空间 \mathbf{V} 的像素间几何距离, 有

$$\mathbf{R} = \frac{1}{2} \sum_{j,s=1}^n \sum_{q=1}^t \left(v_{j,q} \log \frac{v_{j,q}}{v_{s,q}} - v_{s,q} + v_{s,q} \log \frac{v_{s,q}}{v_{j,q}} \right) \mathbf{W}_{j,s}, \quad (11)$$

式中 \mathbf{W} 为原始数据 \mathbf{X} 的像素间距离的边缘权重矩阵。由 LPP 定义可知, 矩阵 \mathbf{X} 用于保护数据分布的内在几何结构。可以采用以下的乘法规则将函数 \mathbf{O} 最小化, 并估计矩阵 \mathbf{U} 和矩阵 \mathbf{V} 的大小, 即

$$u_{i,q} \leftarrow u_{i,q} \frac{\sum_j (x_{i,j} v_{j,q}) / \sum_q (u_{i,q} v_{j,q})}{\sum_j v_{j,q}}, \quad (12)$$

$$\mathbf{v}_q \leftarrow \left[\sum_i u_{i,q} \mathbf{I} + \lambda \mathbf{L} \right]^{-1} \begin{bmatrix} v_{1,q} \sum_i \frac{x_{i,1} u_{i,q}}{\sum_q (u_{i,q} v_{1,q})} \\ v_{2,q} \sum_i \frac{x_{i,2} u_{i,q}}{\sum_q (u_{i,q} v_{2,q})} \\ \vdots \\ v_{n,q} \sum_i \frac{x_{i,n} u_{i,q}}{\sum_q (u_{i,q} v_{n,q})} \end{bmatrix}, \quad (13)$$

式中 \mathbf{v}_q 是矩阵 \mathbf{V} 中的第 q 个列向量, \mathbf{I} 是一个 $n \times n$ 维的单位矩阵。矩阵 \mathbf{L} 代表矩阵 \mathbf{W} 的图拉普拉斯算子。与 NMF 相比, LPNMF 具有局部保护约束性, 可以有效地保护原始高光谱图像多元化的局部结构。该约束性由局部相邻像素的相似性来衡量, 并且借助图拉普拉斯算子来描述其潜在的分布结构。对高光谱图像来说, 其统计结构是较为复杂的, 常常为非高斯分布或多模型分布。根据高光谱数据的分布特性, 利用 LPNMF 对其进行降维, 不但得到了更紧凑的分布, 而且降低了贝叶斯误差, 最终达到了提高分类精度的目的。

3 基于 Gabor 特征与局部保护降维的分类方法

3.1 Gabor 变换

一维 Gabor 变换由傅里叶变换演变而来,用来最大化信号的时频分辨率,从而更好地描述信号的局部特性。随后发展的二维 Gabor 变换,是一种用来对图像进行特征提取的线性变换,广泛应用于分类与识别领域^[13]。二维 Gabor 变换函数由一个实部和一个虚部构成,是通过高斯包络调制的正弦曲线函数,可表示为

$$g(x, y; \delta, \theta, \psi, \sigma, \gamma) = \exp\left(-\frac{x'^2 + \gamma^2 y'^2}{2\sigma^2}\right) \times \exp\left[j\left(2\pi \frac{x'}{\delta} + \psi\right)\right], \quad (14)$$

且

$$x' = x \cos \theta + y \sin \theta, \quad (15)$$

$$y' = -x \sin \theta + y \cos \theta, \quad (16)$$

式中 δ 代表正弦因子的波长,其值以像素为单位,通常大于或等于 2,但不能大于输入图像尺寸的五分之一; θ 代表 Gabor 核的方向夹角,它的取值范围为 $[0, \pi]$,指定了 Gabor 函数并行条纹的方向; ψ 为相位偏移,默认其值为 $\pi/2$,代表 Gabor 变换是具有实部和虚部的复数; γ 代表限定 Gabor 核函数椭圆率的空间相位比,当 $\gamma=1$ 时,Gabor 核函数的形状是圆的,当 $\gamma < 1$ 时,其形状随着平行条纹方向而拉长,取 0.5 作为默认值^[14]; σ 为高斯包络的标准差,可以由波长 δ 和空间频率带宽 b_w 来决定,定义

$$\sigma = \frac{\delta}{\pi} \sqrt{\frac{\ln 2}{2} \frac{2^{b_w} + 1}{2^{b_w} - 1}}, \quad (17)$$

带宽 b_w 的值为正实数。带宽越小,标准差越大,则 Gabor 核的形状越大,当其值在 $[1, 5]$ 时,对本文算法的分类结果影响不大,默认其值为 1。

3.2 高斯混合模型

高斯混合模型分类方法用来对具有两个或两个以上高斯分布的数据进行分类^[15]。数据 \mathbf{X} 的 K 个高斯模型的联合概率密度函数可表示为

$$p(\mathbf{X}) = \sum_{k=1}^K \alpha_k N(\mathbf{X}, \mu_k, \Sigma_k), \quad (18)$$

其中

$$N(\mathbf{X}, \mu_k, \Sigma_k) = \frac{1}{(2\pi)^{d/2} |\Sigma_k|^{1/2}} \times \exp\left[-\frac{1}{2} (\mathbf{X} - \mu_k)^T \Sigma_k^{-1} (\mathbf{X} - \mu_k)\right], \quad (19)$$

式中 $N(\mathbf{X}, \mu_k, \Sigma_k)$ 代表第 k 个高斯混合模型。 α_k, μ_k 和 Σ_k 代表第 k 个模型来自参数向量 $\Theta = \{\alpha_k, \mu_k, \Sigma_k\}$ 的混合权重参数、均值向量及方差矩阵。

对于混合模型来说,以上参数可以通过基于迭代优化的期望最大(EM)算法获得^[16]。EM 算法旨在寻找这些参数的最大似然估计或最大后验概率。设数据集 $\mathbf{X}_0 = \{\mathbf{x}_i\}_{i=1}^n$, \mathbf{x}_i 是第 k 个模型子集 \mathcal{Q}_k 的数据向量, n 是该子集中样本的个数。则该模型数据的对数似然函数为

$$L(\Theta, \mathbf{X}_0) = \sum_{k=1}^K \sum_{i \in \mathcal{Q}_k} p(k | x_i, \Theta) \log[\alpha_k N(x_i, \mu_k, \Sigma_k)] \quad (20)$$

式中 $p(k | x_i, \Theta)$ 是 GMM 第 k 个模型的后验概率

$$p(k | x_i, \Theta) = \frac{\alpha_k N(x_i, \mu_k, \Sigma_k)}{\sum_{k=1}^K \alpha_k N(x_i, \mu_k, \Sigma_k)}. \quad (21)$$

在一次迭代的过程中,参数向量 Θ 通过将(20)式中的对数似然函数 $L(\Theta, \mathbf{X}_0)$ 最大化来获得(the M-step)。在接下来的迭代过程中(the E-step),参数集通过(21)式更新,即

$$\hat{\alpha}_k = \frac{1}{n} \sum_{i=1}^n p(k | x_i, \Theta), \quad (22)$$

$$\hat{\mu}_k = \frac{\sum_{i=1}^n p(k | x_i, \Theta) x_i}{\sum_{i=1}^n p(k | x_i, \Theta)}, \quad (23)$$

$$\hat{\Sigma}_k = \frac{\sum_{i=1}^n p(k | x_i, \Theta) (x - \mu_k) (x - \mu_k)^T}{\sum_{i=1}^n p(k | x_i, \Theta)}, \quad (24)$$

直到(20)式中对数似然函数的逐次近似值的差达到所规定的某个阈值时,停止上述迭代过程。

高光谱图像的常用分类方法包括最大似然估计(MLE)^[17]和支持向量机(SVM)^[18]等。MLE在训练样本数增多时具有较好的收敛性,通常与LDA降维法结合对高光谱图像进行分类。SVM通过引入结构风险最小化原理、最优化理论和核方法演化而成,其分类性能通常优于MLE,在小样本情况下能得到较好的分类结果。然而,高光谱图像的光谱特征受诸多因素影响,各类之间的统计分布常常是复杂的多模型结构,因而,高斯混合模型分类器适合于高光谱图像分类的应用。文献[8]和文献[10]的研究工作证明,将高斯混合模型与局部保护降维相结合,能得到良好的分类结果。因此,本文采用GMM分类器对降维后的特征进行分类,并参照参考文献[8],选取高斯混合模型的个数 $k=5$ 对本文算法进行后续的实验分析。

3.3 本文算法步骤

提出两种基于Gabor特征与局部保护降维的分类算法,对高光谱图像的谱间-空间特征进行研究,分别利用LPNMF和LFDA两种局部保护降维法来保护相邻特征的局部信息和高光谱图像的多模型结构。本文算法的具体步骤如下:

- 1) 对原始高光谱图像进行主成分分析,根据(14)式计算前 C 个最大主成分的Gabor特征空间;
- 2) 利用LPNMF或LFDA对Gabor特征空间进行局部保护降维;
- 3) 根据(18)式对降维后的特征采用高斯混合模型分类器分类。

其具体的算法流程如图1所示。




图1 本文算法流程图

Fig. 1 Flowchart of proposed algorithm

4 实验与讨论

4.1 实验数据

采用的实验数据为机载高光谱遥感数据。实验数据一来自AVIRIS传感器在印第安那获取的220个波段的Indian Pines高光谱遥感数据^[19]。该数据的空间分辨率为20 m,每个波段图像的大小为145 pixel×145 pixel。原始Indian Pines数据有16个类别,选取其中像素较多的8个类别作为主要分析对象,如图2所示。实验数据二来自AVIRIS传感器在加利福尼亚州获取的224个波段的Salinas Valley高光谱遥感数据。该数据的空间分辨率为3.7 m,每个波段图像的大小为512 pixel×217 pixel,共包括16种地物,如图3所示。

4.2 参数调节

为了使本文算法的分类性能达到较优状态,本节对局部保护降维法和嵌入主成分分析的Gabor特征提取法中的主要参数进行了测试与调节。其中,包括局部保护降维法的维数 r 、主成分个数 C 和Gabor滤波器正弦因子的波长 δ 。为了保证实验的客观性,实验结果均取自相同实验条件下的20次实验结果的平均值。




图 2 Indian Pines 数据集。(a) 原始图像;(b) 真实地物标记
Fig. 2 Indian Pines dataset. (a) Original image; (b) real ground label

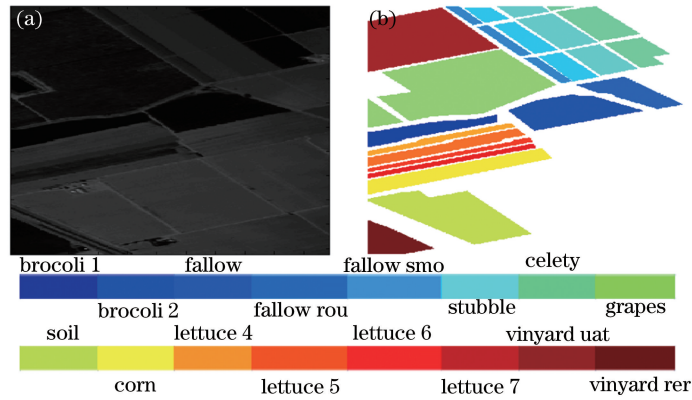


图 3 Salinas Valley 数据集。(a) 原始图像;(b) 真实地物标记
Fig. 3 Salinas Valley dataset. (a) Original image; (b) real ground label

以 Indian Pines 高光谱数据为例,对每个类别选择 50 pixel 作为训练样本,对 LPNMF 和 LFDA 的维数 r 进行测试与调节。当主成分个数 C 和正弦因子波长 δ 为 10 时,本文提出的两种算法在不同维数 r 情况下的分类精度如图 4 所示。提出的 Gabor-LFDA-GMM 算法的分类精度在维数 $r=19$ 时达到最大值 85.79%,提出的 Gabor-LPNMF-GMM 算法的分类精度在 $r=41$ 时达到最大值 88.53%。

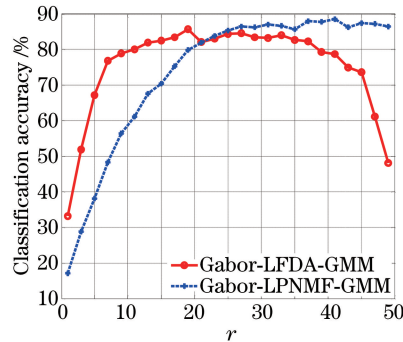


图 4 在不同维数情况下的分类精度
Fig. 4 Classification accuracy under different dimensions

在确定了局部保护降维法的维数 r 后,再对嵌入主成分分析的 Gabor 特征提取法中的参数-主成分个数 C 进行测试与调节。设 $\delta=10$, C 在 4~20 范围内变化,对该数据进行实验。如图 5 所示,主成分个数对 Gabor-LFDA-GMM 算法的分类精度有较大影响,即当主成分较少时,该算法的分类精度较低,最优分类精度出现在 $C=10$ 时;对 Gabor-LPNMF-GMM 算法来说,主成分个数对分类精度影响不大,最优分类精度出现在 $C=8$ 时。以上实验确定了局部保护降维法的维数 r 和主成分个数 C ,接下来,再对 Gabor 滤波器正弦因子的波长 δ 在 2~20 范围内进行测试与调节。如图 6 所示, δ 较小时,两种分类算法的分类精度均较低;当 δ 逐步增大,Gabor-LFDA-GMM 算法的分类精度随着波长 δ 的增大而逐步提高,当波长 δ 增大到 16 时,

该算法的分类精度趋于稳定;而 Gabor-LPNMF-GMM 算法的分类精度随着波长 δ 的增大先提高后降低,在 $\delta=12$ 时达到最高。




图 5 在不同 C 情况下的分类精度

Fig. 5 Classification accuracy under different C

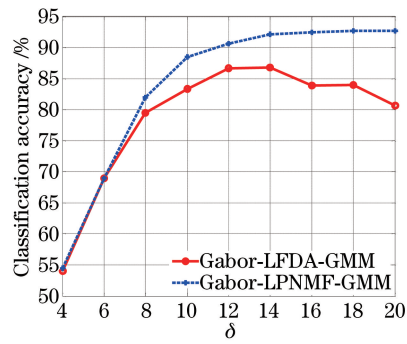


图 6 在不同 delta 情况下的分类精度

Fig. 6 Classification accuracy under different delta

4.3 实验结果与分析

将 Indian Pines 高光谱遥感数据每个类别的 50 个非零像素作为训练样本,将该数据的所有非零像素作为测试样本,测试样本总数为 8624 个。为了保证实验的客观性,以下实验中的所有数据均为相同实验条件下 20 次实验结果的平均值。表 1 中的实验数据对提出的两种算法和其他几种算法的分类精度、Kappa 系数及其标准差进行了比较,比较算法的分类结果也在各自的最优参数下获得。如表 1 所示,当参数 $r=19$ 、 $C=10$ 和 $\delta=12$ 时,Gabor-LFDA-GMM 算法的分类精度和 Kappa 系数分别为 87.08% 和 0.8439,比 LFDA-GMM 算法和 D-LFDA-G-Fusion 算法的分类精度高出了 10% 左右;当参数 $r=41$ 、 $C=8$ 和 $\delta=16$ 时,Gabor-LPNMF-GMM 算法的分类精度和 Kappa 系数分别达到了 91.88% 和 0.9026,比 LPNMF-GMM 算法和 D-LPNMF-G-Fusion 算法的分类精度高出了 15% 以上。同时,本文提出的两种分类算法比传统的 SVM 算法和 LDA-MLE 算法的分类精度和 Kappa 系数也有较大幅度提高。其中,Gabor-LPNMF-GMM 算法的分类性能尤为突出,不但分类精度和 Kappa 系数最高,而且通过 20 次重复实验计算出的标准差最小,说明该算法的分类性能更稳定。

表 1 Indian Pines 数据集的分类结果

Table 1 Classification results of Indian Pines dataset

Classification algorithm	Accuracy /%	Kappa
LDA-MLE	62.34(±1.38)	0.5588(±0.0140)
SVM ($\sigma=0.3$)	77.46(±1.71)	0.7337(±0.0195)
LFDA-GMM ($r=9$)	64.17(±2.04)	0.5767(±0.0218)
D-LFDA-G-Fusion ($r=9$)	67.85(±1.94)	0.6222(±0.0199)
Gabor-LFDA-GMM	87.08(±1.71)	0.8439(±0.0210)
LPNMF-GMM ($r=27$)	73.01(±1.67)	0.6806(±0.0194)
D-LPNMF-G-Fusion ($r=15$)	74.92(±1.39)	0.7004(±0.0149)
Gabor-LPNMF-GMM	91.88(±1.15)	0.9026(±0.0136)

图 7 为不同算法对 Indian Pines 高光谱数据的分类图。由于本文两种算法能够保护相邻特征的局部信息和高光谱图像的多模型结构,故其视觉效果明显优于其他几种分类算法,与表 2 实验结果一致。其中,Gabor-LPNMF-GMM 算法的视觉效果最好。

以相同的实验方法对 Salinas Valley 高光谱数据进行分类。选择该数据每个类别的 50 个非零像素作为训练样本,将该数据的所有非零像素作为测试样本,测试样本的总数为 54129 个。通过表 2 中的实验数据可知,当参数 $r=27$ 、 $C=12$ 和 $\delta=20$ 时,Gabor-LFDA-GMM 算法的分类精度和 Kappa 系数分别为 93.48% 和 0.9271,比 LFDA-GMM 算法和 D-LFDA-G-Fusion 算法的分类精度高出了 5% 以上;当参数 $r=43$ 、 $C=4$ 和 $\delta=26$ 时,Gabor-LPNMF-GMM 算法的分类精度和 Kappa 系数分别达到了 95.66% 和 0.9517,比 LPNMF-GMM 算法和 D-LPNMF-G-Fusion 算法的分类精度高出了 6% 以上。Gabor-LPNMF-GMM 算法的分类精




图 7 Indian Pines 数据的分类图。(a) LDA-MLE; (b) LFDA-GMM; (c) D-LFDA-G-Fusion; (d) Gabor-LFDA-GMM; (e) SVM; (f) LPNMF-GMM; (g) D-LPNMF-G-Fusion; (h) Gabor-LPNMF-GMM

Fig. 7 Classification maps for Indian Pines dataset. (a) LDA-MLE; (b) LFDA-GMM; (c) D-LFDA-G-Fusion; (d) Gabor-LFDA-GMM; (e) SVM; (f) LPNMF-GMM; (g) D-LPNMF-G-Fusion; (h) Gabor-LPNMF-GMM

度和 Kappa 系数不但最高,而且标准差最小,说明该算法比其他算法的分类性能更稳定。图 8 为不同算法对 Salinas Valley 数据的分类图。

表 2 Salinas Valley 数据的分类结果

Table 2 Classification results of Salinas Valley dataset

Classification algorithm	Accuracy / %	Kappa
LDA-MLE	85.86(± 1.11)	0.8429(± 0.0121)
SVM ($\sigma=0.3$)	89.30(± 1.09)	0.8812(± 0.0120)
LFDA-GMM ($r=11$)	86.52(± 0.94)	0.8503(± 0.0103)
D-LFDA-G-Fusion ($r=7$)	88.12(± 1.15)	0.8352(± 0.0131)
Gabor-LFDA-GMM	93.48(± 1.42)	0.9271(± 0.0160)
LPNMF-GMM ($r=37$)	88.64(± 0.92)	0.8738(± 0.0102)
D-LPNMF-G-Fusion($r=17$)	89.14(± 1.20)	0.8793(± 0.0133)
Gabor-LPNMF-GMM	95.66(± 0.61)	0.9517(± 0.0068)

噪声是影响图像质量的主要因素之一。高光谱图像获取过程中都有可能产生噪声,如太阳照射、大气传输、光电成像等环节。高光谱成像系统由诸多子系统构成,而每一个子系统都会产生噪声,因而很难采用定量模型来对其进行描述。对于不确定的问题,通常采用统计方法来进行处理。在光学遥感成像模型中,一般采用加性高斯噪声来对遥感图像中的噪声进行模拟^[19]。作为性能良好的高光谱图像分类算法,在高斯噪声环境中应该具有一定的稳健性,即对带有不同程度噪声的图像进行分类时,能得到比其他算法更好的分类结果。实验证明,提出的 Gabor 特征与局部保护降维结合的分类算法具有良好的抗噪声性能。对原始高光谱遥感图像添加不同幅度的高斯噪声,通过信噪比(SNR)来衡量带噪高光谱图像的质量。Indian Pines 高光谱数据添加噪声后的信噪比范围为 9.30 dB~36.36 dB,Salinas Valley 高光谱数据添加噪声后的信噪比范围为 6.38 dB~32.69 dB。由于添加的高斯噪声为随机噪声,在柱形图中给出了各算法分类结果的误差线,且该实验中的所有误差线均在 95%的置信区间下获得。如图 9 所示,随着噪声强度的增加,Gabor-LFDA-GMM 算法和 Gabor-LPNMF-GMM 算法的分类精度没有明显变化,而其他算法的分类精度均会有不同程度的降低。由此可见,本文两种分类算法具有良好的抗噪声性能。为了进一步分析图 9 中的误差线,表 3 给出了各算法的具体误差值。对于 Indian Pines 高光谱遥感数据和 Salinas Valley 高光谱遥感数据来说,本文算法的噪声误差明显低于其他几种比较算法的噪声误差。进一步说明,本文算法在高斯噪声环境中不但能得到更高的分类精度,而且具有较好的稳定性。

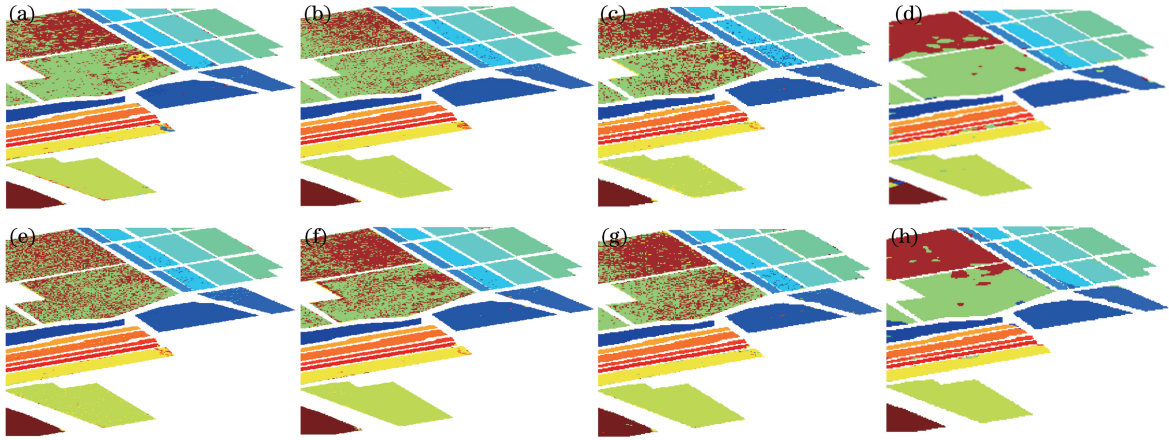


图 8 Salinas Valley 数据的分类图。(a) LDA-MLE; (b) LFDA-GMM; (c) D-LFDA-G-Fusion; (d) Gabor-LFDA-GMM; (e) SVM; (f) LPNMF-GMM; (g) D-LPNMF-G-Fusion; (h) Gabor-LPNMF-GMM
 Fig. 8 Classification maps for Salinas Valley dataset. (a) LDA-MLE; (b) LFDA-GMM; (c) D-LFDA-G-Fusion; (d) Gabor-LFDA-GMM; (e) SVM; (f) LPNMF-GMM; (g) D-LPNMF-G-Fusion; (h) Gabor-LPNMF-GMM




图 9 在噪声环境中的分类结果。(a) Indian Pines 数据集; (b) Salinas Valley 数据集
 Fig. 9 Classification results under noise environment. (a) Indian Pines dataset; (b) Salinas Valley dataset

表 3 噪声环境中的分类误差
 Table 3 Classification errors under noise environment

Algorithm	Indian Pines						Salinas Valley					
	9.30 dB	14.92 dB	19.51 dB	24.33 dB	30.34 dB	36.36 dB	9.30 dB	14.92 dB	19.51 dB	24.33 dB	30.34 dB	36.36 dB
LFDA-GMM	0.401	0.404	0.421	0.436	0.441	0.437	0.176	0.168	0.164	0.154	0.142	0.129
D-LFDA-G-Fusion	0.404	0.408	0.422	0.437	0.441	0.436	0.176	0.167	0.158	0.142	0.130	0.120
Gabor-LFDA-GMM	0.294	0.289	0.296	0.292	0.297	0.295	0.094	0.092	0.090	0.089	0.088	0.089
LPNMF-GMM	0.428	0.436	0.440	0.441	0.432	0.412	0.175	0.175	0.172	0.159	0.141	0.127
D-LPNMF-G-Fusion	0.430	0.439	0.441	0.439	0.427	0.405	0.173	0.162	0.152	0.142	0.131	0.123
Gabor-LPNMF-GMM	0.204	0.199	0.206	0.203	0.202	0.206	0.077	0.076	0.077	0.077	0.076	0.077

5 结 论

传统的高光谱图像分类算法往往只对高光谱图像的光谱特征进行分析,忽略了高光谱图像的空间特征,因此,难以得到优良的分类结果,尤其在高斯噪声环境中的稳健性较差。针对该问题,研究了两种基于 Gabor 特征与局部保护降维的高光谱图像分类算法,发现嵌入主成分分析的 Gabor 特征能充分挖掘高光谱图像的谱间和空间特征,通过结合 LPNMF 或 LFDA 局部保护降维法能进一步保护高光谱图像的局部特征信息和多模型结构,从而有效地提高了分类的准确率。在不同信噪比的高斯噪声环境中进行仿真实验,本文提出的这两种算法的分类结果几乎不受噪声干扰,始终保持着稳定的分类精度和较低的分类误差。

基于谱间-空间特征的分类算法渐渐成为高光谱图像分类领域的研究热点之一,这类算法比单纯基于谱

间特征的分类算法能得到更高的分类精度。但基于谱间-空间特征的分类算法通常涉及到的参数较多,需要通过经验或实验对各参数进行优化选择。本文提出的基于 Gabor 特征与局部保护降维的分类算法有三个主要参数需要通过实验来进行调节。在接下来的工作中,将针对这些参数的自适应选择问题进行研究。

参 考 文 献

- 1 Ye Z, Prasad S, Li W, *et al.* Classification based on 3D DWT and decision fusion for hyperspectral image analysis[J]. IEEE Geoscience and Remote Sensing Letters, 2014, 11(1): 173-177.
- 2 Liu Dawei, Han Ling, Han Xiaoyong, High spatial resolution remote sensing image classification based on deep learning [J]. Acta Optica Sinica, 2016, 36(4): 0428001.
刘大伟, 韩玲, 韩晓勇. 基于深度学习的高分辨率遥感影像分类研究[J]. 光学学报, 2016, 36(4): 0428001.
- 3 Li Zhimin, Zhang Jie, Huang Hong, *et al.* Semi-supervised laplace discriminant embedding for hyperspectral image classification[J]. Journal of Electronics & Information Technology, 2015, 37(4): 995-1001.
李志敏, 张杰, 黄鸿, 等. 面向高光谱图像分类的半监督 Laplace 鉴别嵌入[J]. 电子与信息学报, 2015, 37(4): 995-1001.
- 4 Li C, Chu H, Kuo B, *et al.* Hyperspectral image classification using spectral and spatial information based linear discriminant analysis[C]. IEEE International Geoscience and Remote Sensing Symposium (IGARSS), 2011: 1716-1719.
- 5 Tadjudin S, Landgrebe D A. Robust parameter estimation for mixture model[J]. IEEE Transactions on Geoscience and Remote Sensing, 2000, 38(1): 439-445.
- 6 Sugiyama M. Dimensionality reduction of multimodal labeled data by local Fisher discriminant analysis[J]. Journal of Machine Learning Research, 2007, 8(5): 1027-1061.
- 7 Lin Yu'e, Li Jingzhao, Liang Xingzhu, *et al.* Direct orthogonal discriminant locality preserving projections method[J]. Journal of Optoelectronics · Laser, 2012, 23(3): 561-565.
林玉娥, 李敬兆, 梁兴柱, 等. 直接正交鉴别保局投影算法[J]. 光电子·激光, 2012, 23(3): 561-565.
- 8 Li W, Prasad S, Fowler J E, *et al.* Locality-preserving dimensionality reduction and classification for hyperspectral image analysis[J]. IEEE Transactions on Geoscience and Remote Sensing, 2012, 50(4): 1185-1198.
- 9 Berge A, Solberg A H S. Structured Gaussian components for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2006, 44(11): 3386-3396.
- 10 Ye Z, He M, Fowler J E, *et al.* Hyperspectral image classification based on spectra derivative features and locality preserving analysis[C]. 2nd IEEE China Summit & International Conference on Signal and Information Processing, 2014: 138-142.
- 11 Cai D, He X, Wang X, *et al.* Locality preserving nonnegative matrix factorization[C]. International Joint Conference on Artificial Intelligence, 2009: 1010-1015.
- 12 Lee D D, Seung H S. Learning the parts of objects by non-negative matrix factorization[J]. Nature, 1999, 401(6755): 788-791.
- 13 Jia S, Zhu Z, Shen L, *et al.* A two-stage feature selection framework for hyperspectral image classification using few labeled samples[J]. IEEE Selected Topics in Applied Earth Observations and Remote Sensing, 2014, 7(4): 1023-1035.
- 14 Clausi D A, Jernigan M E. Designing Gabor-filters for optimal texture separability[J]. Pattern Recognition, 2000, 33(11): 1835-1849.
- 15 Dundar M M, Landgrebe D. A model-based mixture-supervised classification approach in hyperspectral data analysis[J]. IEEE Transactions on Geoscience Remote Sensing, 2002, 40(12): 2692-2699.
- 16 Vlassis N, Likas A. A greedy EM algorithm for Gaussian mixture learning[J]. Neural Processing Letters, 2002, 15(1): 77-87.
- 17 Fan Liheng, Lü Junwei, Deng Jiangsheng. Classification of hyperspectral remote sensing images based on bands grouping and classification ensembles [J]. Acta Optica Sinica, 2014, 34(9): 091002.
樊利恒, 吕俊伟, 邓江生. 基于分类器集成的高光谱遥感图像分类方法[J]. 光学学报, 2014, 34(9): 091002.
- 18 Wang Shutao, Zeng Qiuju, Song Haobing, *et al.* Signal denoising method based on the SVM filter absorption methane detection[J]. Chinese J Lasers, 2014, 41(9): 0915001.
王书涛, 曾秋菊, 宋浩兵, 等. 基于 SVM 滤波器的吸收式甲烷检测的信号去噪方法[J]. 中国激光, 2014, 41(9): 0915001.
- 19 Pu H Y, Chen Z, Wang B, *et al.* A novel spatial-spectral similarity measure for dimensionality reduction and classification of hyperspectral imagery[J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 52(11): 7008-7022.