

基于子空间字典偶学习的高光谱图像分类^①

王金甲^② 姜 雪 杨中玉

(燕山大学信息科学与工程学院 秦皇岛 066004)

摘要 针对高光谱高分辨率带来巨大数据量和空间分辨率引起混合像元的问题,提出了基于子空间(subspace)的字典偶学习(DPL)算法,简称DPLsub算法。DPL算法是对字典学习的改进,它通过学习得到综合字典和分析字典,在模式识别中体现了高效性,而子空间投影的方法能更好地表征噪声和高度混合的像元。将光谱和空间特征融合的方法用于分类研究试验。实验数据是两幅高光谱影像,比较了子空间字典偶学习(DPLsub)模型和其他三种分类器即最小二乘支持向量机(LS-SVM)、稀疏多分类回归(SMLR)和字典学习(DL-OMP)的分类结果。实验结果显示,DPLsub算法无论在时间上还是精度上都优于其他算法,证明了这种子空间字典偶学习方法对高光谱图像分类的可行性与高效性。

关键词 高光谱图像分类, 子空间投影, 混合像元, 字典偶学习(DPL), 多特征融合

0 引言

随着传感器与成像技术的发展,遥感影像在军事、农业等方面发挥的重要作用日益明显。但由于高光谱数据具有上百个通道,数据量非常大,存在大量的混合像元和数据冗余现象,给图像传输和存储带来了困难,另外,由于波段间强的相关性和类内多样性的存在使高光谱图像有很多特征提取方面的困难和分类效果不理想等问题,针对这些具体问题研究学者们已提出了很多解决方法^[1],例如高空间高分辨率的遥感图像分类方法,其主要特点是先降维再提特征实现分类研究^[2,3]。同时在现实中,由于种种原因,在像元对应的瞬间视角内包含多于一种地物,因此形成了混合像元,早在2008年罗文斐等人就提出了基于子空间距离解混高光谱图像的算法^[4],之后更多关于子空间投影的方法应用到图像分类^[5,6]。同时为了弥补光谱特征信息的不足,消除“同谱异类,异类同谱”的现象,联合空间-光谱的

多特征方法广泛的应用于高光谱图像分类^[7,8],其中形态学方法是一种有效提取空间特征的方法。图像的分类也依赖于高效的分类器,支持向量机及其改进方法一直被广泛应用,包括赵春晖等人提出的基于改进的最小二乘支持向量机(least squares support vector machine, LS-SVM)^[9],还有稀疏的多分类回归(sparse multinomial logistic regression, SMLR)算法也多次用于遥感图像的分类^[10],都取得良好的效果。

稀疏表示分类(sparse representation classification, SRC)因为其具有低干扰、高特异性和高识别率的性质而得到了广泛关注^[11,12]。高光谱的稀疏表示主要包括两方面:完备的字典稀疏编码和分类。字典学习的目的是通过学习得到综合字典,大多数稀疏字典算法由于 l_0 或 l_1 稀疏限制使时间开销很大。本文提出了基于子空间(subspace)的字典偶学习(dictionary pair learning, DPL)模型和算法,简称DPLsub模型和算法。DPL模型在模式分类过程中同时得到综合字典和分析字典,没有 l_0 和 l_1 范数约

^① 国家自然科学基金(61273019, 61473339),河北省自然科学基金(F2013203368),中国博士后科学基金面上项目(2014M561202),河北省博士后专项项目(B2014010005)和河北省青年拔尖人才支持计划([2013]17)资助项目。

^② 男,1979年生,博士,教授;研究方向:模式识别与图像处理;联系人,E-mail: wjj@ysu.edu.cn
(收稿日期:2016-03-07)

束,可以在线性投影中计算稀疏表示系数,与在非线性空间相比大大降低了所用的时间,同时基于子空间的投影算法可以大大降低计算的维度。

1 多特征的提取

1.1 光谱特征

高光谱遥感的光谱分辨率很高,地物光谱信息丰富,有很多光谱波段,一般从可见光到红外范围就设置了 200 多个波段,本文提取的高光谱图像光谱特征就是去除掉水吸收波段范围内不好的波段,保留剩下波段全部作为光谱特征输入,记为 L_{linear} , 不再做任何非线性变换提取特征。

1.2 扩展的属性特征

早在 2001 年 Benediktsson 就提出了形态学 (morphological profile, MP) 方法用于图像的预处理^[13],之后 Benediktsson 又提出了扩展的形态特征 (extend morphological profile, EMP),即通过降低原始光谱数据的维数,再在每一个主成分上提取形态学特征^[14]。2010 年 Benediktsson 又提出了扩展的属性特征 (extend attribute profile, EAP)^[15],它是 EMP 的延伸,是在提取主成分基础上提取属性特征,其定义为

$$EAP = \{AP(PC_1), AP(PC_2), \dots, AP(PC_c)\} \quad (1)$$

式中 c 表示主成分 (principal component, PC) 的个数。

EMAPs 是基于单一属性的 PCs 上的多层次分析,然而 EMAP 考虑了多个属性,虽然它导致了特征提取时维数的增加,但是它精确地建立了空间特征模型。本实验有 4 种属性^[16]可用于属性特征提取,以这 4 种属性构建高光谱图像的扩展属性特征,记为 L_{EMAP} 。

2 基于子空间的字典偶分类器

$X = \{X_1, X_2, \dots, X_n\}$ 表示输入的图像, n 表示像元的个数, $X_i \in R_d$, d 表示维数, $y = (y_1, y_2, \dots, y_n)$ 是类标签, $y_i \in \{1, 2, \dots, K\}$ 。

2.1 独立的类子空间的学习过程:

让 $\mathbf{R}^{(k)} = \langle X_{l(k)}^{(k)} X_{l(k)}^{(k)T} \rangle$ 表示 K 类训练样本间的相关矩阵,由式(1)计算

$$\mathbf{R}^{(k)} = \mathbf{E}^{(k)} \Lambda^{(k)} \mathbf{E}^{(k)T} \quad (2)$$

的特征分解,式中 $\mathbf{E}^{(k)} = \{e_1^{(k)}, \dots, e_d^{(k)}\}$ 是特征向量矩阵, $\Lambda = \text{diag}(\lambda_1^{(k)}, \dots, \lambda_d^{(k)})$ 是降序排列的特征值矩阵。

矢量像元 X_i 可由两个相互正交向量的和来表示,即 $X_i = \hat{X}_i + \tilde{X}_i$, \hat{X}_i 是 X_i 在 $r^{(k)}$ 维子空间上的投影,这个子空间经过 $r^{(k)}$ 个特征值,即 $r_1^{(k)}, \dots, r_{r^{(k)}}^{(k)}$ 。而 \tilde{X}_i 是正交子空间的投影,这个正交的子空间经过余下的特征值。

本文取 $U^{(k)} = \{e_1^{(k)}, \dots, e_{r^{(k)}}^{(k)}\}$ 作为

$$r^{(k)} = \min\{r^{(k)} : \sum_{i=1}^{r^{(k)}} \lambda_i^{(k)} \geq \sum_{i=1}^d \lambda_i^{(k)} \times \tau\} \quad (3)$$

维子空间独立类的估计, $r^{(k)} < d$ 。在这里 $0 \leq \tau \leq 1$ 是一个阈值参数,控制光谱投影到子空间后的数据损失。这个参数直接影响光谱信息经过投影后所保留的信息量,进而影响分类精度^[16],随着 τ 的增加,分类精度也随着增加。在实验中我们也发现当 $\tau \geq 0.9$ 时,分类精度将趋于平缓,不再明显地增加,因而在本实验中我们取 $\tau = 0.9$ 。

根据 1.1 节去除不好的波段,然后把剩下的光谱波段信息投影到子空间,再输入到字典偶学习器中。

2.2 字典偶的学习过程

Gu 等人提出了具有综合字典 \mathbf{D} 和分析字典 \mathbf{P} 的 DPL 模型^[17]:

$$\{P^*, D^*\} = \arg \min_{P, D} \|X - DPX\|_F^2 + \psi(D, P, X, Y) \quad (4)$$

式中, $\psi(D, P, X, Y)$ 是识别函数,分析字典 \mathbf{P} 用于 X 的编码分析,综合字典 \mathbf{D} 用于重构 X 。DPL 模型的识别力取决于识别函数 $\psi(D, P, X, Y)$ 的设计。分析字典 \mathbf{P} 的子字典 \mathbf{P}_k 对第 i , ($i \neq k$) 类样本进行投影,约为空集,即

$$P_k X_i \approx 0, \forall k \neq i \quad (5)$$

由式(5)可知,系数矩阵 PX 近似是块对角化

的,可以从投影编码矩阵 $\mathbf{P}_k \mathbf{X}_k$ 中利用 \mathbf{D} 中的子字典 \mathbf{D}_k 重构矩阵 \mathbf{P}_k 即得到的字典偶可以使得重构误差最小:

$$\min_{\mathbf{P}, \mathbf{D}} \sum_{k=1}^K \| \mathbf{X}_k - \mathbf{D}_k \mathbf{P}_k \mathbf{X}_k \|_F^2 \quad (6)$$

综合式(4)(5)(6)可得 DPL 模型描述为

$$\{\mathbf{P}^*, \mathbf{D}^*\} = \arg \min_{\mathbf{P}, \mathbf{D}} \sum_{k=1}^K \| \mathbf{X}_k - \mathbf{D}_k \mathbf{P}_k \mathbf{X}_k \|_F^2$$

$$+ \lambda \| \mathbf{P}_k \bar{\mathbf{X}}_k \|_F^2, \quad s.t. \quad \| \mathbf{d}_i \|_2^2 \leq 1 \quad (7)$$

具体的优化 DPL 的过程^[17] 不再详述,本文根据字典偶的残差最小原则对实现高光谱图像进行分类。图 1 所示是本研究实现高光谱图像分类算法的流程图。

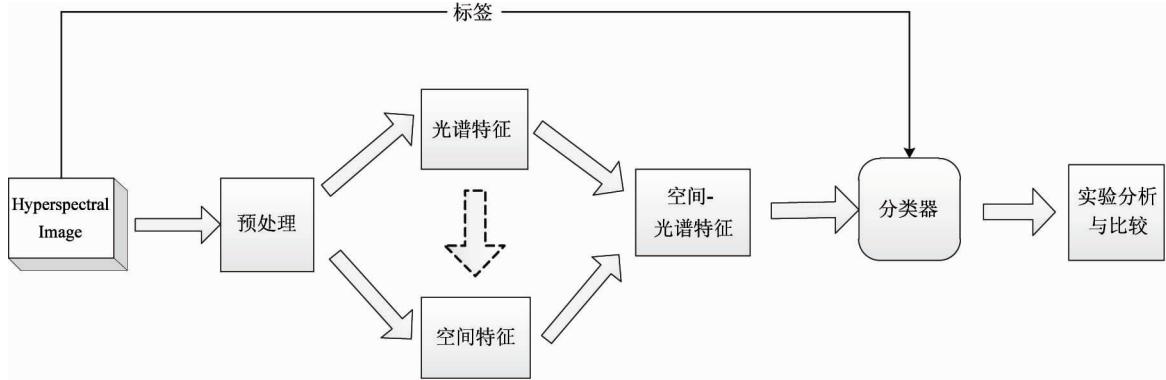


图 1 高光谱图像分类的流程图

3 实验与讨论

本实验数据包括两幅高光谱图像,分别是

AVIRIS Indian Pines 数据和 HYDICE Washington DC 数据。根据第 2 节介绍,在两组原数据的基础上分别提取了光谱与空间两种类型特征,本文所有的实验重复 50 次,具体实验内容如图 2 所示。

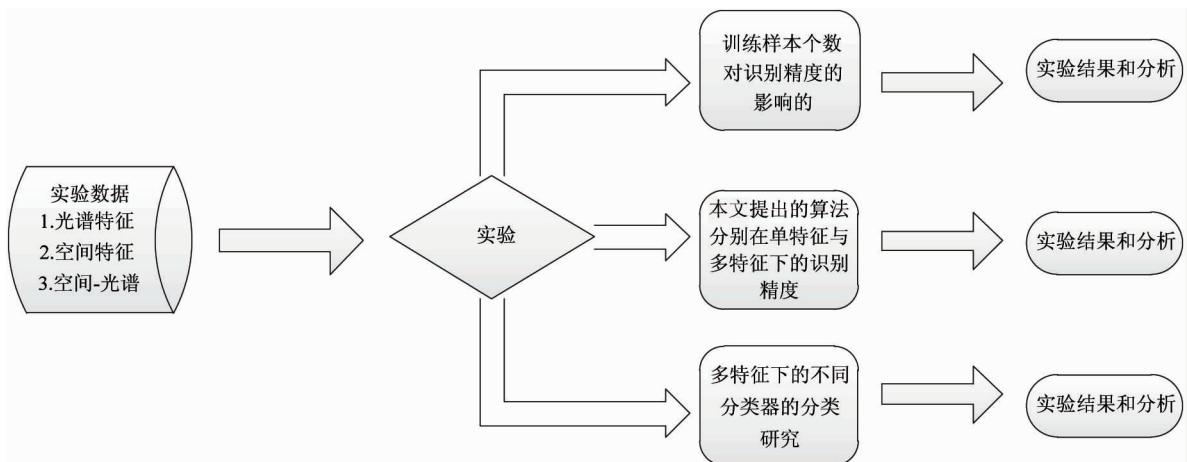


图 2 第三章实验的流程图

3.1 AVIRIS Indian Pines 数据的实验

3.1.1 实验概述

在实验中使用的第一幅高光谱图像是 1992 年通过 AVIRIS 传感器在 Indian Pines 的西北区域采集

的数据,其大小为 145×145 ,包括有 220 个连续波段($400 \sim 2500\text{nm}$),去除水吸收波段范围的 $900 \sim 1400\text{nm}$,还剩下 200 个波段作为本实验数据。HYDICE 高光谱图像波段标准假彩色合成图如

图 3(a)所示。该数据共包括 16 类,各个类别和各

个类别样本的数量如图 3(b)所示。

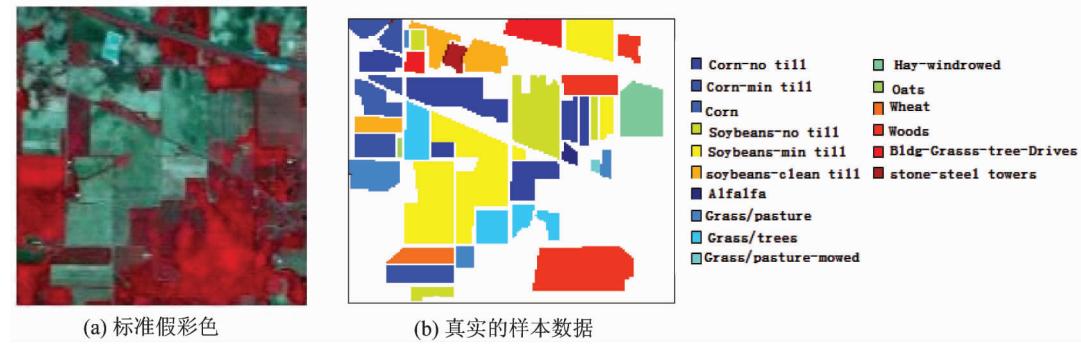


图 3 Indian Pines 高光谱图像

3.1.2 实验结果及讨论

实验 1: 当仅将光谱特征 (L_{linear}) 用于高光谱图像分类时,随着每类训练样本数量的增加,比较字典偶学习(DPL)和子空间字典偶学习(DPLsub)的分类结果如表 1 所示。从表 1 可以看出:(1)当仅有 L_{linear} 用于图像分类时,这两种分类器分类的效果都不尽如意,最高仅达到 73%;(2)当训练样本数量相

同时,DPLsub 分类效果远远优于 DPL。例如当共 560 个训练样本时,DPLsub 的总体分类精度是 71.49%,比 DPL 分类效果高出 7%,说明子空间投影确实有效地提取了原始影像的光谱信息,同时发现即使训练样本数量很大时,DPLsub 也可以快速地实现分类,比传统的 DPL 相比大大降低了消耗的时间。

实验 2: 为了消除“同物异谱,异物同谱”现象对分类的影响,本次实验融合了空间特征 (L_{EMAP}) 到 DPLsub 分类器,每类的训练样本个数是 50,实验结果如表 2 所示:当仅有光谱特征分类时,总体分类准确度是 73.23%;融合了空间特征后 DPLsub 的分类精度达到 94% 以上,大大提高了分类精度。实验结果证明了联合空间-光谱特征时可以弥补光谱特征的不足,明显改善其分类结果。图 4 显示了融合空间特征后,不同的训练样本的总体、平均分类精度及 Kappa 系数,随着每类训练样本的增加,分类精度也会有所提高。当每类样本达到 50 个时,总体分类精度可达 94%,可见有足够的标签样本作为训练样本的重要性。

表 1 不同训练样本的个数的分类精度

样本个数 (每一类)	分类器	
	DPLsub	DPL
160(10)	总体精度(%) 56.88(4.85) 时间(s) 0.29	51.63(1.65) 1.6
240(15)	总体精度(%) 64.74(2.42) 时间(s) 0.30	56.59(1.43) 1.7
320(20)	总体精度(%) 66.67(1.85) 时间(s) 0.31	59.54(1.33) 1.7
400(25)	总体精度(%) 68.28(1.47) 时间(s) 0.31	61.20(1.24) 1.8
480(30)	总体精度(%) 70.02(1.48) 时间(s) 0.32	62.88(1.25) 1.8
560(35)	总体精度(%) 71.49(1.37) 时间(s) 0.32	63.83(1.24) 1.9
640(40)	总体精度(%) 71.88(1.31) 时间(s) 0.35	65.15(1.11) 2.2
720(45)	总体精度(%) 72.51(1.23) 时间(s) 0.35	65.84(0.94) 2.1
800(50)	总体精度(%) 73.23(1.08) 时间(s) 0.37	66.46(1.07) 2.3

表 2 融合空间特征到子空间字典偶学习的分类结果

分类精度(%)	特征类型	
	L_{linear}	融合 $L_{\text{linear}} - L_{\text{EMAP}}$
OA	73.23	94.14
AA	72.44	95.65
Kappa	69.83	93.30
时间(s)	0.35	1.98

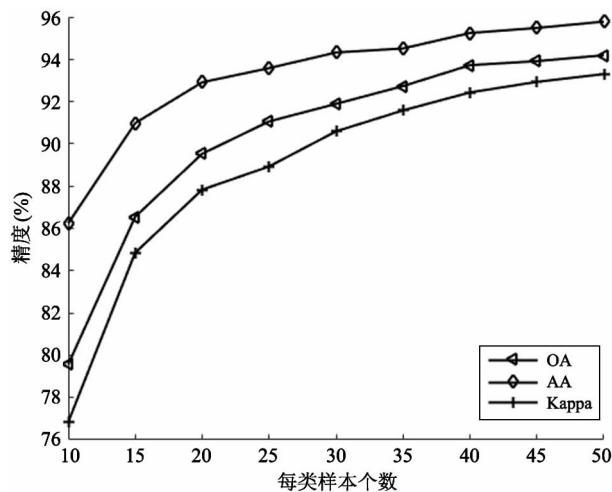


图 4 随着每类训练样本个数的增加,我们算法的分类精度

实验 3: 本实验比较了 DPLsub 和 DPL 及其他三种分类器分类结果。当每类训练样本的个数从 20 向 50 增加时,各个分类器的总体分类结果如图 5 所示。从图 5 中看出,普通的字典学习分类效果最差,当每类训练样本低于 25 个时,DPLsub 和稀疏多分类回归(SMLR)分类效果相近,当增加训练样本时,本文提出的 PDLsub 增长速度最快。当每类训练样本是 50 个时,各个分类器的分类精度的结果如表 3 所示,其分类效果图如图 6 所示。从图 6(a)可

以看出 Corn-no-till、soybeans-no-till 和 soybeans-min-till 三种类别出现较多的误分类,其他类别分类效果很好。从图 6(b)可以看出 Corn-no-till、soybeans-no-till 和 soybeans-min-till 三种类别的混淆现象严重,oats、Wood、Grass/trees 的分类几乎无误,其他类别有少量的样本被误分类。从图 6(c)看出 Corn-no-till、soybeans-no-till 和 soybeans-min-till 的混淆分类情况也很多,soybeans-no-till 和 soybeans-clean-till 之

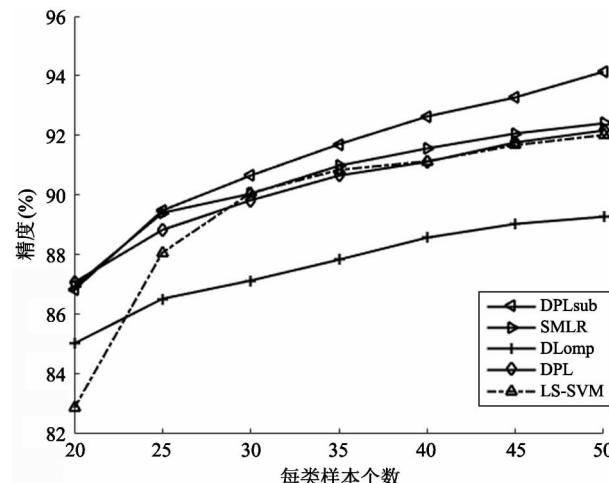


图 5 随着训练样本个数增加时各个分类器的分类结果

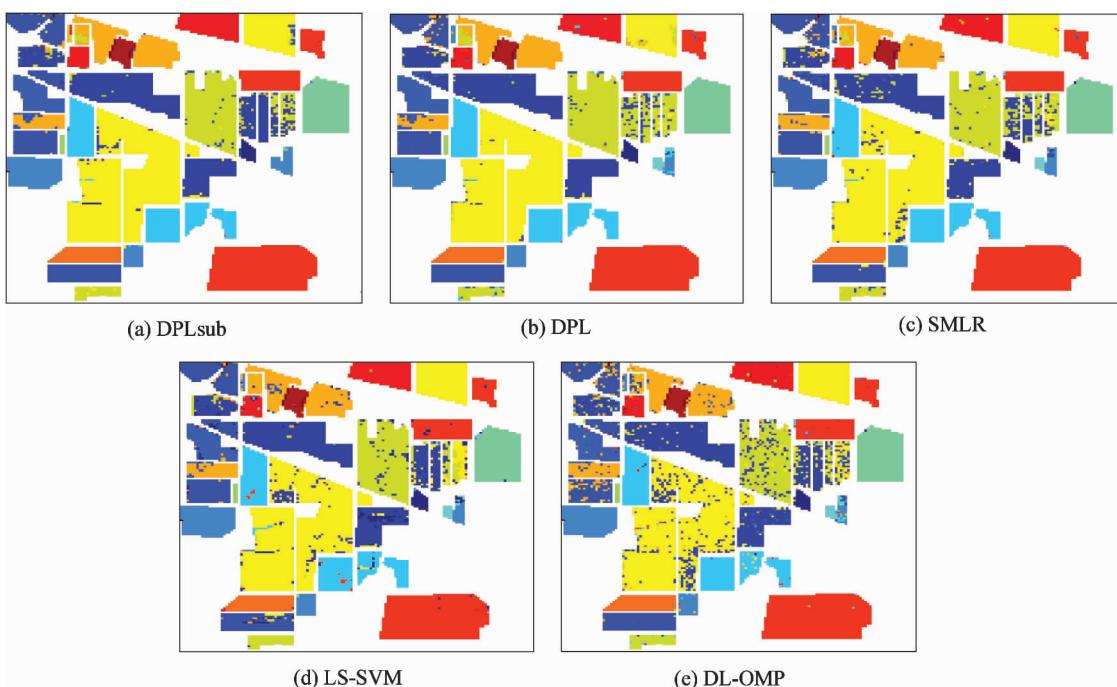


图 6 不同分类器基于空间-光谱特征的分类结果图

间也出现误分类,其他类别分类效果很好。从图 6(d)看出相对于前两种 PDL 和 SMLR 而言,LS-SVM 对 Corn-no-till、soybeans-no-till 和 soybeans-min-till 识别率较高,但是其它类别的样本识别率有所下降,而从图 6(e)看出,DL-OMP 分类效果较差,各类别的分类精度都很低。

表 3 不同分类器基于空间-光谱特征的分类结果

分类精度	DPL	DPLsub	SMLR	LS-SVM	DL-OMP
OA	0.9217	0.9414	0.9241	0.9202	0.8928
AA	0.9528	0.9588	0.9510	0.9414	0.9166
Kappa	0.9151	0.9335	0.9146	0.9331	0.8603
时间(s)	3.5545	2.0134	8.0814	24.5802	1061.15

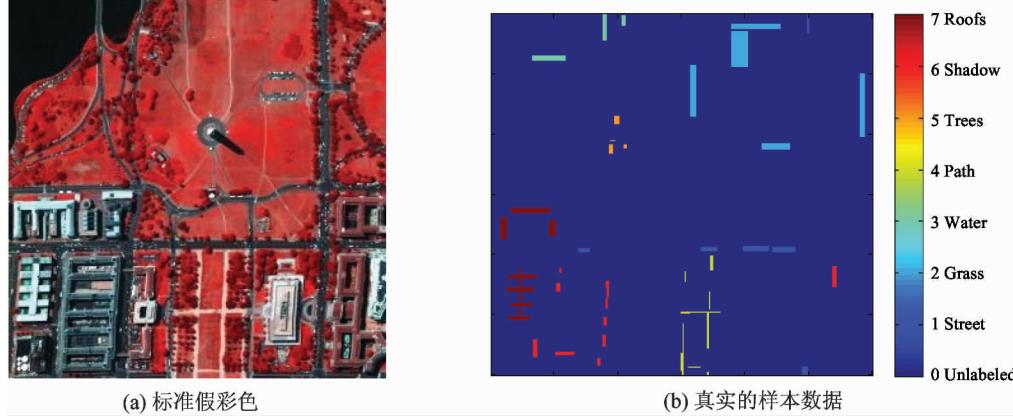


图 7 HYDICE Washington DC 图像

3.2.2 实验结果及讨论

本次使用第二组实验数据比较 DPLsub 和 DPL 及其他三种分类器分类结果。当每类训练样本的个数为 30 时,各个分类器的总体分类结果如表 4 所示,其分类效果图如图 8 所示。从表 4 中看出,本文提出的 DPLsub 分类效果较好。从图 8(a)看出,PDLsub 分类效果图最好,尤其是对 Path、Grass 和 Trees 的识别,其他分类器对 Path 的识别率效果都不近如人意。从图 8(b)看出 PDL 对 Roofs 和 Street 两种类别混淆较多,对 Water、Grass 和 Trees 的识别率较高。从图 8(c)看出 SMLR 对 Water 和 Roofs 的识别率相对较低,对 Grass 和 Trees 识别率相对良

3.2 HYDICE Washington DC 数据的试验

3.2.1 实验概述

在实验中使用的第二个高光谱图像是 HYDICE 高光谱传感器系统在 Washington DC Mall 上空的拍摄,数据大小为 1280×307 ,包括有 210 个连续波段($400 \sim 2400\text{nm}$),去除水吸收波段范围的 900 ~ 1400nm,还剩下 191 个波段用于本实验分析。HYDICE 高光谱图像的标准假彩色合成图如图 7(a)所示。该数据共包括 7 类,各个类别和各个类别样本的数量如图 7(b)所示。

好。从图 8(d)看出 LS-SVM 对 Roofs、Street 及 Shadow 类别的识别率较低,对 Water 和 Grass 的识别率较良好,从图 8(e)看出,DL-OMP 识别效果最差,而 Water 有较高的识别率,但是 DL-OMP 识别时间很长。

表 4 不同分类器基于空间-光谱特征的分类结果

分类精度	DPL	DPLsub	SMLR	LS-SVM	DL-OMP
OA	0.9712	0.9745	0.9565	0.9504	0.8408
AA	0.9723	0.9802	0.9700	0.9516	0.8723
Kappa	0.9638	0.9713	0.9469	0.9536	0.8089
时间(s)	0.5517	2.8922	0.3441	82.0303	3840

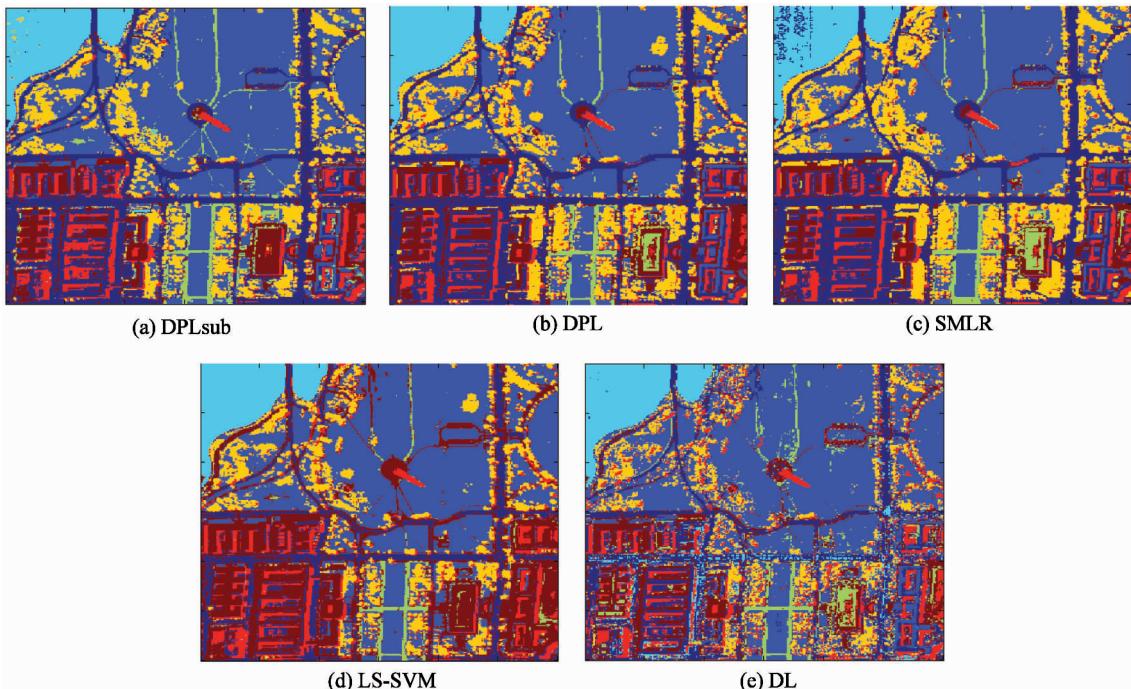


图8 不同分类器基于空间-光谱特征的分类结果图

4 结 论

本文将字典偶学习(DPL)算法用于高光谱图像分类,它通过学习得到综合字典和分析字典,从而进行特征的表示和识别,在提高分类的准确性的同时大大降低了训练和测试阶段的计算时长。其次,字典偶学习算法利用了类标签信息,提升了编码的识别能力。当子空间添加到字典偶学习中时,不仅可以更好地表征噪声和高度混合的像元,而且降低了光谱特征的维度,实验结果表明这种分类器结构简单、容易训练、收敛速度快,是一种有效的遥感图像分类方法。

利用字典偶学习模型和算法的进一步研究工作是:(1)为了更好地区分易混淆的类别,可以选取更具有代表性的地物特征用于训练,有利于分类精度提高和速度提升;(2)可以添加纹理信息有助于区分地物;(3)可以针对不同的类别使用的不同的分类器,联合多种分类器进一步提高分类效果。

参考文献

[1] 苏红军, 杜培军, 盛业华. 高光谱遥感数据光谱特征

提取算法与分类研究. *计算机应用学报*, 2008, 25(2):390-395

- [2] Falco N, Benediktsson J A, Bruzzone L. A study on the effectiveness of different independent component analysis algorithms for hyperspectral image classification. *IEEE journal of selected topics in applied earth observations and Remote Sensing*, 2014, 7(6):2183-2198
- [3] Zhou Y, Peng Y, Chen C L P. Dimension reduction using spatial and spectral regularized local discriminant embedding for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53(2):1082-1094
- [4] 罗文斐, 钟亮, 张兵等. 基于子空间距离的高光谱图像光谱解混算法. *自然科学进展*, 2008, 18(10):1175-1180
- [5] Khodadadzadeh M, Li J, Plaza A, et al. A subspace-based multinomial logistic regression for hyperspectral image classification. *IEEE geoscience and remote sensing letters*, 2014, 11(12):2105-2109
- [6] Gao L, Li J, Khodadadzadeh M, et al. Subspace-based support vector machines for hyperspectral image classification. *IEEE geoscience and remote sensing letters*, 2015, 12(12):349-353
- [7] Fang L, Li S, Kang X, et al. Spectral-spatial hyperspec-

- tral image classification via multiscale adaptive sparse representation. *IEEE Transactions on geoscience and remote sensing*, 2014, 52(12):7738-7749
- [8] Fauvel M, Tarabalka Y, Benediktsson J A, et al. Advances in spectral-spatial classification of hyperspectral images. *Proceedings of the IEEE*, 2013, 101(3):652-675
- [9] 赵春晖, 乔蕾. 基于改进的最小二乘支持向量机的高光谱遥感图像分类. *应用科技*, 2008, 35(1):44-48
- [10] Li J, Huang X, Gamba P, et al. Multiple feature learning for hyperspectral image classification. *IEEE Transactions on geoscience and remote sensing*, 2015, 53(3):1592-1605
- [11] Zongze Y, Hao S, Kefeng J, et al. Hyperspectral image classification using discriminative dictionary learning. *Earth and Environmental science*, 2014, 17(1):682-691
- [12] Yuan H L, Tang Y Y, Lu Y, et al. Hyperspectral image classification based on regularized sparse representation. *IEEE journal of selected topics in applied earth observations and remote sensing*, 2014, 7(6):2174-2182
- [13] Benediktsson J A, Pesaresi M. Feature extraction and classification of urban high-resolution satellite imagery based on morphological preprocessing. *IEEE International Geoscience & Remote Sensing Symposium*, 2001, 1:534-536
- [14] Benediktsson J A, Palmason J A, Sveinsson J R. Classification of hyperspectral data from urban areas based on extended morphological profiles. *IEEE Transactions on Geoscience and Remote Sensing*, 2005, 43:480-491
- [15] Mura M D, Benediktsson J A, Waske B, et al. Extended profiles with morphological attribute filters for the analysis of hyperspectral data. *International Journal of Remote Sensing*, 2010, 31(22):5975-5991
- [16] Li J, Bioucas-Dias J M, Plaza A. Spectral-spatial hyperspectral image segmentation using subspace multinomial logistic regression and Markov random fields. *IEEE Transactions on geoscience and remote sensing*, 2012, 50(3):809-822
- [17] Gu S, Zhang L, Zuo W, et al. Projective dictionary pair learning for pattern classification. *Advances in Neural Information Processing Systems*, 2014, 1:793-801

Subspace-based dictionary pair learning for hyperspectral image classification

Wang Jinjia, Jiang Xue, Yang Zhongyu

(School of Information Science and Engineer, Yanshan University, Qinhuangdao, Hebei 066004)

Abstract

In view of the problem of huge data amount from hyperspectra's high resolution and the mixed pixels problem from the spatial resolution, a subspace-based dictionary pair learning (DPL) algorithm, abbreviated to DPLsub algorithm, was presented. The DPL algorithm is an improvement of the dictionary learning, which reflects the high efficiency in pattern recognition through learning a synthesis dictionary and an analysis dictionary, while the subspace projection method better characterizes noise and highly mixed pixels. The fusion of spectra and spatial characteristics was applied to the classification experiment, and two hyperspectral images were used as the experimental data to compare the classification result of the DPLsub model with that of the other three classifiers of least squares support vector machine (LS-SVM), sparsenultinomial logistic regression (SMLR) and dictionary learning (DL-OMP). The experimental results verifies the feasibility and effectiveness of the proposed DPLsub algorithm in classification of hyperspectral images, and show that it outperforms other current algorithms in time and accuracy.

Key words: hyperspectral image classification, subspace projection, mixed pixels, dictionary pair learning (DPL), fusion features