

基于相关向量机的高光谱影像混合像元分解

杨国鹏^{1,2}, 周 欣³, 余旭初¹, 陈 伟¹

(1. 信息工程大学测绘学院, 河南郑州 450052; 2. 空军装备研究院情报所, 北京 100085;
3. 信息工程大学信息工程学院, 河南郑州 450002)

摘 要: 提出了一种利用相关向量机后验概率进行高光谱影像混合像元分解的方法. 基于支持向量机后验概率输出的高光谱影像混合像元分解方法中, 类别后验概率需要通过带参数的 S 形函数近似, 而且模型需要通过交叉验证获取较好的正则化系数. 相关向量机是在贝叶斯框架下提出的更加稀疏的学习机器, 它没有正则化系数, 核函数不需要满足 Mercer 条件. 本文从分析支持向量机用于高光谱影像混合像元分解存在的不足出发, 介绍了稀疏贝叶斯分类模型和模型参数推断, 采用了快速序列稀疏贝叶斯学习算法. 通过 PHI 影像的混合像元分解实验分析, 表明了基于相关向量机的高光谱影像混合像元分解方法的优势.

关键词: 高光谱影像; 混合像元分解; 稀疏贝叶斯模型; 相关向量机

中图分类号: TP753 **文献标识码:** A **文章编号:** 0372-2112 (2010) 12-2751-06

Relevance Vector Machine for Hyperspectral Imagery Unmixing

YANG Guo-peng^{1,2}, ZHOU Xin³, YU Xu-chu¹, CHEN Wei¹

(1. Institute of Surveying and Mapping, Information Engineering University, Zhengzhou, Henan 450052, China;
2. Intelligence Institute of Airforce's Equipment Academy, Beijing 100085, China;
3. Institute of Information Engineering, Information Engineering University, Zhengzhou Henan 450002, China)

Abstract: We brought forward a hyperspectral imagery unmixing methods based on the posterior probability of relevance vector machine. In the hyperspectral imagery unmixing methods based on the posterior probability of support vector machine, the posterior probability have to be got by sigmoid function approximately, and the model need to set regularization coefficient by cross-validation. Relevance vector machine is a sparse model in the Bayesian framework, its mathematics model doesn't have regularization coefficient and its kernel functions don't need to satisfy Mercer's condition. In this paper, we firstly analyzed the disadvantages of the support vector machine for hyperspectral imagery unmixing, introduced the sparse Bayesian model and the model parameters inference, and selected the fast sequential sparse Bayesian learning algorithm. Through the unmixing experiments of PHI imagery, the advantages of the relevance machine for hyperspectral imagery unmixing were given out.

Key words: hyperspectral imagery; mixed-pixel unmixing; sparse Bayesian model; relevance vector machine

1 引言

高光谱影像具有丰富的地物光谱信息, 与全色、多光谱影像相比, 它记录的电磁波长范围更宽、光谱分辨率更高, 不仅可以根据需要选择特定的波段来突出地物, 还能够提取地物的辐射特性参量, 使遥感定量分析成为可能. 高光谱遥感逐步成为资源调查、环境监测、精细农业、灾害评估、地图制图等领域的重要技术手段. 在军事上, 对目标侦察、战场环境监测、伪装与反伪装、毁伤效果评估等应用领域具有重要意义^[1].

高光谱影像的空间分辨率较低, 其像元的光谱特征通常不是单一地物的光谱特征, 而是几种地物光谱特征

的混合反映. 混合像元的存在, 是像元级影像分类和面积量测精度难以达到使用要求的主要原因^[2], 由于多光谱影像的波段数量有限, 无法实现准确的光谱解混. 高光谱影像的光谱分辨率从微米级提高到纳米级, 使混合像元分析、分解及其模型研究成为可能. 通过高光谱影像混合像元分解, 可以提高影像中提取小目标的能力、地物精细分类精度和影像处理的自动化、智能化水平.

针对高光谱影像的混合像元分解问题, 国内外开展了大量研究, 一般先分析光谱混合模型, 通过模型解算求出每个像元的组分. 现有的光谱混合模型通常包括线性模型、非线性模型和随机混合模型, 具体的光谱解混方法包括最小二乘法、正交子空间投影法、凸面几何学

分析、约束能量最小法和极大似然法等^[3].非线性光谱混合模型的建模与求解逐渐成为国内外研究的重点.

Foody^[4]指出,后验概率是一个很重要的指标量,通过它能够有效地提取亚像元的信息.Kolaczyk^[5]详细分析了用 Bayes 的后验概率值替代混合像元组分的原因,并认为混合像元分解是基于后验概率分类的一种特殊情况.吴波等^[6]提出了一种利用 SVM 后验概率进行高光谱影像的混合像元分解的方法,李惠等^[7]又验证了改进 SVM 两两配对求解多类问题后验概率方法的有效性.二值 SVM 分类器预测值 f 转化为后验概率,需要采用带有参数的 S 形函数近似^[8],如式(1)所示.

$$p(y = 1|f) = \frac{1}{1 + \exp(Af + B)} \quad (1)$$

SVM 基于统计学习理论的结构风险最小化原则^[9],利用 SVM 后验概率实现混合像元分解,能够表达影像中非线性特性,而不需要具体的光谱混合模型^[6].SVM 也存在着不足^[10],主要表现在:①预测模型本身不具有统计意义,类别后验概率只能通过 S 形函数近似;②基函数个数基本上随训练样本集规模成线性增长,模型稀疏性有限;③核函数参数和规则化系数需要通过交叉验证等方法确定,增加了模型训练的计算量.④核函数必须满足 Mercer 条件.

2000 年, Tipping 提出了一种与 SVM 相似的稀疏概率模型来弥补 SVM 的不足,称为相关向量机 (Relevance Vector Machines, RVM)^[11].2003 年, Tipping 设计了快速序列稀疏贝叶斯学习算法,提高了模型训练速度^[12];2005 年, Thayananthan 将该模型推广,解决了多元输出回归和多类分类的训练问题^[13].RVM 最初用以处理回归问题,通过 Laplace 逼近可以将分类问题转化为回归问题求解.目前,已经初步开展了 RVM 在文本识别^[14]、影像分类^[15]、时序分析^[16]等应用领域的研究.

本文首先分析了稀疏贝叶斯分类模型及模型参数推断过程,将 RVM 学习可以转化为最大化边缘似然函数估计问题,采用快速序列稀疏贝叶斯学习算法求解.通过一系列两两配对的方法实现多类 RVM 分类,将两两配对的类别后验概率转换为多类后验概率,利用后验概率进行高光谱影像的混合像元分解.通过 PHI 影像分类实验表明本文方法的优势.

2 相关向量机混合像元分解

2.1 稀疏贝叶斯模型

对于两类稀疏贝叶斯分类问题^[11],假定训练样本集为 $\{\mathbf{x}_n, t_n\}_{n=1}^N$, $\mathbf{x}_n \in \mathbb{R}^d$ 为训练样本, $t_n \in \{0, 1\}$ 为训练样本标号,分类预测模型将非线性基函数的线性组合通过 S 形函数映射到区间 $(0, 1)$ 内进行类别判定

$$y(\mathbf{x}; \mathbf{w}) = \sigma(\mathbf{w}^T \boldsymbol{\phi}(\mathbf{x})) \quad (2)$$

其中, $\boldsymbol{\phi}(\mathbf{x}) = [\phi(\mathbf{x}_1), \phi(\mathbf{x}_2), \dots, \phi(\mathbf{x}_M)]^T$ 为样本基函数映射组成的列向量, $\phi_i(\mathbf{x}) (i = 1, \dots, N)$ 为定义在训练样本点上的核函数, $\phi_i(\mathbf{x}) = K(\mathbf{x}, \mathbf{x}_i)$. 由于不要求 $\phi_i(\mathbf{x})$ 正定,因此 $\phi_i(\mathbf{x})$ 没有必要满足 Mercer 条件, $\mathbf{w} = (w_0, \dots, w_N)^T$ 为所有基函数的权值组成的列向量,采用的 S 形函数为

$$y = \sigma(z) = 1 / (1 + e^{-z}) \quad (3)$$

对于两类问题,如果假设样本独立同分布的,那么训练样本集的似然函数表示为^[17]

$$p(\mathbf{t} | \mathbf{w}) = \prod_{n=1}^N \sigma\{y(\mathbf{x}_n; \mathbf{w})\}^{t_n} [1 - \sigma\{y(\mathbf{x}_n; \mathbf{w})\}]^{1-t_n} \quad (4)$$

其中, $\mathbf{t} = (t_1, \dots, t_N)^T$ 为训练样本的目标向量.

根据概率统计原理,假设参数 w_i 服从均值为 0 方差为 α_i^{-1} 的高斯条件概率分布,因此

$$p(\mathbf{w} | \boldsymbol{\alpha}) = \prod_{i=0}^N N(w_i | 0, \alpha_i^{-1}) \quad (5)$$

其中, $\boldsymbol{\alpha}$ 是权值 \mathbf{w} 先验分布的超参数.

为每一个权值配置独立的超参数是稀疏贝叶斯模型的最显著的特点,也是导致模型具有稀疏性的根本原因^[10].由于这种先验概率分布是一种自动相关判定先验分布,模型训练结束后,非零权值的基函数所对应的样本向量为相关向量,因此称这种学习机为相关向量机.

根据贝叶斯理论,如果已知模型参数的先验概率分布 $p(\mathbf{w}, \boldsymbol{\alpha})$,那么模型参数的后验概率为

$$p(\mathbf{w}, \boldsymbol{\alpha} | \mathbf{t}) = p(\mathbf{t} | \mathbf{w}, \boldsymbol{\alpha}) p(\mathbf{w}, \boldsymbol{\alpha}) / p(\mathbf{t}) \quad (6)$$

若获取了模型参数的后验分布 $p(\mathbf{w}, \boldsymbol{\alpha} | \mathbf{t})$,那么对于待测样本为 x_* ,稀疏贝叶斯模型的预测值 z_* 的分布为

$$p(z_* | \mathbf{t}) = \int p(z_* | \mathbf{w}, \boldsymbol{\alpha}) p(\mathbf{w}, \boldsymbol{\alpha} | \mathbf{t}) d\mathbf{w} d\boldsymbol{\alpha} \quad (7)$$

因为无法直接积分获取 $p(z_* | \mathbf{t})$,我们通过参数推断获取 \mathbf{w} 后,通过式(3)计算 x_* 的后验概率.

2.2 模型参数推断

由于模型参数的后验分布 $p(\mathbf{w}, \boldsymbol{\alpha} | \mathbf{t})$ 不能通过积分直接获取,故将其分解为

$$p(\mathbf{w}, \boldsymbol{\alpha} | \mathbf{t}) = p(\mathbf{w} | \mathbf{t}, \boldsymbol{\alpha}) p(\boldsymbol{\alpha} | \mathbf{t}) \quad (8)$$

根据贝叶斯公式, $p(\boldsymbol{\alpha} | \mathbf{t}) \propto p(\mathbf{t} | \boldsymbol{\alpha}) p(\boldsymbol{\alpha})$,由于模型参数的后验概率 $p(\mathbf{w} | \mathbf{t}, \boldsymbol{\alpha})$ 和边缘似然函数 $p(\mathbf{t} | \boldsymbol{\alpha})$ 都无法积分求解,采用 MacKay^[18]提出的 Laplace 逼近:首先初始化超参数向量 $\boldsymbol{\alpha}$;对于给定的向量 $\boldsymbol{\alpha}$,建立后验概率分布的高斯近似,获取边缘似然函数的近似分布;通过最大化边缘似然函数来重新估计向量 $\boldsymbol{\alpha}$;重复这个过程直到收敛^[10].

利用高斯分布来逼近后验概率分布的 Laplace 方

法,是对后验概率分布的众数位置处函数的二次逼近.

对于给定的向量 α , 由于

$$p(\mathbf{w}|\mathbf{t}, \alpha) = p(\mathbf{t}|\mathbf{w})p(\mathbf{w}|\alpha)/p(\mathbf{t}|\alpha) \quad (9)$$

那么,关于 \mathbf{w} 后验分布的众数通过最大化下式得到

$$\log\{p(\mathbf{w}|\mathbf{t}, \alpha)\} \\ = \sum_{n=1}^N [t_n \log y_n + (1-t_n) \log(1-y_n)] - \frac{1}{2} \mathbf{w}^T \mathbf{A} \mathbf{w} + \text{const} \quad (10)$$

其中, $y_n = \sigma\{y(\mathbf{x}_n; \mathbf{w})\}$, $\mathbf{A} = \text{diag}(\alpha_i)$.

通过迭代再加权最小二乘法求解, 获取以众数位置为中心的高斯分布, 它的均值 $\mathbf{w}_{\text{MP}} = \mathbf{A}^{-1} \Phi^T(\mathbf{t} - \mathbf{y})$, 方差 $\Sigma = (\Phi^T \mathbf{B} \Phi + \mathbf{A})^{-1}$, 其中 $\mathbf{B} = \text{diag}(\beta_1, \beta_2, \dots, \beta_N)$, $\beta_n = \sigma\{y(\mathbf{x}_n)\} [1 - \sigma\{y(\mathbf{x}_n)\}]$.

同样使用 Laplace 逼近方法可以将边缘似然函数 $p(\mathbf{t}|\alpha)$ 近似表示为

$$p(\mathbf{t}|\alpha) = \int p(\mathbf{t}|\mathbf{w})p(\mathbf{w}|\alpha) d\mathbf{w} \\ \approx p(\mathbf{t}|\mathbf{w}_{\text{MP}})p(\mathbf{w}_{\text{MP}}|\alpha) (2\pi)^{M/2} |\Sigma|^{1/2} \quad (11)$$

如果令 $\hat{\mathbf{t}} = \Phi \mathbf{w}_{\text{MP}} + \mathbf{B}^{-1}(\mathbf{t} - \mathbf{y})$, 则近似高斯后验分布的均值 $\mathbf{w}_{\text{MP}} = \Sigma \Phi^T \hat{\mathbf{t}}$ 、方差 $\Sigma = (\Phi^T \mathbf{B} \Phi + \mathbf{A})^{-1}$. 近似的边缘似然函数对数为

$$L(\alpha) = \log p(\mathbf{t}|\alpha) \\ = -\frac{1}{2} \{N \log(2\pi) + \log |\mathbf{C}| + (\hat{\mathbf{t}})^T \mathbf{C}^{-1} \hat{\mathbf{t}}\} \quad (12)$$

其中, $\mathbf{C} = \mathbf{B} + \Phi \mathbf{A}^{-1} \Phi^T$.

这样利用 Laplace 逼近方法可以将分类问题转化为回归问题^[17], 这时目标向量 $\hat{\mathbf{t}} = \Phi \mathbf{w}_{\text{MP}} + \mathbf{B}^{-1}(\mathbf{t} - \mathbf{y})$, 其中 $\mathbf{B} = \text{diag}(\beta_1, \beta_2, \dots, \beta_N)$, 误差 ϵ_n 的方差倒数 β_n 为

$$\beta_n = \sigma\{y(\mathbf{x}_n)\} [1 - \sigma\{y(\mathbf{x}_n)\}] \quad (13)$$

稀疏贝叶斯分类模型学习最终都归结为第 II 类型最大似然参数估计. 通过最大化边缘似然函数 $p(\mathbf{t}|\alpha)$ 估计 α 有三种方法^[17]: MacKay 迭代估计、期望最大化迭代估计、自下而上的基函数选择算法.

自下而上的基函数选择是 Tipping 于 2003 年提出的快速序列稀疏贝叶斯学习算法^[12], 该方法实现过程中, 基函数个数从 1 开始不断增加直至获取相关向量, 而且 Φ 与 Σ 只包含当前模型中存在的基函数. 本文 RVM 训练过程中采用此种快速方法.

2.3 多类分类器构造

高光谱影像分类属于多类问题, 假设存在 K 类 ($K > 2$), 随机样本服从独立同分布的多项式分布, 此时最大似然函数可以表示为^[14]:

$$p(\mathbf{t}|\mathbf{w}) = \prod_{n=1}^N \prod_{k=1}^K \sigma\{y_k(\mathbf{x}_n; \mathbf{w}_k)\}^{t_{nk}} \quad (14)$$

采用 K 编码方法, 分类器共有 K 个输出 $y_k(\mathbf{x}_n; \mathbf{w})$, 每个输出都有各自的参数向量 \mathbf{w}_k 和超参数 α_k .

由于这种多类问题整体求解时, 计算量非常大. 与 SVM 多类分类相似, 可以将多类分类问题分解成一系列二类问题进行求解, 如一对余法 (One Against Rest, OAR)、一对一法 (One Against One, OAO)、决策树^[19]、纠错码^[20]等方法.

2.4 混合像元分解

针对 OAO 法多类构造方法, 它是通过两两配对组合解决多类问题. 本文采用 Wu 等^[21]提出的方法将两两配对后验概率确定类别概率.

对于 k 类问题, OAO 法需要计算 $k(k-1)/2$ 个分类器 C_{ij} , $i < j$ 用于区分类 w_i 与 w_j . 给定样本 \mathbf{x} , 分类器 C_{ij} 输出概率 $r_{ij} = \text{Prob}(x \in w_j | x, x \in \{w_i, w_j\})$, 这里 $r_{ij} = 1 - r_{ji}$, 所有成对概率构成多类后验概率集合 $p_i = \text{Prob}(x \in w_i | x)$. 样本属于各类别的后验概率组成向量 $\mathbf{p} = [p_1, p_2, \dots, p_k]^T$, 需要求解最优化问题

$$\min_p \sum_{i=1}^k \sum_{j:j \neq i} (r_{ji} p_i - r_{ij} p_j)^2 \\ \text{s.t.} \quad \sum_{i=1}^k p_i = 1, p_i \geq 0, \forall i \quad (15)$$

优化问题(15)可以表示为

$$\min_p 2\mathbf{p}^T \mathbf{Q} \mathbf{p} \equiv \min \frac{1}{2} \mathbf{p}^T \mathbf{Q} \mathbf{p} \quad (16)$$

其中, $Q_{ij} = \begin{cases} \sum_{s:s \neq i} r_{si}^2, & \text{if } i = j \\ -r_{ji} r_{ij}, & \text{if } i \neq j \end{cases}$. 这样优化问题(16)可以转化为关于 \mathbf{p} 的线性表达式

$$\begin{bmatrix} \mathbf{Q} & \mathbf{e} \\ \mathbf{e}^T & 0 \end{bmatrix} \begin{bmatrix} \mathbf{p} \\ b \end{bmatrix} = \begin{bmatrix} \mathbf{0} \\ 1 \end{bmatrix} \quad (17)$$

3 高光谱影像混合像元分解实验

全约束最小二乘法^[3] (Full Constrained Least Squares Unmixing, FCLS) 是求解线性混合模型的经典方法. 基于 SVM 后验概率的光谱解混方法是最近学者们研究的热点, 获得了较好的光谱解混结果. 我们将 RVM 后验概率混合像元分解方法与 FCLS 解混和 SVM 后验概率法的比较分析.

实验采用的计算机硬件环境为 Intel Core2 CPU 3.0GHz、2.99GHz 内存 3.25GB, 软件环境为 Microsoft Windows XP、MATLAB 7.5.

3.1 实验数据

1999 年 9 月, 由中科院上海技术物理研究所研制的 PHI 获取的江苏省




图1 PHI影像样本分布

常州市乡村影像,它的光谱覆盖范围为 $0.42 \sim 0.85 \mu\text{m}$,共 80 波段,图像大小为 346×512 ,数据经过反射率转换.样本分布如图 1 所示,样本信息如表 1 所示.

表 1 PHI 数据样本信息

类别	1	2	3	4	5	6
名称	房屋	水体	土壤	树木	农作物	道路
数量	211	222	205	228	266	238

将各类样本按数量随机等分成两部分作为训练样本和测试样本.用训练样本完成 RVM 与 SVM 的训练,用测试样本来检测分类的精度.

3.2 实验内容

由于 SVM 要求核函数满足 Mercer 条件,而且径向基核函数的分类识别能力不低于高阶多项式核函数和 S 形核函数.为便于比较,RVM 与 SVM 都采用径向基核函数,其表达式为

$$k(\mathbf{x}, \mathbf{x}') = \exp(-\eta \|\mathbf{x} - \mathbf{x}'\|^2) \quad (18)$$

其中, η 为核函数参数.为了便于选取合适的 η ,将高光影像的每个波段特征 DN 值规范化到 $[0, 1]$ 范围内.

SVM 模型含有规则化系数 C ,在分类时需要设置,在实验中通过交叉验证网格搜索法来获取^[1].SVM 学习过程采用序列最小优化算法,利用统计模式识别工具箱 STPRtool 实现^[22].在本实验中,通过交叉验证获取 SVM 规则化系数 $C = 2$ 、核函数参数 $\eta = 4$.

由于已经将高光影像数据的 DN 值规范化到 $[0, 1]$ 范围内,为了便于与 SVM 比较进行比较,选择 Gauss 核函数参数 $\eta = 4$,该 PHI 影像 RVM 混合像元分解后,影像中各地物的丰度如图 2 所示.

在图 2 中各类别丰度图中,灰度值越亮代表该端元在对应混合像元中的丰度越大,灰度值越暗表示该端元在对应混合像元中丰度越小.

FCLS 是同时满足各组分和为一约束与非负约束的线性混合模型求解方法.该 PHI 影像 FCLS 分解后,各地物组分的如图 3 所示.

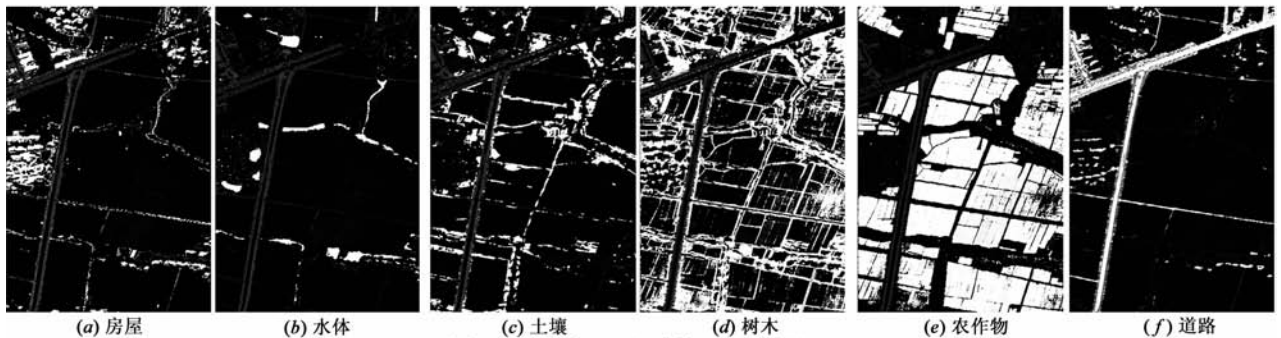


图 2 PHI 影像 RVM 混合像元分解结果

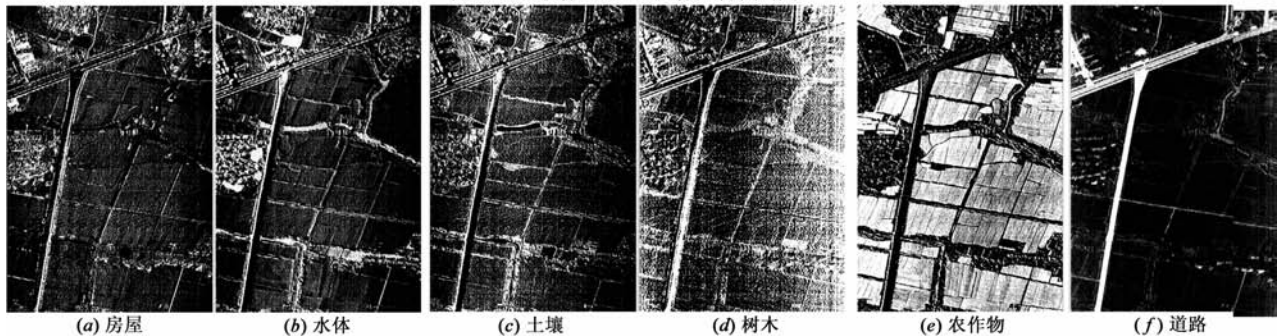


图 3 PHI 影像 FCLS 混合像元分解结果

由于 RVM 与 SVM 都是非线性分类器,能够表达混合像元的非线性特征,我们对这两种基于类别后验概率的混合像元分解方法进行比较,如表 2 所示.

表 2 该 PHI 影像 RVM 与 SVM 光谱分解比较

	RVM	SVM
规则化系数 C	-	2
径向基核参数 η	4	4
模型训练时间(s)	1.05	5.84
模型基函数数量	53	548
像元分解时间(s)	9.23	122.8
分类错误率(%)	1.36	1.36

在表 2 中,基函数数量为多类分类器中所有二值分类器的基函数个数之和.该影像利用 RVM 的混合像元分解的丰度进行分类的结果如图 4 所示.

3.3 实验分析

比较 RVM 与 FCLS 的实验结果可知,图 2 中不同地物的区分特别明显,图 3 中丰度图存在一定的模糊,并存在大量噪声.这是因为 RVM 能够解释混合像元分解中各组分的非线性特性,改善了混合像元分解效果.

通过 RVM 与 SVM 的比较分析,我们还可以得出以下结论:

(1) 由于在 RVM 模型中不存在规则化系数 C , 不需要像 SVM 那样交叉验证获取规则化系数, 因此 RVM 与 SVM 相比受分类器参数选择的影响要小。

(2) 由于在 RVM 模型中需要带参数的 S 形函数将预测值转化为后验概率, 因此 RVM 与 SVM 相比避免了估计 S 形函数参数的过程。

(3) RVM 采用快速序列学习算法时, 训练过程要比采用序列最小优化的 SVM 速度要快, 而且利用 RVM 与 SVM 混合像元分解结果分类精度都相当。

(4) RVM 分类器所用核函数个数仅为 SVM 的 $1/10$, 因此 RVM 模型更加稀疏。因为 RVM 与 SVM 都是通过核函数的线性组合来进行分类预测的, 所以 RVM 预测速度比 SVM 预测快得多。

4 总结

RVM 是按照 SVM 模型的形式, 在贝叶斯框架下提出的具有稀疏概率模型的学习机。在 RVM 求解过程中, 核函数不必要满足 Mercer 条件。在 RVM 模型中, 不需要通过交叉验证获取规则化系数。

通过 PHI 影像混合像元分解实验表明, RVM 具有良好的泛化能力, 能够解释混合像元分解中各分组的非线性特性, 改善了线性混合模型的混合像元分解效果。

在利用 RVM 法进行混合像元分解时, 与 SVM 法相比, RVM 模型中不存在规则化系数 C , 不需要交叉验证获取规则化系数的步骤。RVM 受分类器参数选择的影响较小。

RVM 采用快速序列学习算法时, 训练过程要比序列最小优化的 SVM 速度要快。在 RVM 训练完成后, 只有少数基函数的权值非零, 比 SVM 更加稀疏, 分类预测过程所用时间更短。

参考文献:

[1] 杨国鹏. 基于核方法的高光谱影像分类与特征提取[D]. 郑州: 信息工程大学, 2007.
YANG Guo-peng. Hyperspectral Image Classification and Feature Extraction Based on Kernel Methods[D]. Zhengzhou: Information Engineering University, 2007. (in Chinese)

[2] 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.




图4 利用RVM混合像元分解结果分类图

TONG Qing-xi, ZHANG Bing, ZHENG Lan-fen. Hyperspectral Remote Sensing[M]. Beijing: Higher Education Press, 2006. (in Chinese)

[3] 陈伟. 高光谱影像混合像元分解技术研究[D]. 郑州: 信息工程大学, 2009.
CHEN Wei. Research on Mixed-pixel Unmixing of Hyperspectral Imagery[D]. Zhengzhou: Information Engineering University, 2009. (in Chinese)

[4] Foody G M. Relating the land cover composition of mixed pixels of artificial neural network classification output[J]. Photogrammetry Engineering and Remote Sensing, 1996, 62(5): 491-499.

[5] KOLACZYK E D. On the use of prior and posterior information in the subpixel proportion problem[J]. IEEE Transaction on Geoscience and Remote Sensing, 2003, 41(11): 2687-2691.

[6] 吴波, 张良培, 李平湘. 基于支撑向量机概率输出的高光谱影像混合像元分解[J]. 武汉大学学报: 信息科学版, 2006, 36(1): 51-54.
WU Bo, ZHANG Liang-pei, LI Pingxiang. Unmixing of hyperspectral imagery based on probabilistic outputs of support vector machines[J]. Geomatics and Information Science of Wuhan University, 2006, 36(1): 51-54. (in Chinese)

[7] 李惠, 王云鹏, 李岩, 王兴芳. 基于 SVM 和 PWC 的遥感影像混合像元分解[J]. 测绘学报, 2009, 38(4): 318-323.
LI Hui, WANG Yunpeng, LI Yan, Wang Xingfang. Unmixing of remote sensing imagers based on support vector machines and pairwise coupling[J]. Acta Geodaetica et Cartographica Sinica, 2009, 38(4): 318-323. (in Chinese)

[8] PLATT J C. Probabilistic Outputs for Support Vector Machines and Comparisons to Regularized Likelihood Methods[OL]. <http://research.microsoft.com/~jplatt>, 1999.

[9] SHAWE-TSYLOR J, Cristianini N. Kernel Methods for Pattern Analysis[M]. London: Cambridge University Press, 2004. 47-82.

[10] BISHOP C M. Pattern Recognition and Machine Learning[M]. Germany: Springer, 2007.

[11] BISHOP C M, Tipping M E. Variational relevance vector machines[A]. Proceedings of the 16th Conference on Uncertainty in Artificial Intelligence[C]. San Francisco, CA: Morgan Kaufmann, 2000. 46-53.

[12] TIPPING M E, Faul A. Fast marginal likelihood maximization for sparse Bayesian models[A]. Proceedings of the Ninth International Workshop on Artificial Intelligence and Statistics[C]. Key West, Florida: AI & Statistics, 2003.

[13] THAYANANTHAN A. Template-based Pose Estimation and Tracking of 3D Hand Motion[D]. Cambridge, UK: Department of Engineering, University of Cambridge, 2005.

[14] SILVA C, RIBEIRO B. Scaling text classification with rele-

- vance vector machines[A]. Proceedings of IEEE International Conference on Systems, Man and Cybernetics [C]. Taipei: IEEE Press, 2006. 4186 – 4191.
- [15] DEMIR B, ERTURK S. Hyperspectral image classification using relevance vector machines[J]. IEEE Geoscience and Remote Sensing Letters, 2007, 4(4): 586 – 590.
- [16] NIKOLAEV N, TINO P. Sequential relevance vector machine learning from time series[A]. Proceedings of IEEE International Joint Conference on Neural Networks Vol. 2 [C]. NK USA: IEEE Press, 2005. 1308 – 1313.
- [17] TIPPING M E. Sparse Bayesian learning and the relevance vector machine[J]. Journal of Machine Learning Research, 2001, 1: 21 – 244.
- [18] MACKAY D J C. The evidence framework applied to classification networks[J]. Neural Computation, 1992, 4(5): 720 – 736.
- [19] 连可, 黄建国, 王厚军, 龙兵. 一种基于遗传算法的 SVM 决策树多分类策略研究[J]. 电子学报, 2008, 36(8): 1502 – 1507.
LIAN Ke, HUANG Jian-guo, WANG Hou-jun, LONG Bing. Study on a GA-based SVM decision-tree multi-classification strategy[J]. Acta Electronica Sinica, 2008, 36(8): 1502 – 1507. (in Chinese)
- [20] 尹安容, 谢湘, 匡镜明. Hadamard 纠错码结合支持向量机在多分类问题中的应用[J]. 电子学报, 2008, 36(1): 122 – 126.
YIN An-rong, XIE Xiang, KUANG Jing-ming. Application of Hadamard ECOC in multi-class problems based on SVM[J]. Acta Electronica Sinica, 2008, 36(1): 122 – 126. (in Chinese)
- [21] WU T F, LIN C J, WENG R C. Probability estimates for multi-class classification by pairwise coupling[J]. Journal of Machine Learning Research, 2004, 5: 975 – 1005.
- [22] FRANC V, HLAVAC V. Statistical Pattern Recognition Toolbox for Matlab User's guide [DB/OL]. <http://cmp.felk.cvut.cz/cmp/cmp software.html>. 2004.

作者简介:



杨国鹏 男, 1982 年 9 月出生于山东聊城. 2010 年在信息工程大学测绘学院获摄影测量与遥感专业博士学位, 从事高光谱影像分析、图像处理与模式识别等研究.
E-mail: yangguopeng@hotmail.com



周欣 女, 1983 年 6 月出生于河南三门峡. 2007 年在信息工程大学信息工程学院获工学硕士学位, 现为该校博士生, 从事现代通信中的信号处理研究.