

高光谱半监督分类的标签约束弹性网图算法

陈逸^{1,2} 闫培新³ 陈基伟^{1,2} 孙玉宝^{1,2*}

¹(江苏省大气环境与装备技术协同创新中心江苏省大数据分析技术重点实验室 江苏 南京 210044)

²(南京信息工程大学自动化学院 江苏 南京 210044)

³(中国人民解放军 63936 部队 北京 102202)

摘要 图半监督算法联合利用少量的标定样本与大量的无标签数据进行学习,可缓解高光谱图像的维数灾难问题,被广泛应用于高光谱图像分类,其核心在于如何确定图模型中各样本的近邻样本。提出一种高光谱图像半监督分类的标签约束弹性网图算法。充分利用有限的样本标签信息,通过顶点间的约束传递形成标签约束矩阵,进而针对每一顶点自适应选取符合标签约束的像素作为表示字典。通过在该字典上的弹性网表示来选择与其最为关联的近邻样本,构建高光谱图像的图表示模型,并基于该图模型实现高光谱图像的半监督分类。实验结果验证了该算法的有效性,相比多个半监督算法,分类准确性更高。

关键词 高光谱图像 标签约束 弹性网表示 半监督分类

中图分类号 TP3

文献标志码 A

DOI:10.3969/j.issn.1000-386x.2020.12.029

LABEL CONSTRAINED ELASTIC NET GRAPH ALGORITHM FOR HYPERSPECTRAL IMAGES SEMI-SUPERVISED CLASSIFICATION

Chen Yi^{1,2} Yan Peixin³ Chen Jiwei^{1,2} Sun Yubao^{1,2*}

¹(Jiangsu Key Laboratory of Big Data Analysis Technology, Jiangsu Collaborative Innovation Center on Atmospheric Environment and Equipment Technology, Nanjing 210044, Jiangsu, China)

²(School of Automation, Nanjing University of Information Science and Technology, Nanjing 210044, Jiangsu, China)

³(No. 63936 Troop, Chinese People's Liberation Army, Beijing 102202, China)

Abstract The graph semi-supervised algorithm combines a small number of labeled samples with a large amount of unlabeled data to learn, which can alleviate the dimensionality disaster of hyperspectral images. It is widely used in hyperspectral images classification, and its core is how to determine the neighbor samples of each sample in the graph model. This paper proposes a label-constrained elastic network graph algorithm for hyperspectral images semi-supervised classification. The given label information was fully utilized, and the label constraint matrix was formed by the constraint propagation between the vertices. Then, for each vertex, the pixels that meet the label constraint were adaptively selected as the representation dictionary of the underlying vertex. The nearest neighbors of each vertex could be found by selecting the mostly related vertices in its elastic net representation upon the associated dictionary, and the semi-supervised classification of hyperspectral images was realized based on the constructed graph model. The experimental results verify the effectiveness of the proposed algorithm, and it has higher classification accuracy than multiple semi-supervised algorithms.

Keywords Hyperspectral image Label constraint Elastic network representation Semi-supervised classification

$$V = \begin{bmatrix} X \\ EMP \end{bmatrix} \in \mathbf{R}^{[m(2n+1)+d] \times N} \quad (1)$$

式中: X 为光谱特征矩阵; EMP 为 EMP 特征矩阵,由每个像素点 x 的 $EMP(x)$ 特征向量联合而成, $EMP(x) = \{MP_{PC^1}(x), MP_{PC^2}(x), \dots, MP_{PC^m}(x)\}$ 由 m 个主成分(PC)的 MP 特征联合组成^[22],每个 PC 的 MP 特征由不同圆形结构元素在像素点 x 处进行开操作和闭操作得到; n 是半径不同的圆形结构元素的个数,则一个 MP 特征维度为 $(2n+1)$, d 是光谱波段的数量, N 为样本数量。

不同于现有模型直接将所有样本自身作为字典的方式,本文利用标签约束信息对每个样本构建对应的表示字典,建立标签约束的弹性网表示来生成图模型,有利于提升构图的准确性。整个模型的框图如图 2 所示。




图2 标签约束的弹性网表示

1.1 标签约束的字典生成

文献[16-18]针对顶点集中每一顶点,将其他所有顶点作为字典进行稀疏分解,由于字典中包含了所有类别的顶点,这增加了误选不同类别顶点作为近邻的概率,同时增加了样本系数分解的复杂度。本文利用给定的样本标签,通过标签传递形成顶点间的标签约束矩阵,标识各顶点间属于同一类别的置信度,进而利用该信息,可选择置信度高的像素作为当前样本的表示字典,有利于降低误选不同类别顶点作为近邻的概率。

由于高光谱图像只存在少量有限的样本具有标签约束信息,所以希望通过初始的标签约束信息,将其传递到无标签约束的样本上,使得所有样本之间都拥有标签约束信息。

给定一个高光谱数据集 $X = \{x_i\}_{i=1}^N$, 数据样本数量为 N , 其中 x_i 代表第 i 个样本的特征。选取部分样本进行标记,得到标签成对约束信息。定义属于同一类别即可以连接的集合为 $ML = \{(x_i, x_j) \mid l_i = l_j\}$, 属于不同类别即必然不连接的集合为 $NL = \{(x_i, x_j) \mid l_i \neq l_j\}$, 其中 l_i 代表样本 x_i 的类别标签。根据文献[23], 标签约束传递的过程就是确定两个未知标签的样本是属于必然不连接集合还是可以连接集合,等价于将两个样本之间的关系分类为 +1 类或者 -1 类。

首先,定义初始约束矩阵 $Z = [z_{ij}]_{N \times N}$ 如下:

$$z_{ij} = \begin{cases} 1 & (x_i, x_j) \in ML \\ -1 & (x_i, x_j) \in NL \\ 0 & \text{其他} \end{cases} \quad (2)$$

然后,通过高斯核函数度量样本之间的相似性。成对约束的传递可以看作一个两类的半监督学习问题,具体可以定义为^[23]:

$$\min_U \|U - Z\|_F^2 + \frac{\delta}{2} \text{tr}(U^T L U + U L U^T) \quad (3)$$

式中: $\delta > 0$ 为正则化参数; tr 为矩阵的迹算子; Z 是初始约束矩阵; L 是图的正则化拉普拉斯矩阵; U 是期望获得的标签约束矩阵。

式(3)具有解析解,标签约束矩阵 U 计算如下:

$$U^* = (1 - \alpha)^2 (I - \alpha \bar{L})^{-1} Z (I - \alpha \bar{L})^{-1} \quad (4)$$

最后,得到标签约束矩阵 $U = [u_{ij}]_{N \times N}$ 。式(4)中: $\alpha = \delta / (\delta + 1)$, $\bar{L} = I - L$ 。 u_{ij} 代表了两个样本是否为同一类的置信度。如果 $u_{ij} > 0$, 那么代表样本 (x_i, x_j) 很有可能属于同一类别,可以建立连接;反之,如果 $u_{ij} < 0$, 那么代表样本 (x_i, x_j) 很有可能属于不同类别,不应连接。

基于获得的标签约束矩阵 U , 可为每一顶点构建标签约束的字典。对于高光谱图像的每一个像素点 x_i , 根据标签约束信息 U_i , 挑选出前 M 个置信度最高的像素 x_j 构建标签约束字典 D_i :

$$D_i = \{x_j \mid R_M(U_i), j \neq i\} \quad (5)$$

式中: $R_M(U_i)$ 表示选取 U_i 中前 M 个最大置信度的像素作为字典原子。根据标签约束信息,只有与当前顶点类别最为一致的样本才会被选中作为字典的原子,有利于提升后续分解的准确性。

1.2 标签约束的弹性网表示

基于式(5)的字典生成方法,本文进一步构建高光谱图像的弹性网表示模型,该模型在 l_1 约束的基础上加上 l_2 惩罚项^[24],能够度量非零系数间的相关性,选取多个相关的样本来表征当前样本。

基于每个像素点构建的标签约束字典,进行弹性网表示,获取样本稀疏表示的系数矩阵。关于构建标签约束字典的方法,已在 1.1 节中详细阐述,由式(5)即可得到。通过求解下面的约束优化问题找到数据集 X 中所有像素点的弹性网表示^[25]:

$$\begin{aligned} \min_{C, E} & \|C\|_1 + \lambda \|C\|_F^2 + \gamma \|E\|_{2,1} \\ \text{s. t.} & x_i = D_i c_i + e_i \quad 1 \leq i \leq N \end{aligned} \quad (6)$$

式中: c_i 是 x_i 基于字典 D_i 获得的表示系数; $C = [c_1, c_2, \dots, c_N]$ 是系数矩阵; E 是表征误差矩阵; λ 和 γ 是正则化参数。本文使用最小角回归法(Least Angle Regression, LARS)求解式(6)的模型,可获得所有样本

的表示系数矩阵 C 。

2 半监督分类算法设计

本节基于所构建的标签约束弹性网图模型进行半监督分类学习。给定包含 n 个样本的高光谱数据集 $X = \{x_1, \dots, x_l, x_{l+1}, \dots, x_n\}$, 前 l 个数据样本点有标签, 对应样本标签为 $y_i \in L, L$ 为样本类别标签集 $\{1, 2, \dots, c\}$, 剩余的其他样本点未标记。由此可得初始的标签矩阵 $Y_{n \times c}$, 如果样本 x_i 的标签 $y_i = j$, 那么记标签矩阵内元素 $Y_{ij} = 1$, 否则记 $Y_{ij} = 0$ 。半监督学习的目标是预测所有样本的标签, 其表示为 $n \times c$ 的矩阵, $F = [F_1^T, F_2^T, \dots, F_n^T]^T$ 对应数据集 X 的分类结果。

本文利用前 l 个样本的标签信息, 通过式(4)获得标签约束矩阵后, 进一步求解式(6)的标签约束弹性网表示模型。根据每个样本点的弹性网稀疏表示系数 C 可以构建用于半监督分类的图模型, 样本之间的系数可以直接作为边的权重:

$$W = \frac{|C| + |C|^T}{2} \quad (7)$$

进一步建立该图上的半监督分类模型, 对高光谱图像进行分类。图的半监督学习模型可以表示为以下正则化问题:

$$F = \min_F \frac{1}{2} \sum_{i=1}^l \|F_i - Y_i\|_2^2 + \mu \cdot \text{tr}(F^T \Delta F) \quad (8)$$

式中: 第一项约束前 l 个样本的预测标签与真实标签应趋于一致; 第二项约束预测标签分布的光滑性; Δ 是标签约束弹性网图的拉普拉斯矩阵, $\Delta = I - D^{-1/2} W D^{-1/2}$; D 为所构建图的度矩阵; tr 为矩阵的迹算子; μ 是正则化参数, 权衡两项的作用。

式(8)可通过迭代算法进行求解, 迭代 $F(t+1) = \beta \Delta F(t) + (1-\beta)Y$ 直至收敛, 其中 $\beta \in (0, 1)$ 。 F^* 是 $\{F(t)\}$ 的收敛值, 最终的优化解析解可以表示为:

$$F^* = (I - \beta \Delta)^{-1} Y \quad (9)$$

根据获得的矩阵 F , 每个样本的类别判别为:

$$f_i = \arg \max_{j \leq c} f_{ij} \quad (10)$$

完整的算法流程参见算法 1。

算法 1 高光谱半监督分类的标签约束弹性网图算法

输入: 高光谱数据矩阵 X , 初始标签约束矩阵 Z 。

输出: 分类结果 f_1, f_2, \dots, f_n 。

- 1) 构建空谱联合特征。
- 2) 根据式(4)进行标签传递得到标签约束矩阵 U 。
- 3) 根据 U 针对每个像素点构建字典 D_i 。
- 4) 根据式(6)求解标签约束的弹性网表示, 获取系数矩阵 C 。

5) 构建高光谱图像的标签约束弹性网图模型, 计算拉普拉斯矩阵 $\Delta = I - D^{-1/2} W D^{-1/2}$, W 是邻接矩阵, D 是度矩阵。

6) 依据式(9)计算预测的标签矩阵 $F = [F_1^T, F_2^T, \dots, F_n^T]^T$ 。

7) 依据式(10)判别各像素点 x_i 的预测标签 f_i 。

3 实验

为了验证本文提出的高光谱图像半监督分类的标签约束弹性网图算法(LCE + SSL)的有效性, 将其与以下几种方法进行比较, 包括:

- 1) 只使用光谱特征的支持向量机进行像素分类(PX + SVM);
- 2) 采用支持向量机对扩展形态学特征和光谱特征级联的像素进行分类(EMP + SVM)^[7];
- 3) 文献[15]中提出的基于图的半监督学习(Graph + SSL);
- 4) 利用形态学属性剖面的稀疏表示进行分类(SR + EMAPs)^[18];
- 5) 对空谱联合特征仅使用高斯核构图的半监督分类学习(GGraph + SSL);
- 6) 空谱联合特征的标签约束高斯核构图的半监督分类学习(LCG + SSL)。

本文采用以下定量指标来评估分类结果的性能: 每类样本分类的准确率, 所有样本分类的总体准确率 OA, 各类样本分类的平均准确度 AA, Kappa 系数。

3.1 高光谱数据集

本文所使用的高光谱图像数据集主要为:

1) Indian Pines(IP) 高光谱数据集。该高光谱数据集是 20 世纪 90 年代由 AVIRIS 传感器采集的印第安纳州西北部的 Indian Pines 实验基地图像。其图像大小为 145 像素 \times 145 像素, 原始波段去除掉 24 个受干扰的光谱波段, 一般使用留下的 200 个光谱波段进行实验, 地面分辨率为 20 m \times 20 m, 地面覆盖物的类别一共有 16 类。

2) Salinas Scene(SS) 高光谱数据集。该高光谱数据集也是由 AVIRIS 传感器所采集的, 是美国加利福尼亚州 Salinas 山谷上空的图像。图像大小为 512 像素 \times 217 像素, 原始波段去除掉 20 个不可用的光谱波段, 使用留下的 204 个光谱波段进行分类实验, 地面分辨率为 3.7 m \times 3.7 m, 地面覆盖物的类别一共有 16 类。

3.2 实验设置

由于高光谱图像的特殊性, 利用构图来进行分类时, 直接处理整个高光谱图像会导致非常大的计算负担。例如 IP 数据集的大小为 145 像素 \times 145 像素, 如

果对其直接进行构图,其权重矩阵的大小为 $21\ 025 \times 21\ 025$,所以在进行实验的时候选择将其分割为大小约为 $73\ \text{像素} \times 73\ \text{像素}$ 的不重叠小块,逐一对其进行处理与实验,最后再合成观察实验效果。

关于实验中两个参数 α 和 β 对分类性能的影响,从给定的集合 $\{0.1, 0.3, 0.5, 0.7, 0.9\}$ 中选取这两个参数进行实验。经过大量实验对比,找到最优的 α 和 β 以获得最好的分类效果。

3.3 实验对比

在每个数据集中,分别从每个类中随机选取 10% 的像素作为标签样本。分类结果分别见表 1 和表 2,最优的结果用粗体显示。

表 1 标签样本为 10% 的 IP 数据集的 OA、AA、Kappa 系数和平均类准确率 %

指标	PX + SVM	EMP + SVM	Graph + SSL	SR + EMAPs	GGraph + SSL	LCG + SSL	LCE + SSL
C1	38.05	73.91	20.87	91.95	84.78	89.13	86.96
C2	78.72	87.82	71.05	82.51	89.78	90.83	95.17
C3	68.70	86.51	51.52	89.06	84.94	79.76	88.80
C4	52.96	83.97	48.95	63.24	80.59	84.39	80.59
C5	90.11	90.64	91.39	93.62	96.89	93.58	93.37
C6	96.44	98.44	93.51	99.27	98.36	99.18	98.49
C7	66.40	90.00	89.29	97.20	32.14	89.29	96.43
C8	96.51	98.95	100	100	98.74	99.16	99.58
C9	38.89	53.00	18.00	27.78	10.00	95.00	60.00
C10	71.20	85.49	77.53	84.49	93.83	95.78	94.75
C11	78.62	87.98	83.60	94.83	93.73	94.01	94.42
C12	70.79	84.25	39.87	89.27	78.08	82.80	88.03
C13	97.28	98.63	99.41	98.21	98.54	99.51	98.05
C14	90.97	96.27	98.91	99.70	99.37	98.34	99.84
C15	58.27	90.26	49.64	97.61	66.84	77.46	90.93
C16	87.38	99.78	88.17	96.02	95.70	98.92	93.55
OA	79.65	89.98	77.76	91.76	91.40	92.33	94.40
AA	73.83	87.78	70.11	87.80	81.39	91.70	91.19
Kappa 系数	76.76	88.56	74.51	90.88	90.20	91.26	93.61

表 2 标签样本为 10% 的 SS 数据集的 OA、AA、Kappa 系数和平均类准确率 %

指标	PX + SVM	EMP + SVM	Graph + SSL	SR + EMAPs	GGraph + SSL	LCG + SSL	LCE + SSL
C1	99.37	99.93	99.89	100	99.45	99.95	98.95
C2	99.92	99.83	96.34	99.94	99.97	99.95	99.97
C3	99.66	99.78	94.10	99.93	100	99.75	100

续表 2

指标	PX + SVM	EMP + SVM	Graph + SSL	SR + EMAPs	GGraph + SSL	LCG + SSL	LCE + SSL
C4	99.27	99.00	99.17	99.44	98.92	99.64	99.57
C5	98.83	99.21	98.43	98.51	98.28	98.58	97.91
C6	99.90	99.94	99.93	99.86	99.80	99.97	99.77
C7	99.71	99.75	99.96	99.80	100	99.89	99.41
C8	87.54	94.36	96.48	99.04	98.45	96.42	99.02
C9	99.60	99.95	99.57	99.93	99.97	100	100
C10	96.71	99.19	98.77	98.98	98.38	98.32	99.51
C11	97.96	99.57	96.42	98.82	93.63	96.16	98.78
C12	99.79	99.98	95.23	100	99.79	100	99.64
C13	98.96	99.48	94.67	99.23	98.58	98.80	98.47
C14	96.68	99.66	94.15	97.89	96.45	97.38	97.85
C15	76.51	88.31	92.61	86.97	95.12	95.01	97.04
C16	99.00	99.61	99.81	100	100	100	100
OA	93.71	97.05	97.12	97.79	98.54	98.23	99.05
AA	96.86	98.60	97.22	98.65	98.55	98.74	99.12
Kappa 系数	92.99	96.72	96.79	97.12	98.38	98.03	98.94

表 1 列出了各算法在 Indian Pines (IP) 高光谱数据集上的实验结果,在使用支持向量机的两个实验中,通过 OA、AA、Kappa 系数三个指标来观察,EMP + SVM 的分类效果明显优于 PX + SVM,由此可以学习到空谱联合特征的使用确实可以提升分类效果。Graph + SSL 也取得了不错的分类效果,与 SVM 不同的是,基于图的方法将标签通过边传播到近邻的顶点上,使其获得正确标签达到分类的结果。另外利用 EMAPs 的稀疏表示模型和高斯核构图的方法在分类效果上有了大幅度提升,可见构建特征表示的模型方法也很重要。与 GGraph + SSL 相比,LCG + SSL 在构图时利用到了标签成对约束信息,三个指标都有所提升,特别是 AA 得到了很大的提升,可见标签约束对构图及分类效果的提高起到相当可观的作用。LCE + SSL 与 LCG + SSL 相比,虽然在构图时都使用到了标签约束信息,但是构图时使用弹性网的方法,进一步提升了分类准确性。综上所述,从 OA、AA、Kappa 系数三个方面结合来看,本文提出的高光谱图像半监督分类的标签约束空谱联合特征弹性网图算法 (LCE + SSL) 比其他方法得到的分类效果都要好。本文方法不仅在三个指标上都达到了 90% 以上的正确率,并且在每类样本的分类上都达到了很好的效果。由于部分样本的训练样本数量较少,如第 1 类、第 9 类等样本,因此其他方法分类的效果都

比较差,而本文方法的分类效果明显有了很大的提升。

图 3 为 IP 数据集上各个实验的分类效果图,可以看出本文方法的分类图出错率更低,分类效果更好。

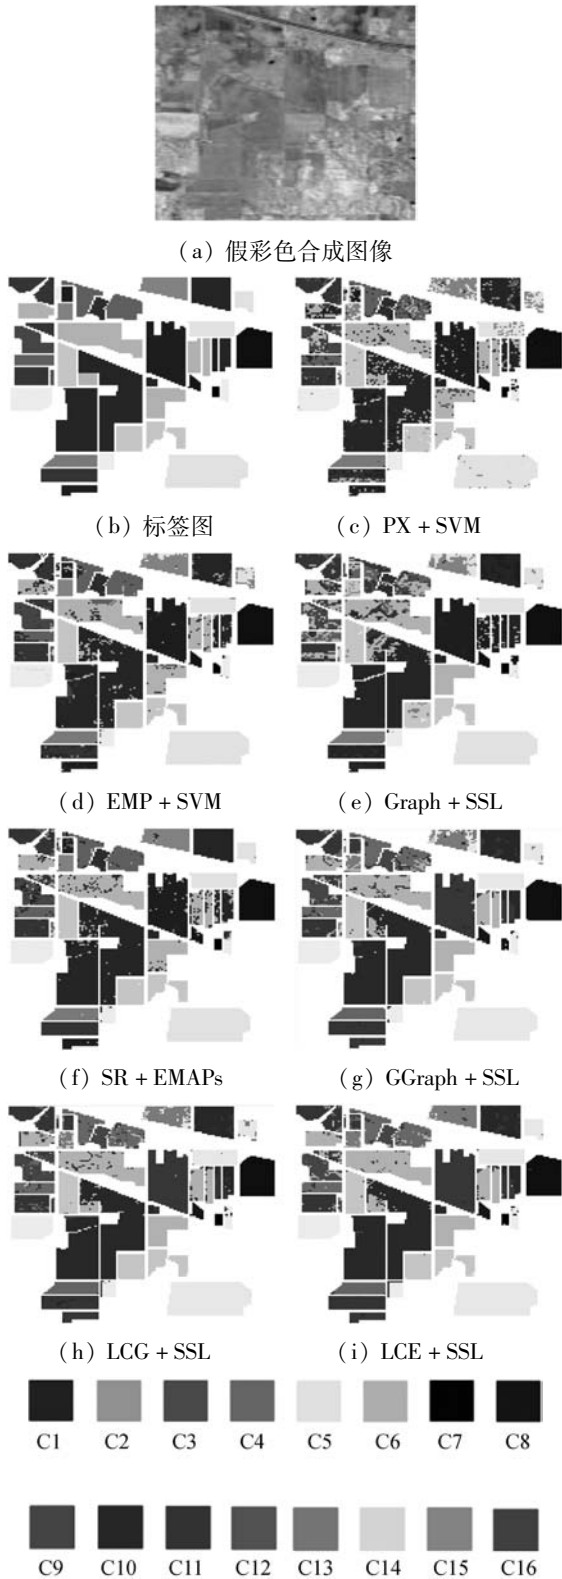


图 3 IP 数据集的分类效果图

表 2 是基于 Salinas Scene(SS)高光谱数据集进行的实验,与 IP 数据集一样,选择从每类样本中随机选择 10% 的像素作为标签样本。该数据集由于每类样本的分布较为均匀,所有的算法基本上都可以达到比

较不错的分类效果,尤其是本文方法,更是达到了 99% 以上的优异效果,有些样本的分类正确率甚至达到了 100%。该数据集的分类效果图如图 4 所示。

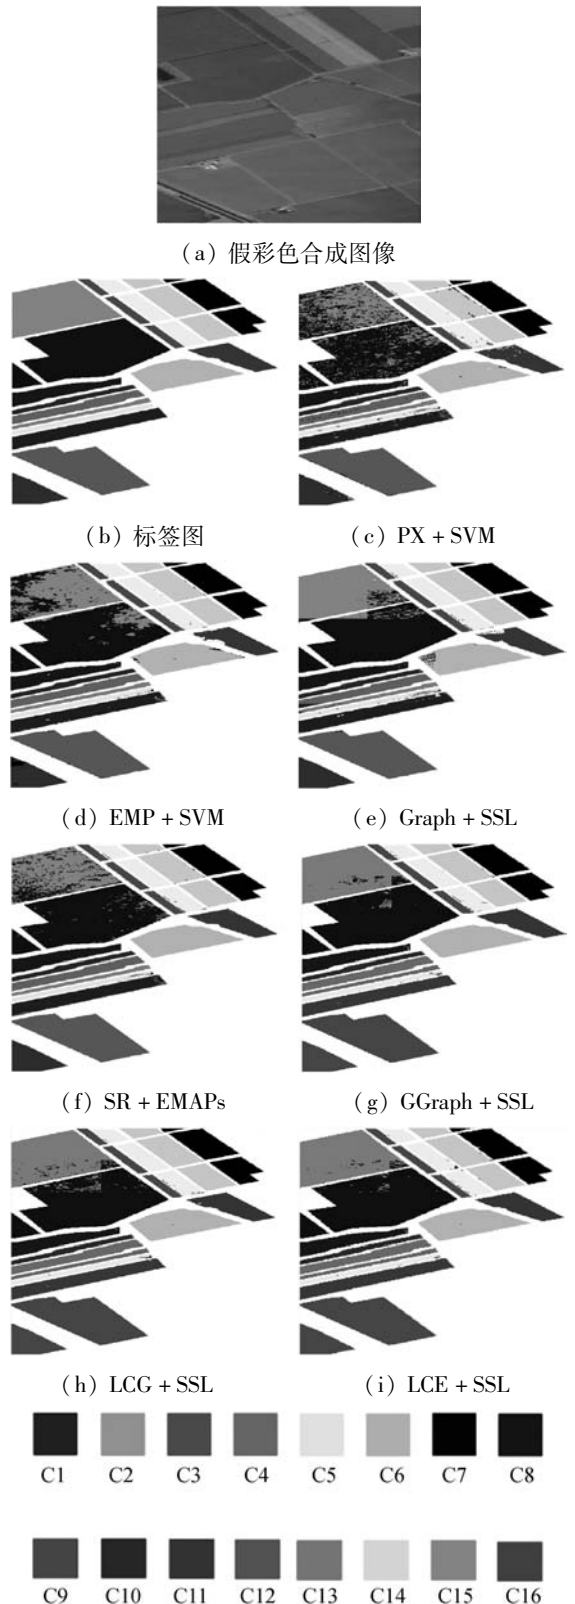


图 4 SS 数据集上的分类效果图

实验结果证明,本文方法总体上的分类效果最优,利用标签约束信息的弹性网构图有助于提高分类准确性。

4 结 语

针对高光谱图像的分类问题,本文提出了一种标签约束的弹性网表示图模型用于高光谱图像半监督分类。在特征表示上,选择将空间特征与光谱特征相联合构成空谱联合特征。在弹性网分解时利用了标签约束信息,降低了计算复杂度,使得构图更加准确。在基于图的半监督分类模型上,本文使用两个高光谱图像进行多次实验,采用六种方法与本文的方法进行对比,实验结果均表明,本文方法具有较好的分类性能。

参 考 文 献

- [1] 叶志京. 面向高光谱图像空谱分类的学习算法研究[D]. 武汉:华中科技大学,2016.
- [2] 高恒振. 高光谱遥感图像分类技术研究[D]. 长沙:国防科学技术大学,2011.
- [3] Hecker C, Meijde M V D, Werff H V D, et al. Assessing the influence of reference spectra on synthetic SAM classification results[J]. IEEE Transactions on Geoscience and Remote Sensing,2008,46(12):4162-4172.
- [4] Ghamisi P, Benediktsson J A, Sveinsson J R. Automatic spectral-spatial classification framework based on attribute profiles and supervised feature extraction[J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 52(9): 5771-5782.
- [5] Li J, Bioucas-Dias J M, Plaza A. Hyperspectral image segmentation using a new bayesian approach with active learning[J]. IEEE Transactions on Geoscience and Remote Sensing,2011,49(10):3947-3960.
- [6] Pesaresi M, Benediktsson J A. A new approach for the morphological segmentation of high-resolution satellite imagery[J]. IEEE Transactions on Geoscience and Remote Sensing,2001,39(2):309-320.
- [7] Fauvel M, Benediktsson J A, Chanussot J, et al. Spectral and spatial classification of hyperspectral data using SVMs and morphological profiles[J]. IEEE Transactions on Geoscience and Remote Sensing,2008,46(11):3804-3814.
- [8] Jensen J R. Introductory digital image processing: A remote sensing perspective[M]. Prentice Hall,2004.
- [9] Cheng Y E, Zhou S G, Yuan C Q, et al. Hyperspectral image classification based on active deep learning[J]. Computer Engineering and Applications,2017,53(17):192-196.
- [10] Zhu X J. Semi-supervised learning literature survey[R/OL]. US:University of Wisconsin-Madison,2008. [2019-08-06]. http://pages.cs.wisc.edu/~jerryzhu/pub/ssl_survey.pdf.
- [11] Chapelle O, Scholkopf B, Zien A. Semi-supervised learning [M]. Cambridge, MA, USA: MIT Press,2006.
- [12] 梅松青. 基于自适应图的半监督学习方法[J]. 计算机系统应用,2014,23(2):173-177.
- [13] Yan S C, Xu D, Zhang B Y, et al. Graph embedding: A general framework for dimensionality reduction[C]//2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition(CVPR'05). IEEE,2005:830-837.
- [14] Cai D, He X F, Han J W, et al. Graph regularized nonnegative matrix factorization for data representation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2011,33(8):1548-1560.
- [15] Camps-Valls G, Marsheva T V B, Zhou D Y. Semi-supervised graph-based hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2007,45(10):3044-3054.
- [16] Cheng B, Yang J C, Yan S C, et al. Learning with l1-graph for image analysis[J]. IEEE Transactions on Image Processing,2010,19(4):858-866.
- [17] Gu Y F, Feng K. L1-graph semisupervised learning for hyperspectral image classification[C]//2012 IEEE International Geoscience and Remote Sensing Symposium. IEEE,2012:1401-1404.
- [18] Song B Q, Li J, Mura M D, et al. Remotely sensed image classification using sparse representations of morphological attribute profiles[J]. IEEE Transactions on Geoscience and Remote Sensing,2014,52(8):5122-5136.
- [19] Scholkopf B, Platt J, Hofmann T. Learning with hypergraphs: Clustering, classification, and embedding[C]//Proceedings of the 19th International Conference on Neural Information Processing Systems,2006:1601-1608.
- [20] 李二珠. 半监督支持向量机高光谱遥感影像分类[D]. 徐州:中国矿业大学,2014.
- [21] Sun Y B, Wang S J, Liu Q S, et al. Hypergraph embedding for spatial-spectral joint feature extraction in hyperspectral images[J]. Remote Sensing,2017,9(5):506.
- [22] Benediktsson J A, Palmason J A, Sveinsson J R. Classification of hyperspectral data from urban areas based on extended morphological profiles[J]. IEEE Transactions on Geoscience and Remote Sensing,2005,43(3):480-491.
- [23] Lu Z W, Peng Y X. Exhaustive and efficient constraint propagation: A graph-based learning approach and its applications[J]. International Journal of Computer Vision, 2013, 103(3):306-325.
- [24] Zou H, Hastie T. Regularization and variable selection via the elastic net[J]. Journal of the Royal Statistical Society: Series B,2005,67(2):301-320.
- [25] Liu Q S, Sun Y B, Wang C T, et al. Elastic net hypergraph learning for image clustering and semi-supervised classification[J]. IEEE Transactions On Image Processing, 2017,26(1):452-463.