

一种新的两分类器融合的空谱联合 高光谱分类方法

孙 乐^{1,2}, 吴泽彬³, 冯 灿⁴, 刘建军³, 肖 亮³, 韦志辉³

(1. 江苏省网络监控工程中心, 江苏南京 210044; 2. 南京信息工程大学计算机与软件学院, 江苏南京 210044;
3. 南京理工大学计算机科学与工程学院, 江苏南京 210094; 4. 北方信息控制集团软件中心, 江苏南京 211153)

摘 要: 本文提出一种两分类器融合的高光谱空谱联合分类方法, 首先利用子空间多项式逻辑回归在图像的特征子空间中分类, 得到满概率图; 根据满概率将每个像素分至概率最大的两个最可信类别, 并在原始空间中构建最可信类别字典, 利用稀疏解混对每个像素在最可信类别字典下进行稀疏表示, 得到稀疏概率图; 最后将满概率图和稀疏概率图线性融合, 并利用边缘保持的马尔可夫正则项挖掘图像空间信息, 得到具有边缘保持的空谱分类模型. 实验表明, 提出的两分类器融合方法即使在训练样本较少时也比现有方法得到更好的分类结果.

关键词: 高光谱分类; 子空间逻辑回归; 稀疏解混; 多分类器; 马尔可夫正则项

中图分类号: TP751 **文献标识码:** A **文章编号:** 0372-2112 (2015)11-2210-08

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2015.11.011

A Novel Two-Classifier Fusion Method for Spectral-Spatial Hyperspectral Classification

SUN Le^{1,2}, WU Ze-bin³, FENG Can⁴, LIU Jian-jun³, XIAO Liang³, WEI Zhi-hui³

(1. Jiangsu Engineering Center of Network Monitoring, Nanjing, Jiangsu 210044, China;
2. School of Computer and Software, Nanjing University of Information Science and Technology, Nanjing, Jiangsu 210044, China;
3. Computer Science and Engineering, Nanjing University of Science and Technology, Nanjing, Jiangsu 210094, China;
4. Software Center of China North Industries Group Corporation, Nanjing, Jiangsu 211153, China)

Abstract: This paper presents a new multiple-classifier approach for spectral-spatial classification of hyperspectral images (HSI). Firstly, subspace based multinomial logistic regression (MLRsub) method is used to calculate the full probability of each pixel in the feature space; Secondly, the sub-dictionary is constructed by the training samples of the most two reliable classes, which is determined by the full probability for each pixel. Then, sparse unmixing (SU) is used to calculate the sparse probability in the original HSI. Finally, the full probability and sparse probability are fused linearly and the spatial information is exploit by an edge preserving Markov random field (MRF) regularizer. Experimental results indicate that our proposed multiple-classifier leads to better classification performance than the state-of-the-art methods, even with small training samples.

Key words: hyperspectral classification; subspace multinomial logistic regression; sparse unmixing; multiple classifier; MRF regularizer

1 引言

高光谱图像由成百个连续波段图像构成, 波段范围从可见光延伸到近红外(400 ~ 2500 纳米)^[1]. 不同地物在不同波段上的反射强度不同, 使得高光谱像元具有不同的光谱曲线, 这为高光谱图像分类提供了固有的特

点^[2,3]. 近年来, 许多学者提出了很多有效的算法^[4~18]. 其中, 支持向量机(support vector machine, SVM)在高光谱有监督分类方面应用较好, 如文献[5,6]利用 SVM 与形态学属性结合的方法对高光谱图像进行分类. 此外, 多项式逻辑回归^[7~9](multinomial logistic regression, MLR)在自学习类别间概率分布方面具有很大优势, 它是种利用

收稿日期: 2014-02-27; 修回日期: 2014-07-30; 责任编辑: 蓝红杰

基金项目: 国家自然科学基金(No. 61101194, No. 61301215, No. 61301217); 国家自然科学基金面上项目(No. 61471199); 江苏省气象探测与信息处理重点实验室开放课题(No. KDXS1404); 江苏省自然科学基金(青年项目)(No. BK20150923); 南京信息工程大学人才启动经费; 江苏省光谱成像与智能感知重点实验室开放课题

交替迭代来处理不适定问题的方法.子空间多项式逻辑回归(subspace based MLR, MLRsub)^[9]主要从特征空间中挖掘高光谱数据的本质:由于空间分辨率较低,高光谱数据多是以混合像元(mixed pixel)的形式存在.该方法基于多项式逻辑回归模型独立地学习各个类别子空间,并被应用来解决高光谱分类这一不适定问题.稀疏表示方法^[10]是另一类应用于高光谱分类领域的新方法,该方法假设任一像元都是存在于由它同类别像元张成的子空间中的,即任一像元都可以由同类别的少数几个像元线性表示,其优点在于直接把训练样本集合当做稀疏表示字典.以上三类方法通常只考虑光谱信息,为了更好的挖掘高光谱图像的空间信息,结合光谱信息和空间信息的方法^[10~16]被越来越多的学者所提出,如联合稀疏表示(joint sparse representation)^[10]方法,组合核(composite kernel)^[11,12]方法,划分聚类(partitional clustering)^[13]方法,扩展形态学属性(extended morphological profiles)^[14]方法,以及马尔科夫场(Markov random field)^[7,8,15,16]方法.

然而以上方法都是单一的分类方法,具有各自的优点,没有体现几种方法相融合的优点,因此,研究者们提出了多分类器融合(multiple classifier fusion, MCF)^[17~19]的高光谱图像分类.多分类器系统将多个分类器的结果以一定的方式融合起来,从而得到更好的分类结果,通过这种方式可以显著提高分类器的泛化性能.

基于以上讨论,本文提出一种新的两分类器融合的高光谱图像空谱联合分类方法,即稀疏性解混和子空间多项式逻辑回归分类器融合的高光谱图像分类方法.文献[20]提出了利用局部和全局概率分布进行融合分类的框架,但其利用 SVM 与逻辑回归相结合的方法仅从机器学习方面入手,并未考虑特征空间与原始高光谱数据空间的光谱特性的融合,而本文不仅仅从局部和全局概率分布,而且考虑特征空间与原始空间概率分布相结合的方法,同时引入了边缘保持的概念,得到一种新的具有边缘保持特性的空谱联合分类方法.

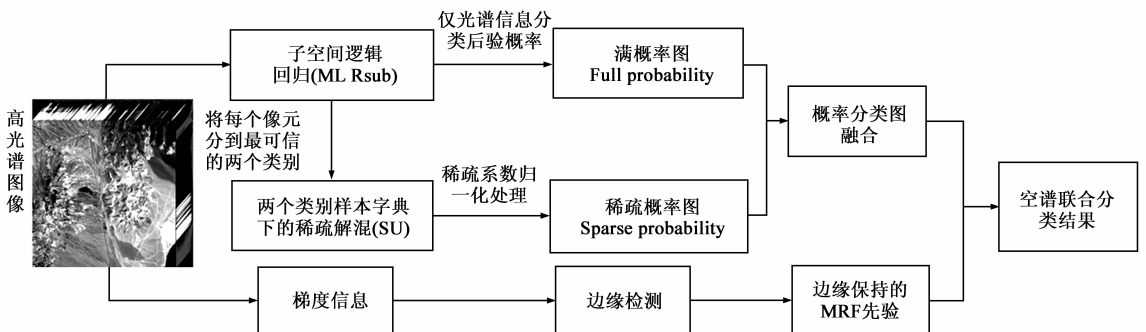


图1 多分类器框架下的高光谱空谱联合分类流程图

2 仅光谱信息两分类器融合的高光谱分类

子空间逻辑回归的优点在于充分挖掘特征空间的光谱特性;稀疏表示方法的优点是能够直接利用训练样本构成字典对待分类像元进行稀疏表示.因此,本文将特征空间和原光谱空间的特征进行融合,同时考虑全局分类(像元级)与局部分类(亚像元级)的特性,提出了一种两分类器融合的高光谱图像空谱联合分类方法,流程如图1所示.

2.1 子空间多项式逻辑回归(MLRsub)分类器

假设 $\mathbf{x} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n\}$ 为高光谱图像,其中 $\mathbf{x}_i = [x_{i1}, x_{i2}, \dots, x_{iL}]^T$ 是坐标为 $i \in S$ 的 L 维光谱向量, $S = \{1, 2, \dots, n\}$ 为图像 \mathbf{x} 中的 n 个像元的索引集合, L 是波段数. $\mathbf{y} = \{\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_n\}$ 为对应高光谱图像 \mathbf{x} 的分类标记,其中, $\mathbf{y}_i = [y_{i1}, y_{i2}, \dots, y_{iK}]^T$, K 为类别数,且 $y_{ik} = \{0, 1\}$, $\sum_k y_{ik} = 1$, $k \in \{1, 2, \dots, K\}$. $\mathbf{D}_l = \{(\mathbf{x}_1, \mathbf{y}_1), \dots, (\mathbf{x}_l, \mathbf{y}_l)\}$ 为样本数为 l 的训练样本集合.

MLRsub 模型^[9]可以写成如下形式:

$$p(y_{ik} = 1 | \mathbf{x}_i, \mathbf{w}) = \frac{\exp(\mathbf{w}^{(k)} \mathbf{h}(\mathbf{x}_i))}{\sum_{k=1}^K \exp(\mathbf{w}^{(k)} \mathbf{h}(\mathbf{x}_i))} \quad (1)$$

其中, $\mathbf{h}(\mathbf{x}_i) = [h_1(\mathbf{x}_i), \dots, h_m(\mathbf{x}_i)]^T$ 是由 m 个固定函数作用在输入数据上的向量,通常称作特征; $\mathbf{w}^{(k)}$ 为第 k 类的逻辑回归量,且 $\mathbf{w} = [\mathbf{w}^{(1)T}, \dots, \mathbf{w}^{(K)T}]^T$. 李军等^[9]提出了联合 MLR 和子空间投影的方法来对高光谱进行分类,得到了很好的分类结果,该分类器被称为子空间多项式逻辑回归分类器(MLRsub),MLRsub 的核心思想:每一类别的样本都是存在于一个低维(相对于光谱维而言)子空间中.因此,每一类像元都可以由一组子空间的基向量(basic vectors)张成,而分类的准则即为测试样本到各个类子空间的距离.文献[8]给出了第 k 类的输入函数 $\mathbf{h}^{(k)}(\mathbf{x}_i)$ 的定义:

$$\mathbf{h}^{(k)}(\mathbf{x}_i) = [\|\mathbf{x}_i\|^2, \|\mathbf{x}_i^T \mathbf{U}^{(k)}\|^2]^T \quad (2)$$

其中 $\mathbf{U}^{(k)} = \{\mathbf{u}_1^{(k)}, \dots, \mathbf{u}_{l^{(k)}}^{(k)}\}$ 第 k 类对应的子空间中一组 $l^{(k)}$ 维的正交基向量,且 $l^{(k)} \ll L$.

2.2 稀疏性解混(SU)分类器

稀疏解混分类器对高光谱数据进行分类主要基于以下假设:任一像元都可由它同类别的少数几个像元光谱线性表示.即待分类像元 $x_i \in x$ 是第 k 类的,那么它可由第 k 类训练样本构成的子字典 $A^k = (a_1^k, a_2^k, \dots, a_l^k) \in \mathbb{R}^{L \times l^k}$ 线性表示,即

$$\begin{aligned} x &\approx s_1^k a_1^k + s_2^k a_2^k + \dots + s_l^k a_l^k \\ &= [a_1^k a_2^k \dots a_l^k] \cdot [s_1^k s_2^k \dots s_l^k]^T \\ &= A^k \cdot s^k \end{aligned} \quad (3)$$

其中 s^k 为 l^k 维向量,其分量为测试样本 x 在类别 k 对应的子字典 A^k 中的表示系数.如果将所有类别的训练样本集合看做一个字典 $\{A^k\}_{k=1,2,\dots,K}$,那么任一高光谱像元都可由这一字典中的原子线性表示,且线性表示系数是稀疏的.数学表示为:

$$\begin{aligned} x &\approx A^1 \cdot s^1 + A^2 \cdot s^2 + \dots + A^K \cdot s^K \\ &= \underbrace{[A^1 \dots A^K]}_A \cdot \underbrace{\begin{bmatrix} s^1 \\ \vdots \\ s^K \end{bmatrix}}_s \\ &= A \cdot s \end{aligned} \quad (4)$$

其中 A 为包含所有 K 个类别训练样本的 $L \times l$ 矩阵,且 $l = \sum_{k=1}^K l^k$ 为所有 K 个类别样本的总个数,向量 s 为对应的系数, s 是稀疏的.

稀疏解混分类的过程即为求解稀疏表示系数的过程,本文使用 $\|s\|_0$ 来刻画向量 s 的稀疏性,模型如下:

$$s = \arg \min_s \|A \cdot s - x\|_2^2, \text{ s.t. } s > 0, \|s\|_0 < T_0 \quad (5)$$

其中 $s > 0$ 表示向量 s 的每个分量都大于 0, T_0 为阈值,表示非零系数的个数不得大于 T_0 .采用文献[10]给出的正交匹配追踪(orthogonal matching pursuit, OMP)算法来求解模型(5),其优点在于能够快速求得模型(5)的近似解.

求得系数向量 s 后,为了和逻辑回归分类器得到近似的概率图,需要将 s 进行归一化处理以满足概率分布和为一的性质,则 $\hat{s} = s / \|s\|_2$.由于各类别训练样本对应的表示系数相对分散,为了将待分类像元 x_i 进

行分类需要将 x_i 在各个类别的训练样本中的表示系数进行累加求和,并将其定义为 x_i 分到第 k 类的概率,定义如下:

$$p(y_{ik} = 1 | x_i) = \sum_{j=1}^l s_j^k \quad (6)$$

其中 $y_{ik} = 1$ 表示像元 x_i 被分到第 k 类.

2.3 满概率图和稀疏概率图的融合

为了挖掘特征空间和原始空间、整体和局部之间的分类特性,需要将两类分类器进行融合,具体的融合步骤如图 2 所示.

步骤 1 利用子空间逻辑回归方法挖掘高光谱数据特征空间的分类特性,得到分类概率图.如图 2(a)给出了分类概率图中像元被分到最可信 A、B、C 类的概率最大的两类的比例关系.

步骤 2 根据 MLRsub 得到的概率图将每个像元分至其最可信的两个类别,如图 2(a).为了降低计算复杂度,设置阈值($T = 95\%$),分类概率中最大概率大于或者等于 95% 的像元被认为是纯净像元,其他的为混合像元,如图 2(b)所示.

步骤 3 对混合像元,选择其最可信的两个类别训练样本,在原始高光谱数据空间中构建最可信字典,例如 $A = \{A^1, A^3\}$,并利用 SU 方法求得该像元在其最可信字典下的稀疏表示系数,根据式(6)对求得的稀疏表示系数进行归一化处理,得到该像元的分类概率向量,如图 2(c).遍历整个图像,求得稀疏概率图.

步骤 4 MLRsub 求得的概率图和步骤 3 得到的稀疏概率图进行线性融合,得到融合后的分类概率,如图 2(d).

为了区分两者,称 MLRsub 结果为满概率图而称 SU 结果为稀疏概率图.数学表示如下:

$$p_{full} = \{p(y_{ik} = 1 | x_i, w), k = 1, 2, \dots, K\} \quad (7)$$

$$\begin{aligned} p_{sparse} &= \{p(y_{i1} = 1 | x_i, A), 0, \dots, 0, \\ &\quad p(y_{iK} = 1 | x_i, A)\} \end{aligned} \quad (8)$$

为了更好的利用满概率和稀疏概率,使用线性方法将其融合,如下式所示:

$$p(y_{ik} = 1 | x_i) = \lambda p_{full} + (1 - \lambda) p_{sparse} \quad (9)$$

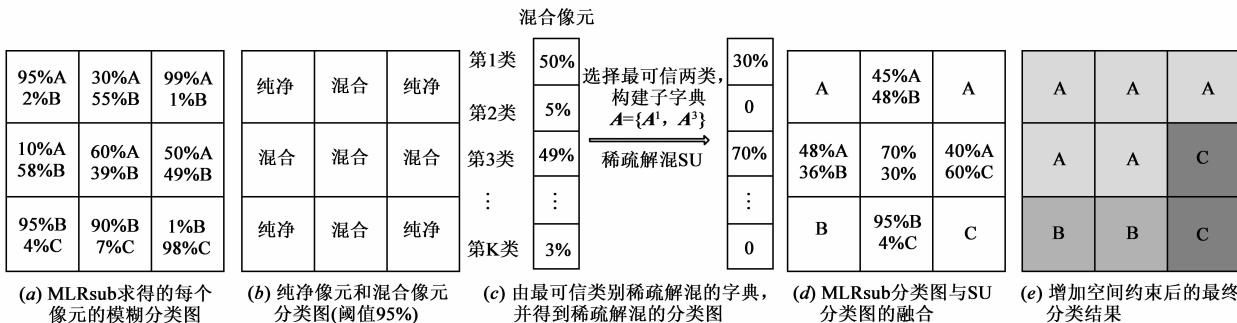


图2 两分类器融合的具体步骤

其中 λ 为调节参数,控制满概率和稀疏概率的比重.

3 边缘保持的马尔可夫场(MRF)空间先验

本文采用马尔可夫场模型^[9]来刻画空间先验,即 $p(\mathbf{y})$ 服从 Gibbs 分布,数学表示为:

$$p(\mathbf{y}) = \frac{1}{Z} \exp\left\{\mu \sum_{|i-j| < \epsilon} \delta(y_i - y_j)\right\} \quad (10)$$

其中, Z 为归一化常数; $|i - j| < \epsilon$ 表示像元 i 和 j 为邻域像元; $\delta(y)$ 是个单位脉冲函数,当 $y = 0$ 时, $\delta(y) = 1$ 而当 $y \neq 0$ 时, $\delta(y) = 0$. $\delta(y_i - y_j)$ 将使邻域像元分到相同标签的概率较大,从而使结果分片光滑,其中参数 μ 控制着分类结果的光滑程度.

边缘信息对图像的分类尤为重要,梯度是刻画图像边缘的有效方法,高光谱图像边缘定义如下:

$$E_i = \begin{cases} 1, & \text{如果 } \Delta \mathbf{x}_i > \tau \\ 0, & \text{其他情况} \end{cases} \quad (11)$$

其中 $\Delta \mathbf{x}_i = \sum_{j \in N_i} \|\mathbf{x}_i - \mathbf{x}_j\|_2$ 定义了像元 i 处的梯度, N_i 为像元 i 的水平和垂直邻域, τ 为阈值.

将边缘信息引入到空间先验中,式(10)重写为:

$$p(\mathbf{y}) = \frac{1}{Z} \exp\left\{\mu \sum_{|i-j| < \epsilon, E_i=0} \delta(y_i - y_j)\right\} \quad (12)$$

这一先验将使得非边缘上的邻域像元具有相同的分类标签,而对于边缘上的像元不进行处理,从而保持图像边缘上的像元类别,避免过分割现象.

4 最大后验估计的空谱联合高光谱分类

综上,在最大后验-马尔可夫场(MAP-MRF)框架下,分类标签 \mathbf{y} 的最大后验估计为:

$$\hat{\mathbf{y}} = \arg \min_{\mathbf{y}} \left(\sum_{i \in S} -\log p(y_i | \mathbf{x}_i) - \mu \sum_{|i-j| < \epsilon, E_i=0} \delta(y_i - y_j) \right) \quad (13)$$

其中,第一项为满概率和稀疏概率线性融合得到的似然概率项,它包含了高光谱图像中的光谱信息;第二项是具有边缘保持性质的 MRF 空间先验项.

模型(13)既包含了光谱信息同时又包含空间信息,且保持了图像的边缘. \mathbf{y} 的值只能是一些不连续的分类号,这一整数优化问题可采用空间加权的图割(graph cut)^[21]方法近似求解,且具有多项式求解时间,空间自适应的权值选择图像梯度的倒数.具体过程见算法 1.

算法 1 MLRsub-SU-MRF-E 两分类器融合的空谱联合分类方法

1. 输入类别个数 K , 训练样本集合 $\mathbf{A} = [\mathbf{A}^1, \mathbf{A}^2, \dots, \mathbf{A}^K]$, 测试样本 \mathbf{x}_i , 高光谱图像中像元个数 N , 融合参数 λ , 平滑参数 μ
2. while $i < N$ do
3. $p_{\text{full}}^i = \text{MLRsub}(\mathbf{A}, K, \mathbf{x}_i)$, $i \in S$
4. $(\mathbf{A}^1, \mathbf{A}^2) = \max(p_{\text{full}}^i, 2)$, 根据 p_{full}^i 求得像元 i 的最可信两个类别 $(\mathbf{A}^1, \mathbf{A}^2)$

5. $p_{\text{sparse}}^i = \text{SU}(\mathbf{A}^1, \mathbf{A}^2, \mathbf{x}_i)$
6. $p(y_i | \mathbf{x}_i) = \lambda p_{\text{full}}^i + (1 - \lambda) p_{\text{sparse}}^i$
7. end while
8. $\hat{\mathbf{y}} = \text{Graphcut}(\mathbf{P}, \mu, E_i)$, 其中 $\mathbf{P} = \{p(y_i | \mathbf{x}_i)\}$, $i \in S$
9. 输出: 分类标签 $\hat{\mathbf{y}} = (\hat{y}_1, \hat{y}_2, \dots, \hat{y}_N)$

5 实验

实验采用两组高光谱遥感数据. 本文方法将与以下算法进行比较: SVM-CK(composite kernel)^[12]组合核方法、逻辑回归分类方法 MLRsub^[9]、稀疏表示分类方法 SU^[10], 核联合稀疏表示方法 KSOMP^[10], 自适应空间 TV 正则项的多项式逻辑回归方法 SMLR-SpTV^[16], MLRsub-MRF 以及 SU-MRF, 其中 MLRsub-SU 代表本文提出的两分类器的融合结果(光谱信息), MLRsub-SU-MRF 和 MLRsub-SU-MRF-E 分别为本文提出的空谱联合以及具有边缘保持特性的空谱联合分类方法. 实验中, SVM-CK 的参数选择采用十次交叉验证的方法, MLRsub 的参数根据文献[9]给出的最优参数设置, 稀疏表示采用 OMP, 非零个数的阈值为 $T_0 = 3$. 对于 MRF 正则项方法, 如未做特殊说明, 一律取 $\mu = 2$. 实验从平均精度(average accuracy, AA)、总精度(overall accuracy, OA)和 Kappa 系数方面进行量化分析, 结果均采用 10 次实验平均值, 最优结果用粗体显示, 次优结果用下划线标出.

5.1 Indian Pines 数据集

实验一使用机载可见红外成像光谱仪(AVIRIS)采集的美国 Indian Pines 实验区的高光谱遥感图像. 该图像包含 220 个波段, 空间分辨率 20m, 大小为 145×145 . 去除 20 个水汽吸收和低信噪比波段, 剩余 200 个波段. 该地区共含 16 种地物, 随机选择标定样本的 6.7% 作为训练样本(如图 3(c)), 剩下的 93.3% 作为测试样本. 对于样本较少的类, 选择该类样本总数的一半作为训练样本. 表 1 列出了地物及其训练测试样本数, 分布图如图 3(a).

表 1 给出了几种高光谱图像分类算法以及本文算法在 Indian Pines 上的实验结果. 从表 1 中可以看出, 本文方法在子空间逻辑回归与稀疏解混的融合上(MLRsub-SU)并未使分类精度提升很大, 然而增加了 MRF 空间先验以后的分类结果却得到了很大的提升, 并获得了较好的结果. 这说明在高光谱图像中大部分的像元都是由少数几种类型的像元混合而成的, 这与高光谱图像的成像特性以及地物分布相吻合. KSOMP、SVM-CK、MLRsub、MLRsub-MRF 方法以及 SU 和 SU-MRF 的结果都没有本文方法好, 说明通过 MLRsub 挖掘特征空间的信息与 SU 方法挖掘原始空间的信息相结合可以找到两种方法的平衡点, 发挥各自的优点, 且这一优点在 MRF 空间先验下得到了进一步放大, 从而提升最终的

分类精度. 由于 IndianPines 数据集空间分辨率较低, 边缘信息并未使得分类结果有明显提升. SMLR-SpTV 添加了训练样本固定这一约束, 在平均采样方式下, 本文方法比 SMLR-SpTV 的分类精度稍低, 但时间复杂度要优

于 SMLR-SpTV.

图 3 给出了各算法结果的图形显示, 从视觉上可以看出空间信息对分类结果的精度提升明显, 本文的算法结果仅次于 SMLR-SpTV 方法.

表 1 Indian Pines 数据的分类结果 (%)

每类随机采取 50 个训练样本, $\lambda = 0.6$

训练样本	测试样本	精度 (%)	KSOMP	SMLR-SpTV	SVM-CK	MLRsub	MLRsub-MRF	SU	SU-MRF	MLRsub-SU	MLRsub-SU-MRF	MLRsub-SU-MRF-E
697	9669	OA	88.33	92.16	88.98	67.55	87.98	72.40	76.67	72.87	90.79	90.82
		AA	89.76	96.27	93.66	76.70	93.57	81.70	85.92	82.15	94.33	92.26
		Kappa	0.867	0.911	0.889	0.634	0.864	0.688	0.736	0.693	0.895	0.895
		时间 (s)	100.8	106.3	2.87	5.05	5.41	7.60	7.93	13.04	13.37	13.94

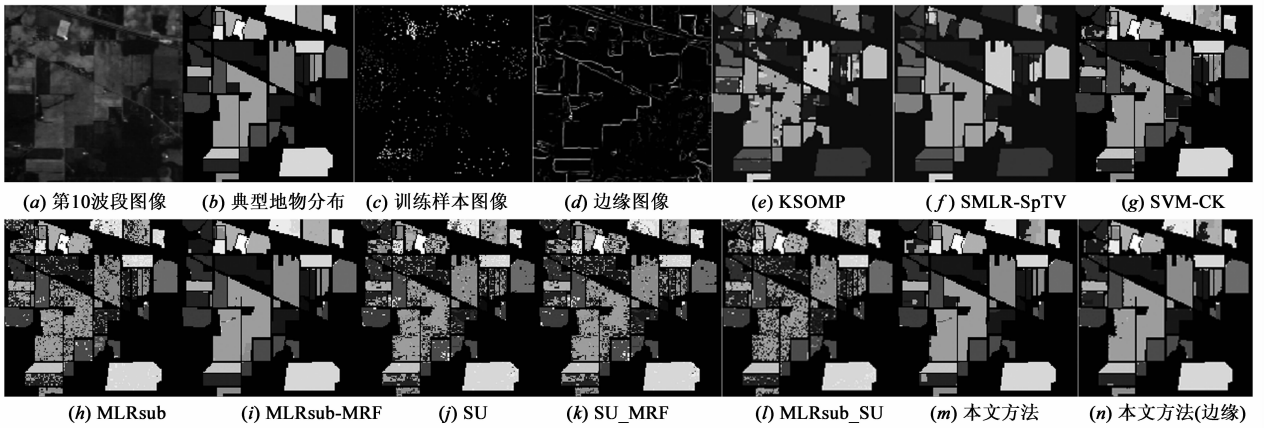


图 3 IndianPines 数据集分类结果





图 4 University of Pavia 数据集分类结果

图 5(a)和(b)分别给出了 IndianPines 数据集上算法的分类精度和时间复杂度与最可信类别个数之间的关系图.从图中可以看出,最可信类别位于 2~10 之间的分类精度差别不大,但是随着最可信类别个数的增加,算法时间复杂度成指数级上升.

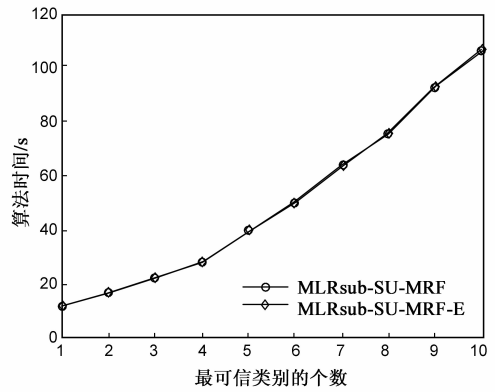
为了体现线性融合的参数 λ 对分类结果的影响,在给定训练样本的情况下,给出了 IndianPines 上分类精度和参数 λ 之间的函数关系,如图 6(a).从图中可以看出

在 λ 取值为[0.3~0.8]的区间分类结果都比各自单一方法的分类精度高.

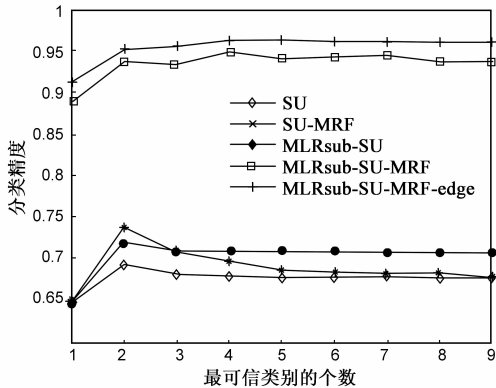
图 7(a)给出了 IndianPines 上本文相关算法的分类精度与训练样本个数的函数关系图.从图中可以看出,随着训练样本的增多,分类精度越来越高,本文方法在样本数为 100~700 之间时,分类精度都是最高的,即使样本总数仅为 100 时,分类精度也达到了 75% 以上.



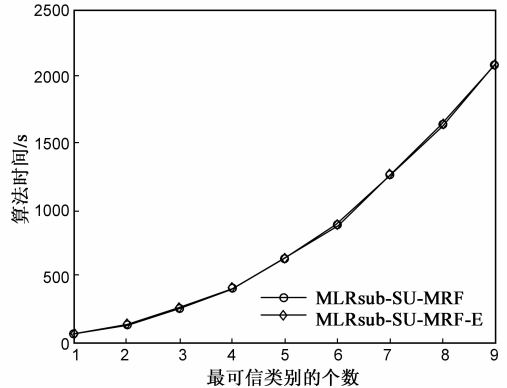
(a) IndianPines 上分类精度与最可信类别个数之间关系



(b) IndianPines 上算法运行时间与最可信类别个数之间关系




(c) Pavia 数据集上分类精度与最可信类别个数之间关系




(d) Pavia 数据集上算法运行时间与最可信类别个数之间关系

图 5 分类精度以及算法时间与最可靠类别个数之间的函数关系图



(a) Indian Pines 数据集



(b) University of Pavia 数据集

图 6 分类精度与融合参数 λ 之间的函数关系图

5.2 University of Pavia 数据集

实验二使用机载反射光学系统成像光谱仪 (RO-SIS) 采集的 University of Pavia 的高光谱遥感图像. 该图像包含 115 个波段, 空间分辨率 1.3m, 大小为 610×340 . 去除 12 个水汽吸收和低信噪比波段后, 剩下余 103 个波段. 该地区共含 9 种地物, 随机从各类样本中选择 100 个训练样本, 其余作为测试样本. 该数据集的训练样本和测试样本是分开两部分, 且训练样本是比较集中采集的块状分布如图 4(c), 这和 IndianPines 数据从整个数据图像中直接随机抽取训练样本是不同的. 表 2 中列出了训练和测试样本数, 分布图如图 4(a).

表 2 给出了以上分类算法在 University of Pavia 上的实验结果. 从表 2 可以看出, 对于 Pavia


数据集的实验结果再次证明了本文算法的分类精度是有效的, 从平均意义上比 MLRsub-MRF 高 2.5%. 边缘信息的融入使得高空间分辨率 (Pavia 的空间分辨率为 1.3m) 高光谱图像的分类结果得到明显改善 (高 5% 左右). 对 Pavia 数据而言, 由于其训练样本属于固定块

采样, 这种方式更符合实际情况, 本文方法要优于所有其他方法.


图 4 给出各算法结果的图形显示, 从视觉上可以看出空间信息对分类结果的精度提升明显, 本文算法在所有的包含空间信息的分类算法中视觉效果也是最好的. 图 5(c) 和 (d) 分别给出了 Pavia 数据集上各算法分类精度和时间复杂度与最可信类别个数之间的函数关系图. 从图中可以看出: 对于高光谱图像来说, 最可信类别数位于 [2, 9] 区间上的分类精度差别不大, 但是时间复杂度几乎成指数级上升, 因此本文只选择 2 类最可信类别. 图 6(b) 给出了 Pavia 数据集上分类精度和参数 λ 之间的函数关系, 在 [0.2, 0.8] 这一区间内分类结果都比各自单一方法的分类精度高. 图 7(b) 给出了各算法的分类精度与训练样本个数的函数关系图, 从图上可以看出, 本文算法在样本数 [200 ~ 900] 范围内都取得了最好的分类精度, 边缘信息的融入对高光谱图像的分类精度具有显著提升.

表 2 University of Pavia 数据的分类结果 (%)

		每类随机采取 100 个训练样本, $\lambda = 0.6$										
训练样本	测试样本	精度 (%)	KSOMP	SMLR-SpTV	SVM-CK	MLRsub	MLRsub-MRF	SU	SU-MRF	MLRsub-SU	MLRsub-SU-MRF	MLRsub-SU-MRF-E
900	42776	OA	74.12	80.99	87.25	64.65	90.37	68.48	72.83	69.80	92.00	95.09
		AA	76.37	92.34	91.62	74.33	89.97	77.66	81.68	78.33	92.85	93.38
		Kappa	0.647	0.729	0.837	0.560	0.874	0.605	0.659	0.620	0.896	0.935
		时间 (s)	501.5	342.5	14.82	7.29	11.21	77.42	80.13	88.32	91.72	92.53



(a) IndianPines数据集



(b) University of Pavia数据集

图 7 分类精度与训练样本个数之间的函数关系图

6 结论

本文提出了一种多分类器融合的高光谱空谱联合分类方法, 该方法不仅融合了局部类别与整体类别分类的特点, 也融合了特征空间和原始空间的光谱信息同时保持图像的边缘信息, 实验结果表明多分类器融合的空谱联合方法有效地提高了高光谱图像的分类精度.

参考文献

- [1] 童庆禧, 张兵, 郑兰芬. 高光谱遥感-原理、技术与应用 [M]. 北京: 高等教育出版社, 2006.
Tong Qingxi, Zhang Bing, Zheng Lanfen. Hyperspectral Remote Sensing [M]. Beijing: Higher Education Press, 2006. (in Chinese)

- [2] 吴泽彬, 韦志辉, 孙乐, 刘建军. 基于迭代加权 L1 正则化的高光谱混合像元分解[J]. 南京理工大学学报, 2011, 35(4): 431 – 435.
Wu Zebin, Wei Zhihui, Sun Le, Liu Jian-jun. Hyperspectral unmixing based on iterative weighted L1 regularization[J]. Journal of Nanjing University of Science and Technology, 2011, 35(4): 431 – 435. (in Chinese)
- [3] 宋相法, 焦李成. 基于稀疏表示及光谱信息的高光谱遥感图像分类[J]. 电子与信息学报, 2012, 34(2): 268 – 272.
Song Xiangfa, Jiao Licheng. Classification of hyperspectral remote sensing image based on sparse representation and spectral information[J]. Journal of Electronics and Information Technology, 2012, 34(2): 268 – 272. (in Chinese)
- [4] 刘建军, 吴泽彬, 韦志辉, 肖亮, 孙乐. 基于约束非负矩阵分解的高光谱图像解混快速算法[J]. 电子学报, 2013, 41(3): 432 – 437.
Liu Jianjun, Wu Zebin, Wei Zhihui, Xiao Liang, Sun Le. A fast algorithm for hyperspectral unmixing based on constrained non-negative matrix factorization[J]. Acta Electronica Sinica, 2013, 41(3): 432 – 437. (in Chinese)
- [5] Melgani F, Bruzzone L. Classification of hyperspectral remote sensing images with support vector machines[J]. IEEE Trans Geosci Remote Sensing, 2011, 42(8): 1778 – 1790.
- [6] Fauvel M, Benediktsson J, et al. Spectral and spatial classification of hyperspectral data using SVMs and morphological profiles[J]. IEEE Trans Geosci Remote Sensing, 2008, 46(11): 3804 – 3814.
- [7] Li Jun, Bioucas-Dias J, Plaza A. Spectral-spatial classification of hyperspectral data using loopy belief propagation and active learning[J]. IEEE Trans Geosci Remote Sensing, 2013, 51(2): 844 – 856.
- [8] Li Jun, Bioucas-Dias J, Plaza A. Semi-supervised hyperspectral image segmentation using multinomial logistic regression with active learning[J]. IEEE Trans Geosci Remote Sensing, 2010, 48(11): 4085 – 4098.
- [9] Li Jun, Bioucas-Dias J, Plaza A. Spectral-spatial hyperspectral image segmentation using subspace multinomial logistic regression and Markov random fields[J]. IEEE Trans Geosci Remote Sensing, 2012, 50(3): 809 – 823.
- [10] Yi Chen, Nasrabadi N M, Tran D. Hyperspectral image classification using dictionary-based sparse representation[J]. IEEE Trans Geosci Remote Sensing, 2011, 49(10): 3973 – 3985.
- [11] Plaza A, Benediktsson A, et al. Recent advances in techniques for hyperspectral image processing[J]. Remote Sensing of Environment, 2009, 113: S110 – S122.
- [12] Camps-Valls G, Gomez-Chova L, et al. Composite kernels for hyperspectral image classification[J]. IEEE Trans Geosci Remote Sensing Lett, 2006, 3(1): 93 – 97.
- [13] Tarabalka Y, Benediktsson J A, Chanussot J. Spectral-spatial classification of hyperspectral imagery based on partitioned clustering techniques[J]. IEEE Trans Geosci Remote Sensing, 2009, 47(8): 2973 – 2987.
- [14] Mauro D M, Alberto V, et al. Classification of hyperspectral images by using extended morphological attribute profiles and independent component analysis[J]. IEEE Trans Geosci Remote Sensing Lett, 2011, 8(3): 542 – 546.
- [15] Sun Le, Wu Zebin, et al. A novel supervised method for hyperspectral image classification with spectral-spatial constraints[J]. Chinese Journal of Electronics, 2014, 23(1): 135 – 141.
- [16] Le Sun, Zebin Wu, et al. Supervised spectral-spatial hyperspectral image classification with weighted Markov random fields[J]. IEEE Trans Geosci Remote Sensing, 2015, 53(3): 1490 – 1503.
- [17] Tarabalka Y, Benediktsson J, et al. Multiple spectral-spatial classification approach for hyperspectral data[J]. IEEE Trans Geosci Remote Sensing, 2010, 48(11): 4122 – 4132.
- [18] XiaJunshi, Du Peijun, He Xiyun. MRF-based multiple classifier system for hyperspectral remote sensing image classification[J]. Multiple Classifier Systems, 2013, 7872: 343 – 351.
- [19] Bigdeli B, Samadzadegan F, Reinartz P. A multiple SVM system for classification of Hyperspectral remote sensing data[J]. Journal of the Indian Society of Remote Sensing, 2013, 41(4): 763 – 776.
- [20] Khodadadzadeh M, Li Jun, et al. Spectral-spatial classification of hyperspectral data using local and global probabilities for mixed pixel characterization[J]. IEEE Trans Geosci Remote Sensing, 2014, 52(10): 6298 – 6314.
- [21] Boykov Y, Kolmogorov V. An experimental comparison of min-cut/max-flow algorithms for energy minimization in vision[J]. IEEE Trans on PAMI, 2004, 26(9): 1124 – 1137.

作者简介



孙 乐 男, 1987 年生于江苏宿迁. 博士, 南京信息工程大学讲师. 研究方向为高光谱遥感图像解混、分类和目标识别.

E-mail: sunlecncom@163.com



吴泽彬 男, 1977 年生于浙江杭州. 南京理工大学计算机科学与工程学院副教授. 研究方向为数据挖掘、虚拟仿真、高光谱图像处理.

E-mail: zebin.wu@gmail.com