

基于改进型相关向量机的高光谱图像分类

赵春晖 齐 滨 张 燚

(哈尔滨工程大学信息与通信工程学院, 黑龙江 哈尔滨 150001)

摘要 相关向量机(RVM)高光谱图像分类算法是一种基于贝叶斯概率模型的监督机器学习算法,其分类精度较高、测试时间较短。然而算法本身存在训练时间随着训练样本增加直线上升、分类效率整体降低等问题。针对这种情况,提出一种基于改进型相关向量机(VRVM)的高光谱图像分类算法。本算法在传统概率模型中引入一个新的分布,使得计算复杂度较高的积分运算可近似地拆分成两个较为简单的对数和形式。实验结果表明,VRVM高光谱图像分类算法的总体分类精度和相关向量的数量与RVM基本相同,但训练时间随样本数的增加有明显的减少。

关键词 遥感;高光谱图像;相关向量机;分类算法

中图分类号 TP751.1 文献标识码 A doi: 10.3788/AOS201232.0828004

Hyperspectral Image Classification Based on Variational Relevance Vector Machine

Zhao Chunhui Qi Bin Zhang Yi

(College of Information and Communication Engineering, Harbin Engineering University, Harbin, Heilongjiang 150001, China)

Abstract The hyperspectral image classification algorithm of relevance vector machine (RVM) is a supervised machine learning algorithm based on Bayes probability model, whose classification accuracy is good and the test time is short. However, the traditional RVM has some shortcomings that the training time will be very long and the effectiveness of the algorithm might decrease if the size of training samples is big or the dimensionality of the data is high. To solve these problems, a hyperspectral image classification algorithm of variational relevance vector machine (VRVM) is proposed. A new distribution is imported into the traditional probability model, which can replace complicated convolution operation with simple logarithm addition operation. Experimental results show that, in the classification of hyperspectral image, the overall classification accuracy and the number of relevance vectors of VRVM are nearly the same with RVM. However, with the increase of the sample, the training time has obviously reduced.

Key words remote sensing; hyperspectral image; relevance vector machine; classification algorithm

OCIS codes 110.4234; 280.4788; 100.4145; 110.2970

1 引 言

高光谱图像具有丰富的地物光谱信息,与全色、多光谱图像相比,高光谱图像在地物识别方面具有较大的优势,其较高的光谱分辨率极大地增强了地物细微差别分辨能力,使其在医学、农学等方面有广泛的应用^[1,2]。高光谱图像分类算法根据是否需要训练样本,分为非监督分类和监督分类^[3~5]。非监督分类算法中的代表算法主要有:1) K 均值聚类方

法,该方法易实现,但缺点在于初始聚类中心对分类结果影响很大,并且容易陷入局部最优;2) ISODATA 动态聚类方法,该方法使用最小光谱距离方程产生聚类,对现存类别进行合并、分裂等操作,达到最终分类目的;3) 平行管道法,该方法实质上是一种基于最近规则的试探法。非监督分类算法由于没有训练样本,因此对大样本、高维数的高光谱图像分类精度不高。

收稿日期: 2012-03-19; 收到修改稿日期: 2012-04-12

基金项目: 国家自然科学基金(61077079)和高等学校博士学科点专项基金(20102304110013) 资助课题。

作者简介: 赵春晖(1965—),男,博士,教授,主要从事高光谱图像处理方面的研究。E-mail: zhaochunhui@hrbeu.edu.cn

支持向量机(SVM)^[6]是由 Cortes 于 1995 年提出的,建立在统计学理论和结构风险最小原理的基础上,在模型复杂性与学习能力之间寻求最佳折中,是监督分类的典型代表,已经成为模式识别以及机器学习研究领域比较领先的方法之一。但 SVM 高光谱图像分类仍存在着一定的局限性:1)支持向量的数量会随着训练样本数量的增加而线性增加,这样会导致分类效率降低;2)预测结果没有后验概率,无法通过结果观测到分类的准确度;3)计算过程中需要给定的惩罚系数 C ,由于是人为设定其值大小,所以容易造成主观误差;4)核函数必须满足 Mercer 条件^[7,8]。

相关向量机(RVM)^[9]是由 Tipping 于 2001 年提出的一种与 SVM 类似的稀疏概率模型。将 RVM 应用于高光谱图像分类中可以在保证分类精度与 SVM 相同的情况下,提供一个后验概率分布,并且与 SVM 分类相比,相关向量的个数远远小于支持向量的个数,其核函数也不需要满足 Mercer 条件。文献^[10]针对 RVM 算法分类精度低、核参数选择困难等问题,提出临界滑动阈值的概念,并将 RVM 与 K 近邻算法结合构建 KNN-RVM 分类器,实验显示了该分类器的分类准确性。文献^[11]提出使用遗传算法对 RVM 进行自动优化核函数参数,实验结果显示该方法可以高效准确地优化 RVM 核参数,并且对具有较多参数的核函数更具实用性。但是 RVM 高光谱图像分类在解决以上 SVM 问题的同时也引入了新的问题。由于高光谱数据样本大、维数高^[12],使分类过程中的训练时间随着样本复杂度的增加而直线上升,严重影响了分类的效率。为此,本文在深入研究相关向量机算法的基础之上,提出一种改进的相关向量机(VRVM)高光谱图像分类算法。该算法针对高光谱图像数据的特点,引入一个新的概率分布,从而降低训练过程中的运算复杂度,提高高光谱图像分类效率。

2 改进的相关向量机方法

2.1 改进型相关向量机模型

传统的概率模型可以将随机变量分为观测数据 D 和非观测变量 θ ^[13]。观测数据 D 的边缘概率密度为

$$P(D) = \int P(D, \theta) d\theta. \quad (1)$$

对于(1)式的积分计算,通常来说较为复杂。因此改进思想是通过引入近似的分布 $Q(\theta)$,其中对于任意

选择的非观测变量 θ ,可以将边缘概率密度的积分形式分解为两个对数之和,即将(1)式近似的分解为

$$\ln P(D) = L(Q) + f_{\text{KL}}(Q \| P), \quad (2)$$

式中

$$L(Q) = \int Q(\theta) \ln \frac{P(D, \theta)}{Q(\theta)} d\theta. \quad (3)$$

引入的分布 $Q(\theta)$ 是 $P(D, \theta)$ 和后验分布 $f_{\text{KL}}(Q \| P)$ 之间的 Kullback-Leibler 的距离差,可表示为

$$f_{\text{KL}}(Q \| P) = - \int Q(\theta) \ln \frac{P(\theta | D)}{Q(\theta)} d\theta, \quad (4)$$

式中 $f_{\text{KL}}(Q \| P) \geq 0$ 。(2)式的右半部分是 Q 的独立分布,因此最大化 $L(Q)$ 等同于最小化的 $f_{\text{KL}}(Q \| P)$ 。综合(3)、(4)式,则 $Q(\theta)$ 就是 $P(\theta | D)$ 的近似边缘概率分布。通过该近似的方法,只要选择一个合适的 Q 分布, $L(Q)$ 的值即便在传统模型函数未知的情况下也可以通过简单的计算得到。因此改进型 RVM 的方法就是选择一个形式较为简单的 $Q(\theta)$,使得 $L(Q)$ 的计算较为简单,并且同时保证 $L(Q)$ 的形式足够灵活。

根据(1)式且考虑到参数 θ 的变形形式 $\{\theta_i\}$,则 $Q(\theta)$ 可以定义为

$$Q(\theta) = \prod_i Q_i(\theta_i), \quad (5)$$

式中 $Q_i(\theta_i)$ 的值可表示为

$$Q_i(\theta_i) = \frac{\exp\langle \ln P(D, \theta) \rangle_{k \neq i}}{\int \exp\langle \ln P(D, \theta) \rangle_{k \neq i} d\theta_i}, \quad (6)$$

式中 $\langle \cdot \rangle_{k \neq i}$ 定义为对于 $Q_k(\theta_k)$ 分布(其中 $k \neq i$) 的期望。可以证明,如果概率模型中的每个因素 $Q_i(\theta_i)$ 可以用一种带有节点的有向循环图来表示,那么 $Q_i(\theta_i)$ 的解就仅仅取决于 Q 分布的变量形式^[14]。(6)式的右半部分取决于 $Q_{k \neq i}$ 的任意时刻,所以(6)式是 $Q_i(\theta_i)$ 的一种特殊的求解表达式。又因为 $Q_i(\theta_i)$ 是共轭的条件分布,因此可以通过计算得到所需时刻的标准条件分布。然后通过初始化,循环使用(6)式,迭代更新变量,最终得到 Q 的所有分布。

2.2 复杂度分析

控制运算复杂度的通常方法就是引入一种超参数,利用该方法可以避免在超大离散指数模型结构中的运算。此种方法已经成功地应用于基于贝叶斯的主成分分析寻找主成分的最优个数。通常为去除多余的参数,使用拉普拉斯分布,即

$$P(w) = \lambda \exp(-\lambda |w|). \quad (7)$$

然而,利用(7)式很难计算出(6)式的值,因此这样的预处理方法通用性不强。为了更好地计算出(6)式的值,提出一种(7)式的变换替代框架形式,变形表达式为

$$P(w | \alpha) = N(w | 0, \alpha^{-1}), \quad (8)$$

(8)式利用一种超前优先方法可以近似为

$$P(\alpha) = \Gamma(\alpha | a, b) = b^a \alpha^{a-1} \exp(-b\alpha) / \Gamma(a), \quad (9)$$

式中 $\Gamma(a)$ 为伽玛函数,(9)式的分布其优点在于其表达式形式较为简单,可表示为

$$\langle \alpha \rangle = a/b, \langle \alpha^2 \rangle - \langle \alpha \rangle^2 = a/b^2. \quad (10)$$

由此可以得到(8)式中的边缘分布 $w(t)$ 分布是包含在一个 a 的积分中。其中拉普拉斯分布与所介绍的边缘分布有着各自的特点,比较如图 1 所示,其中 $a=b=1$ 。

该方法的优点在于不直接应用拉普拉斯分布




图 1 边缘分布(实线)与拉普拉斯分布(点线)比较
Fig. 1 Comparison of the marginal distribution (solid line) and the Laplace distribution (dotted line)

$P(w)$ 而是利用共轭形式的结合表达式 $Q(w, \alpha) = Q(w)Q(\alpha)$ 来代替,这样可以方便地提取超大离散指数模型结构的框架形式,降低运算复杂度。

2.3 改进型相关向量机分类算法

输入数据边缘概率的对数形式为

$$\ln P(T | X) = \ln \iint P(T | X, w) P(w | \alpha) P(\alpha) dw d\alpha. \quad (11)$$

利用之前处理的结论以及近似的分解变量形式 $Q_w(w)Q_\alpha(\alpha)$, 并且结合(3)式,将(11)式近似为

$$\ln P(T | X) \geq \iint Q_w(w) Q_\alpha(\alpha) \ln \left[\frac{P(T | X, w) P(w | \alpha) P(\alpha)}{Q_w(w) Q_\alpha(\alpha)} \right] dw d\alpha. \quad (12)$$

由于(12)式的积分式计算会增加运算的复杂度,因此根据 Jaakkola 和 Jordan 的分析方法^[15],引入下式

$$\sigma(y)^t [1 - \sigma(y)]^{1-t} = \sigma(z) \geq \sigma(\xi) \exp \left[\frac{z - \xi}{2} - \lambda(\xi)(z^2 - \xi^2) \right], \quad (13)$$

式中 $z = (2t - 1)y$, $\lambda(\xi) = (1/4\xi) \tanh(\xi/2)$ 。 ξ 是一个可变参数,当等号成立时,可以得到 $\xi = z$ (ξ 下面用矢量形式表示)。将(13)式代入相关向量机模型中,可以得到

$$P(T | X, w) \geq F(T, X, w, \xi) = \prod_{n=1}^N \sigma(\xi_n) \exp \left[\frac{z_n - \xi_n}{2} - \lambda(\xi_n)(z_n^2 - \xi_n^2) \right], \quad (14)$$

式中 $z_n = (2t_n - 1)w^T \phi_n$, 并且 $P(T | X, w) / F(T, X, w, \xi) \geq 1$ 就等同于 $\ln P[T | X, w] / F(T, X, w, \xi) \geq 0$ 。

将(14)式代入(12)式中,得

$$\ln P(T | X) \geq L = \iint dw d\alpha Q_w(w) Q_\alpha(\alpha) \ln \left[\frac{F(T, X, w) P(w | \alpha) P(\alpha)}{Q_w(w) Q_\alpha(\alpha)} \right], \quad (15)$$

优化(15)式右边的函数 $Q_w(w)$ 和 $Q_\alpha(\alpha)$ 以及参数 $\xi = \{\xi_n\}$, 优化的结果为 $Q_w(w)$ 产生了一个一般的正态分布形式^[16]:

$$Q_w(w) = N(w | m, S), \quad (16)$$

式中的参量分别为 $S = [A + 2 \sum_{n=1}^N \lambda(\xi_n) \phi_n \phi_n^T]^{-1}$ 和 $m = \frac{1}{2} S [\sum_{n=1}^N (2t_n - 1) \phi_n]$, 且 $A = \text{diag}(\alpha)$ 。

相对而言,优化产生的结果使得 $Q_\alpha(\alpha)$ 是服从伽玛分布的

$$Q_\alpha(\alpha) = \prod_{m=0}^N \Gamma(\alpha_m | \bar{a}, \bar{b}_m), \quad (17)$$

$$\bar{a} = a + \frac{1}{2}, \quad \bar{b}_m = b + \frac{1}{2} \langle w_m^2 \rangle. \quad (18)$$

最后,对于变形参数 ξ_n 进行最小化,该参数的值是通过下式计算而得

$$\xi_n^2 = \phi_n^T \langle \mathbf{w} \mathbf{w}^T \rangle \phi_n. \quad (19)$$

同样,通过(15)式的右半部分,对 L 的值可以通过下式计算而得

$$L = \langle \ln F \rangle + \langle \ln P(\mathbf{w} | \boldsymbol{\alpha}) \rangle + \langle \ln P(\boldsymbol{\alpha}) \rangle - \langle \ln Q_w(\mathbf{w}) \rangle - \langle \ln Q_\alpha(\boldsymbol{\alpha}) \rangle, \quad (20)$$

式中

$$\left\{ \begin{aligned} \langle \ln F \rangle &= \sum_{n=1}^N \left[\ln \sigma(\xi_n) + \frac{1}{2}(2t_n - 1) \langle \mathbf{w}^T \rangle \phi_n - \frac{1}{2} \xi_n - \lambda(\xi_n) (\phi_n^T \langle \mathbf{w} \mathbf{w}^T \rangle \phi_n - \xi_n^2) \right] \\ \langle \ln P(\mathbf{w} | \boldsymbol{\alpha}) \rangle &= -\frac{1}{2} \sum_{m=0}^N \langle \alpha_m \rangle \langle \omega_m^2 \rangle + \frac{1}{2} \sum_{m=0}^N \langle \ln \alpha_m \rangle - \frac{(N+1)}{2} \ln(2\pi) \\ \langle \ln P(\boldsymbol{\alpha}) \rangle &= \sum_{m=0}^N \{ -b\bar{a}/\bar{b} + (a-1) [\psi(\bar{a}) - \ln \bar{b}] + a \ln b - \ln \Gamma(a) \} \\ - \langle \ln Q_w(\mathbf{w}) \rangle &= \frac{N+1}{2} (1 + \ln 2\pi) + \frac{1}{2} \ln |\mathbf{S}| \\ - \langle \ln Q_\alpha(\boldsymbol{\alpha}) \rangle &= \sum_{m=0}^N [-(\bar{a}_m - 1) \psi(\bar{a}_m) - \ln \bar{b}_m + \bar{a}_m + \ln \Gamma(\bar{a}_m)] \end{aligned} \right. \quad (21)$$

对于新输入的预测,可以通过现有的、训练好的权重模型计算而得 $P(T | X, \langle \mathbf{w} \rangle)$, 从而可对数据进行分类。

3 仿真实验

3.1 模拟分类实验

实验应用 Ripley 的模拟分类数据^[17]。随机选择 100 个数据样本用来训练 SVM、RVM 以及 VRVM。为了准确评价 3 种分类方法的分类精度,其核函数均采用高斯核函数,其中宽度参数设定为 5 层交叉验证的结果,为了保证实验结果的准确性,将 SVM 的惩罚系数 C 设定为 5 层交叉验证的近似估计值。表 1 给出了 3 种分类算法的总体分类精度以及 3 种方法的支持向量(SVs)或相关向量(RVs)的个数。可以看到,RVM 与 VRVM 有着极为近似的总体分类精度,相对而言,VRVM 的总体分类精度比 SVM 提高了 1%,但 RVM 和 VRVM 相关向量的数量较 SVM 相比减少了 90%。

表 1 模拟分类结果

Table 1 Simulative classification

Algorithm	Overall classification	Number of SVs or RVs
	accuracy / %	
SVM	89.4	38
RVM	90.7	4
VRVM	90.8	4

3.2 高光谱图像分类实验

3.2.1 分类精度

实验采用美国航空可见光/红外成像光谱仪所测高光谱数据 92AV3C。图像共 200 个波段,图像

大小为 144 pixel × 144 pixel。实验选取 5 类地物: corn-no till, corn-min, soybean-no till, soybean-min 和 woods, 分别有 1434、834、968、2468、1294 个样本点^[18], 如图 2 所示。实验环境: Matlab R2010b、WIN XP、CPU Pentium (R) 3.00 GHz/768 MB RAM。




图 2 高光谱图像数据。(a)实验数据的假彩合成图;
(b)实验数据真实标记图

Fig. 2 Hyperspectral image data. (a) False-color image of the experimental data; (b) real labeled map of the experimental data

高光谱图像在不同波段区间有着不同区分度,如图 3 所示,实验数据在 10~40、45~55、60~70 和 110~140 这些波段之间有着较好的区分度,因此实验选取样本在区分度较高的波段对 3 种分类机进行测算。实验采用总体分类精度(OA)和 Kappa 系数作为评价标准。

实验首先在分辨率较好的波段范围内随机选取 4 个波段,之后在此数据内随机选取 0.5%、2%、5% 的数据作为训练样本,为了准确评价 3 种分类方法的分类精度,其核函数均采用高斯核函数,其中宽度参数设定为 5 层交叉验证的结果,为了保证实验结

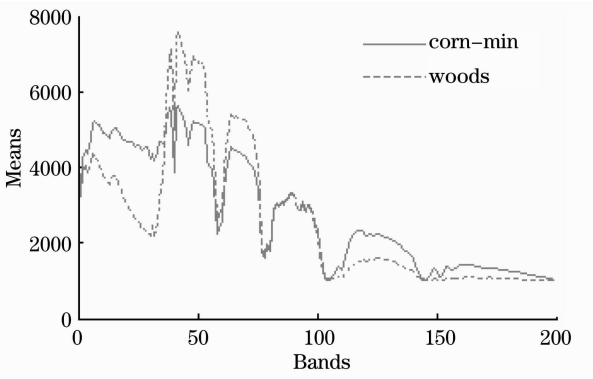


图 3 不同波段间区分度

Fig. 3 Distinguishability of different bands

果的准确性将 SVM 的惩罚系数 C 设定为 5 层交叉验证的近似估计值^[19],之后分别对 SVM、RVM、VRVM 进行训练,将其应用于高光谱图像分类,由于随机选取训练样本对结果产生影响,因此采取 5 次实验结果并求其平均统计精度,之后选取与训练样本不同波段的数据作为测试样本,保证训练样本与测试样本彼此隔离,进行实验,实验结果均为测试样本分类结果。结果表明,VRVM 的总体分类精度与 SVM、RVM 基本相同。在总体分类精度上由于选择的样本数量较小,VRVM 的分类精度较另外两种方法有所提高,如表 2~4 所示。

表 2 各类别测试样本分类精度
(取 0.5% 的数据作为训练样本)

Table 2 Classification accuracy (selecting 0.5% data as training samples)

Training sample	SVM / %	RVM / %	VRVM / %
Corn-no till	74.34	73.33	75.21
Corn-min	71.64	70.90	72.36
Soybean-no till	79.33	77.59	80.59
Soybean-min	54.34	52.48	55.97
Woods	87.22	85.64	89.59
OA	70.03	68.55	71.49

表 3 各类别测试样本分类精度
(取 2% 的数据作为训练样本)

Table 3 Classification accuracy (selecting 2% data as training samples)

Training sample	SVM / %	RVM / %	VRVM / %
Corn-no till	77.61	77.40	77.68
Corn-min	75.54	76.30	77.70
Soybean-no till	83.67	83.57	83.78
Soybean-min	58.75	57.94	60.37
Woods	91.19	91.11	92.35
OA	74.06	73.79	75.14

表 4 各类别测试样本分类精度

(取 5% 的数据作为训练样本)

Table 4 Classification accuracy (selecting 5% data as training samples)

Training sample	SVM / %	RVM / %	VRVM / %
Corn-no till	79.31	77.97	80.21
Corn-min	78.16	77.32	79.88
Soybean-no till	85.33	84.57	87.21
Soybean-min	60.32	58.04	62.42
Woods	93.42	92.03	94.01
OA	75.91	74.38	77.42

Kappa 系数代表实验结果与原数据隶属度的关系,Kappa 系数越大,证明隶属度越高,分类效果越好。经过计算 VRVM 的 Kappa 系数相对 SVM 与 RVM 的有所增高,证明在小样本训练条件下,VRVM 在分类精度上有着较好的表现,实验结果如表 5 所示,其中训练样本为 2%。

表 5 不同分类器的 Kappa 系数

Table 5 Kappa coefficients of different classifiers

	SVM	RVM	VRVM
Kappa	0.669	0.667	0.683

3.2.2 分类效率

实验数据依然采用美国航空可见光/红外成像光谱仪所测高光谱数据 92AV3C,比较 3 种不同算法 SVM、RVM、VRVM 应用于高光谱图像分类效率好坏。主要评价指标包括:支持向量或相关向量的个数、训练时间以及测试时间,实验结果如表 6 和表 7 所示。

表 6 支持向量或相关向量的个数

Table 6 Number of SVs or RVs

Training sample	SVs	RVs	VRVs
350(5%)	268	77	76
700(10%)	546	134	134
1050(15%)	821	185	185
1400(20%)	1105	228	226
3499(50%)	2754	358	355

实验结果表明,RVM 与 VRVM 在不同训练样本个数情况下,相关向量的个数为 SVM 支持向量个数的 18%左右,两种算法具有比 SVM 更加简单的空间复杂度。相对于 RVM 而言,VRVM 的训练时间普遍减少,但是较 SVM 而言,训练时间依然很长,时间复杂度较高,这是 RVM 算法本身的缺陷。然而在测试时间上,RVM 与 VRVM 都有着较小的时间,甚至在小样本测试时间可以忽略不计,而 SVM 在测试时间上较慢,这也是因为在应用 SVM 时其支持向量较多的原因。

表 7 分类效率

Table 7 Efficiency of classification

Training sample	SVM		RVM		VRVM	
	Training time /s	Test time /s	Training time /s	Test time /s	Training time /s	Test time /s
350(5%)	2.7	3.2	14	0.3	12	0.3
700(10%)	3	3.6	43	0.4	40	0.4
1050(15%)	5.3	5.1	124	1.2	114	1.2
1400(20%)	8.4	12.3	809	2.4	609	2.3
3499(50%)	21.47	27.6	1806	3.9	1430	3.8

4 结 论

针对高光谱图像的特点以及相关向量机的不足,提出了基于改进型相关向量机高光谱图像分类算法。改进型相关向量机是一种利用近似算法的监督型机器学习理论,其优点在于将相关向量机的概率模型内较难计算的部分,近似化简为较为简单的对数和运算,以此提高训练的效率。实验结果表明,改进型相关向量机高光谱图像分类算法可以使得分类精度保持与 SVM 和 RVM 相同的情况下(小样本时还有所提高),减少训练时间以及测试时间,提高整体分类效率。在以后的研究中,可以结合数据降维或者应用小波核函数等方法来进一步降低运算时间。通过深层次的研究,在训练样本较小时,VRVM 的测试时间很短,所以有可能发展改进成为一种实时测试的算法,然而由于 RVM 的算法本身存在的缺陷,例如运算中矩阵应用的是记忆体,因此会对于其应用存在一定的限制,也是未来研究改进的方向。

参 考 文 献

- Li Shanshan, Zhang Bing, Gao Lianru *et al.*. Research on hyperspectral target detection algorithms based on variance minimum[J]. *Acta Optica Sinica*, 2010, **30**(7): 2116~2122
李山山,张兵,高连如等.基于方差最小的高光谱目标探测算法研究[J]. *光学学报*, 2010, **30**(7): 2116~2122
- Zhao Liaoying, Shen Yinhe, Li Xiaorun *et al.*. Composite kernel target detection based on mathematical morphology for hyperspectral imagery[J]. *Acta Optica Sinica*, 2011, **31**(12): 1228003
赵辽英,沈银河,厉小润等.基于数字形态学的高光谱图像组合核目标检测[J]. *光学学报*, 2011, **31**(12): 1228003
- Wang Liguang, Zhao Chunhui, Qiao Yulong *et al.*. Research on all-around weighting methods of hyperspectral imagery classification [J]. *J. Infrared Millim. Waves*, 2008, **27**(6): 442~445
王立国,赵春晖,乔玉龙等.高光谱图像分类的全面加权方法研究[J]. *红外与毫米波学报*, 2008, **27**(6): 442~445
- Shen Yi, Zhang Min, Zhang Miao. Mutual information bands selection and empirical mode decomposition based support vector machines for hyperspectral data high-accuracy classification [J]. *Laser & Optoelectronics Process*, 2011, **48**(9): 091001
沈毅,张敏,张淼.基于互信息波段选择和经验模态分解的高精度高光谱数据分类[J]. *激光与光电子学进展*, 2011, **48**(9): 091001

- Zhao Guilin, Zhu Qibing, Huang Min. Apple mealiness detection using supervised isometric feature mapping and support vector machine based on hyperspectral scattering image [J]. *Laser & Optoelectronics Process*, 2011, **48**(10): 101002
赵桂林,朱启兵,黄敏.高光谱的有监督 Isomap-SVM 苹果粉质化分类[J]. *激光与光电子学进展*, 2011, **48**(10): 101002
- C. Cortes, V. Vapnik. Support-vector networks [J]. *Mach. Learn.*, 1995, **20**(3): 273~297
- Yang Guopeng, Zhou Xin, Yu Xuchu *et al.*. Relevance vector machine for hyperspectral imagery unmixing [J]. *Acta Elelectronica Sinica*, 2010, **38**(12): 2751~2756
杨国鹏,周欣,余旭初等.基于相关向量机的高光谱影响混合像元分解[J]. *电子学报*, 2010, **38**(12): 2751~2756
- F. A. Mianji, Y. Zhang. Robust hyperspectral classification using relevance vector machine [J]. *IEEE Trans. Geosci. Remote Sensing*, 2011, **49**(6): 2100~2112
- M. Tipping. Sparse bayesian learning and the relevance vector machine [J]. *J. Mach. Learn. Res.*, 2001, **1**: 211~244
- Zhang Lei, Liu Jianwei, Luo Xionglin. KNN and RVM based classification method: KNN-RVM classifier [J]. *Pattern Recognition and Artificial Intelligence*, 2010, **23**(3): 376~384
张磊,刘建伟,罗雄麟.基于 KNN 和 RVM 的分类方法-KNN-RVM 分类器[J]. *模式识别与人工智能*, 2010, **23**(3): 376~384
- Li Gang, Wang Guilong, Xue Huifeng. GA optimizing method to kernel function parameters of RVM [J]. *Control Engineering of China*, 2010, **17**(3): 335~342
李刚,王贵龙,薛惠锋. RVM 核参数的遗传算法优化方法 [J]. *控制工程*, 2010, **17**(3): 335~342
- M. Pal, G. M. Foody. Feature selection for classification of hyperspectral data by SVM [J]. *IEEE Trans. Geosci. Remote Sensing*, 2010, **48**(5): 2297~2307
- G. Oliveri, A. Massa. Bayesian compressive sampling for pattern synthesis with maximally sparse non-uniform linear arrays [J]. *IEEE Trans. Antennas and Propagation*, 2011, **59**(2): 467~481
- R. Ram, M. Chetty. A markov-blanket-based model for gene regulatory network inference [J]. *IEEE/ACM Trans. Comput. Biol.*, 2011, **8**(2): 353~367
- T. Jaakkola, M. Jordan. Bayesian parameter estimation through variational methods [J]. *Stat. Comput.*, 2000, **10**(1): 25~37
- C. Bishop, M. Tipping. Variational relevance vector machines [C]. *Proc. 16th Conference on Uncertainty in Artificial Intelligence*, Morgan Kaufmann, 2000. 46~53
- B. D. Ripley. Neural networks and related methods for classification [J]. *J. Roy. Statist. Soc.*, 1994, **56**(3): 409~456
- J. Chen, C. Wang, R. Wang. Using stacked generalization to combine SVMs in magnitude and shape feature spaces for classification of hyperspectral data [J]. *IEEE Trans. Geosci. Remote Sensing*, 2009, **47**(7): 2193~2205
- Yang Guopeng, Yu Xuchu, Zhou Xin *et al.*. Research on relevance vector machine for hyperspectral imagery classification [J]. *Acta Geodaetica et Cartographica Sinica*, 2010, **39**(6): 572~578
杨国鹏,余旭初,周欣等.基于相关向量机的高光谱影像分类研究[J]. *测绘学报*, 2010, **39**(6): 572~578