

文章编号 1004-924X(2012)06-1398-08

最速上升关联向量机高光谱影像分类

董超*, 田联房

(华南理工大学 自动化科学与工程学院, 广东 广州 510641)

摘要:针对高光谱影像近邻波段高度相关, 直接在高维空间分类并非最优的问题, 提出了基于最速上升和关联向量机(SA-RVM)的高光谱影像分类算法。使用最速上升(SA)算法搜索最优特征子空间, 剔除冗余特征; 然后, 在特征子空间中训练RVM并分类。对4套测试数据进行的实验表明, SA选择的特征子空间中, RVM分类精度提高了2.5%以上, 与支持向量机(SVM)相当。对训练样本较少的2套数据, 精度提高了5.63%和6.2%。此外, SA-RVM的解稀疏, 预测未知样本类别属性所需时间短。总体来看, SA-RVM精度高、判别速度快, 适合处理大场景高光谱影像。

关键词:高光谱图像; 影像分类; 最速上升; 关联向量机

中图分类号: TP751.1 **文献标识码:** A **doi:** 10.3788/OPE.20122006.1398

Hyperspectral image classification by steepest ascent relevance vector machine

DONG Chao*, TIAN Lian-fang

(School of Automation Science and Engineering,
South China University of Technology, Guangzhou 510641, China)

* Corresponding author, E-mail: dcAuto@scut.edu.cn

Abstract: As the adjacent bands of a hyperspectral image are highly correlated, it is not optimum to classify the hyperspectral image in the high dimensional space. To solve the problem, a novel hyperspectral image classifier based on Steepest Ascent and Relevance Vector Machine (SA-RVM) was proposed in this paper. The SA was used to search an optimum feature space and to eliminate redundant features of the image firstly. Then, RVM was trained in the optimized feature subspace and used to classify the test samples. Experiments were performed for four sets of data, it is shown that the accuracies of RVM have raised more than 2.5% in the feature subspace selected by SA, which is close to those of Support Vector Machines (SVMs). For the two data sets with fewer training samples, the accuracies of RVM increase by 5.63% and by 6.2% in the subspace. In addition, benefiting from the sparse solution, the SA-RVM requires very short time in predicting the class labels of unknown samples. It concludes that the SA-RVM has higher precision and efficiency in the prediction, and it is

收稿日期: 2012-02-09; 修订日期: 2012-03-10.

基金项目: 中国博士后科学基金面上资助项目 (No. 20100480750); 中央高校基本科研业务费资助项目 (No. 2012ZM0100)

suitable for processing the large-scale hyperspectral images.

Key words: hyperspectral image; image classification; Steepest Ascent (SA); Relevance Vector Machine (RVM)

1 引言

高光谱影像光谱分辨率高、数据量大,对科研人员提出了新的技术难题。训练样本有限时,传统分类器在高维空间建模精度低,该效应称为 Hughes 效应^[1]。采集足够多的训练样本,可保证分类器的建模精度,但这样做耗费人力、物力,实际应用中并不可取。近年来大量研究报道指出,解决高光谱影像的小样本分类问题,可归为以下4类:(1)正规化协方差矩阵^[2];(2)降维,包含特征提取和特征选择^[3-4];(3)半监督学习策略^[5];(4)低复杂度分类器^[6-7],如支持向量机(Supported Vector Machine, SVM)。

SVM可处理高维数据、泛化能力强,但在应用中仍存在参数多、解稀疏程度不高、无法计算预测概率、核函数必须满足 Mercer 条件等缺点。尤其是解的稀疏程度不高这个缺点,使得 SVM 判别模型相对复杂,预测海量数据实时性不好。关联向量机(Relevance Vector Machine, RVM)^[8]使用超参数约束模型复杂度,保障泛化性能,提高解的稀疏度,已成功解决了机器视觉等领域的技术难题。近些年,RVM 已被应用于遥感影像处理^[9-13]。使用 RVM 对高光谱影像分类,精度可达到 SVM 的水平。此外,RVM 解更稀疏,适合处理大场景影像^[9]。RVM 可直接处理多类别分类问题^[10,12],与判别分析、神经网络和 SVM 等相比,其性能更优异。

高光谱影像相邻波段高度相关,直接在高维空间分类并非最优。为解决该问题,先前已提出遗传关联向量机(GA-RVM)高光谱影像分类算法^[13]。该算法使用遗传算法(Genetic Algorithm, GA)选择面向 RVM 的最优参数和特征子空间,经 GA 优化后,近一半冗余波段被剔除,几种难分地物的分类精度大幅提升。GA-RVM 使用 RVM 分类精度作为评价准则,是一种嵌入型特征选择算法,耗时长、实时性差。本文将特征选

择和分类看成两个独立的模块,提出基于最速上升(Steepest Ascent, SA)和关联向量机(RVM)的高光谱影像分类算法 SA-RVM。使用 SA 剔除冗余特征,并在特征子空间中使用 RVM 进行分类。该方法计算开销相对较低、判别速度快,性能优于 GA-RVM。此外,SA-RVM 也继承了 RVM 的稀疏特性,适合处理大场景高光谱影像。

2 基于最速上升的特征选择

高光谱影像波段多,相邻波段间相关性高,直接在高维空间分类效果欠佳,需使用特征选择等剔除冗余特征,以提高后续分类算法的精度和效率。特征选择算法的设计包含评价准则和搜索策略两方面,即使用搜索策略在原始特征空间内寻找满足评价准则的最优特征子集。评价准则方面,可用 Bhattacharyya (BH) 距离、Jeffries-Matusita (JM) 距离、分类器精度等指标度量。搜索算法的性能对特征选择至关重要,目前顺序前向搜索(SFS)、顺序后向搜索(SBS)、顺序前向浮动选择(SFFS)、顺序后向浮动选择(SBFS)、最速上升(SA)等算法已成功应用于高光谱影像特征提取。研究表明,SA 搜索的特征子空间中类别可分性更高,故本文使用 SA 算法作为搜索策略,以 JM 距离为评价准则来搜索最优特征子空间,提高 RVM 的分类精度。

设有 C 类、 N 个训练样本 $\{x_n\}_{n=1}^N$, 原始数据包含 D 个特征、选择后保留 d 个特征,且满足 $d < D$ 。SA 算法将 D 个特征分割成已选特征 S (包含 d 个特征) 和剔除特征 B (包含 $D-d$ 个特征) 两部分,根据 JM 距离依次置换 S 和 B 中某一个特征,重复该过程直至 JM 距离收敛,算法流程如下:

(1) 从 D 个特征中随机选择 d 个特征组成已选特征 S_0 , 其余 $D-d$ 个特征组成剔除特征 B_0 ;

(2) 将训练样本和 S_0 代入公式(1)~(2), 计

算 $JM(S_0)$, 令 $JM_{\max} = JM(S_0)$ 。其中 P_i , m_i 和 C_i 分别为第 i 类地物的先验概率、均值向量和协方差矩阵;

$$JM = 2 \sum_{i=1}^c \sum_{j=i+1}^c P_i P_j \sqrt{2[1 - \exp(-b_{ij})]} \quad (1)$$

$$b_{ij} = \frac{1}{8} (m_i - m_j)^T \left[\frac{C_i + C_j}{2} \right]^{-1} (m_i - m_j) + \frac{1}{2} \ln \left[\frac{|C_i + C_j|}{2\sqrt{|C_i||C_j|}} \right] \quad (2)$$

(3) 第 k 次迭代步: 从第 $k-1$ 次迭代步的 B_{k-1} 中任取一个特征 u , 替换 S_{k-1} 中任意一个特征 v , 组成新的候选特征 $Q_{u,v}$ 。遍历 B_{k-1} 与 S_{k-1} 每次互换一个特征的所有组合, 组成候选特征集 $Q = \{Q_{u,v} \}_{\substack{u=1,2,\dots,D \\ v=1,2,\dots,d}}$;

(4) 依次将各候选特征 $Q_{u,v}$ 代入公式(1)~(2), 计算 $JM(Q_{u,v})$, 令 $JM_k(Q) = \max\{JM(Q_{u,v})\}$;

(5) 若 $JM_k(Q) > JM_{\max}$, 根据与最大值 $JM_k(Q)$ 对应的 (u, v) 坐标, 置换 S_{k-1} 和 B_{k-1} 中相应的特征, 并记录为 S_k 和 B_k ; 令 $JM_{\max} = JM_k(Q)$, $k = k+1$, 跳转至步骤(3)继续优化; 若 $JM_k(Q) \leq JM_{\max}$, 算法收敛, 跳转至步骤(6);

(6) 第 $k-1$ 步的已选特征 S_{k-1} 即为最优特征。

SA 算法按照 JM 距离上升最快的方向, 每次将剔除特征 B 中的一个特征置换到已选特征 S 中, 直至 JM 距离收敛。每个迭代步中, 需计算 $d \times (D-d)$ 个候选特征 $Q_{u,v}$ 的 JM 距离。若 K 步迭代后收敛, 其计算复杂度为 $K \times d \times (D-d)$ 。

3 关联向量机

对训练样本 $\{x_n\}_{n=1}^N$ 和类别标号 $\{t_n\}_{n=1}^N$, RVM 使用核函数 K 的线性组合描述输入、输出间的关系

$$y(x; \omega) = \sum_{n=1}^N \omega_n K(x, x_n) + \omega_0 \quad (3)$$

其中 $\omega = \{\omega_n\}_{n=0}^N$ 为权重系数。二类问题中, 类别标号 $t_n \in \{0, 1\}$ 。RVM 算法使用伯努利分布计算条件概率密度

$$p(t | \omega) = \prod_{n=1}^N y_n^{t_n} (1 - y_n)^{1-t_n} \quad (4)$$

其中 $t = \{t_1, t_2, \dots, t_N\}^T$, $\omega = \{\omega_0, \omega_1, \omega_2, \dots, \omega_N\}^T$,

$y_n = \sigma(y(x_n; \omega))$ 。 $\sigma(y)$ 为 Sigmoid 连接函数,

$$\sigma(y) = 1 / (1 + e^{-y}) \quad (5)$$

用于将 $y(x)$ 映射到 $[0, 1]$ 内。为保证算法泛化能力, 假设 ω 符合式(6)正态分布。

$$p(\omega | \alpha) = \prod_{n=0}^N N(\omega_n | 0, \alpha_n^{-1}) \quad (6)$$

根据似然函数和先验概率, 由贝叶斯公式得 ω 的后验概率密度

$$p(\omega | t, \alpha) = \frac{p(t | \omega) p(\omega | \alpha)}{p(t | \alpha)} \quad (7)$$

其中 $p(t | \alpha)$ 为证据函数。求 $p(\omega | t, \alpha)$ 的极值, 可得到权重系数 $\{\omega_n\}_{n=0}^N$ 和超参数 $\{\alpha_n\}_{n=0}^N$ 的最优值。对分类问题, 似然函数和后验概率均不符合高斯分布, 式(7)无解析解, 需要使用迭代重加权最小二乘和 Laplacian 算法计算近似解^[8], 算法流程如下:

(1) 初始化 ω 和 α ;

(2) 固定 α , 按公式(8)~(10)更新 ω ,

$$g = \nabla_{\omega} \log p(\omega | t, \alpha) |_{\omega_{MP}} = \Phi^T (t - y) - A \omega \quad (8)$$

$$H = \nabla_{\omega} \nabla_{\omega} \log p(\omega | t, \alpha) |_{\omega_{MP}} = -(\Phi^T B \Phi + A) \quad (9)$$

$$\omega_{MP}^{new} \leftarrow \omega_{MP}^{old} - H^{-1} g \quad (10)$$

矩阵 Φ , A 和 B 的细节参考[8];

(3) 固定 ω , 按公式(11)更新 α

$$\alpha_n^{new} = \frac{1 - \alpha_n^{old} \sum_m}{\omega_{MP}^{new}{}^2} \quad (11)$$

其中 $\Sigma = -H^{-1}$;

(4) 重复步骤(2)~(3), 直至收敛;

(5) 使用优化后的模型预测测试样本类别归属。

算法收敛后, 多数 α_n 数值较大, 与之对应的 ω_n 后验概率为 0, 使得 RVM 的解高度稀疏。与数值较小的 α_n 相对应的样本点称为关联向量, 其权重系数 ω_n 非零, 预测未知样本类别属性时带入式(3), 用于分类^[8]。RVM 为二分类算法, 需结合一对一(OAO)、一对多(OAA)等实现多分类, 参考[12]中结论, 使用性能最优的 OAO。RVM 应用于高光光谱影像分类的技术细节参考文献[9, 12-13]。

4 SA-RVM 算法

本文提出基于最速上升和关联向量机的高光

谱影像分类算法(Steepest Ascent and Relevance Vector Machine, SA-RVM),继承 RVM 解稀疏程度高、预测时间短的特点。使用 SA 特征选择算法剔除冗余特征,提高 RVM 的分类精度,算法流程参见图 1。首先,对原始数据进行预处理操作,删除水汽吸收、低信噪比波段。其次,以 JM 距离为评判指标,使用 SA 算法选择最优特征子空间。最后,在特征子空间中训练 RVM,并预测待分类影像类别属性。




图 1 SA-RVM 算法流程图

Fig. 1 Flowchart of SA-RVM algorithm

5 实验结果

实验环节使用 Indian Pine 实验区高光谱影像^[14]测试 SA-RVM 算法,该数据由机载可见光/红外成像光谱仪(AVIRIS)采集。原始数据空间分辨率为 20 m,包含 145×145 个像元;光谱分辨率为 10 nm,将 400~2 500 nm 谱段分割成 224 个波段。剔除 24 个水汽吸收和低信噪比波段,剩余 200 个波段用于测试。表 1 和图 2 给出实验区 9 种典型地物信息,其中 5 种农作物光谱曲线近似,分类难度大。

表 1 Indian Pine 地区 9 种典型地物信息统计表

Tab.1 Information of nine typical ground objects of Indian Pine

类别	名称	总样本数
C1	玉米地 1	1 265
C2	玉米地 2	728
C3	牧草	449
C4	树草	671
C5	干草	456
C6	大豆地 1	849
C7	大豆地 2	2 268
C8	大豆地 3	577
C9	树林	1 226




图 2 Indian Pine 典型地物分布示意图

Fig. 2 Distribution map of typical ground objects of Indian Pine

为全面了解算法性能,分别从每种地物中提取 5%、10%、30% 和 50% 的样本组成训练样本集,其余作为测试样本,分析训练样本不足、适中和充足时 SA-RVM 的性能。SA-RVM 在 Matlab 2008 下实现,SA 算法依参考文献[4]编写,RVM 在 SPARSE BAYES V1. 10 的基础上结合 OAO 算法实现多分类。SA 算法的初值随机生成,为避免随机初值对算法性能的影响,测试 SA-RVM 算法 5 次并计算平均值。测试过程中,使用 libsvm 软件包提供的 SVM 作为基准,验证 SA-RVM 的性能。RVM 和 SVM 均使用径向基函数(RBF)核,参数使用 K-Fold 交叉验证和网格搜索方法寻优^[9,12-13]。

图 3 验证了 SA 提取特征的有效性,其中横坐标为特征数,纵坐标为 JM 距离。随特征数增加, JM 距离上升,但增长幅度逐渐减小。测试数据包含 9 类地物,理论上至少需要 8 个特征才能

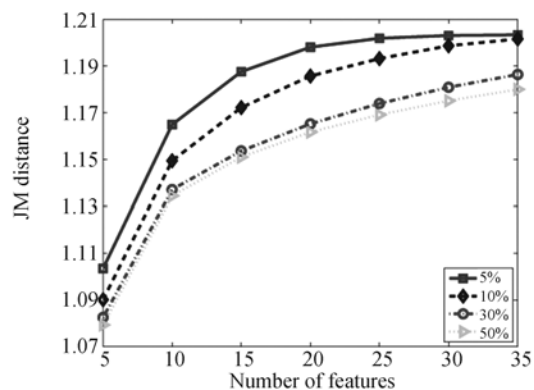


图 3 各实验数据集在 SA 提取的特征子空间中的 JM 距离

Fig. 3 JM distances of data sets in feature subspace selected by SA

完全将 9 类地物完全区分开。若仅提取 5 个特征,特征空间中 9 种地物间存在重叠,故类别可分性(即体现为 JM 距离)较低。当特征数从 5 增长到 10 后,有效特征数首次大于 8,因此 JM 距离改进最为明显。若特征数进一步增长,特征空间中的类别可分性进一步提高,但幅度逐渐放缓,基本与理论分析结果一致。当特征数达到 20 个以上,各条曲线涨幅已很低,该现象与文献[4]的结论一致。

图 4 比较了 SA 提取的特征空间中,RVM 的分类效果。与图 3 不同,随特征数增长,RVM 精度先升后降。特征数从 5 增长到 10 时,各条曲线的 OA 均大幅上涨,其原因与图 3 相同。当特征数超过 10 个后,5%数据集 RVM 的精度缓慢下降,10%的出现波动、在特征数超过 20 个后衰减。训练样本充足的两套测试数据(30%和 50%),曲线的峰值出现在 20~30 个特征之间,有效特征大于 5%和 10%这两种情况,且衰减幅度较小。该实验验证了在高维空间中分类并非最优,特征过多时 RVM 的精度反而会衰减。若能够提取有效特征,分类精度将得到改善,证明了本文提出方法的有效性。综合图 3 和图 4 的实验结果,对该套数据 RVM 使用 30 个左右的最优特征,可获得最佳分类效果。




图 4 经 SA 算法处理后,各实验数据集特征子空间中 RVM 的总体分类精度

Fig. 4 Overall accuracy of RVM for each data set in feature subspace after processed by SA

表 2 量化分析 SA-RVM 等 5 种算法,括号中数字为经 SA 或 GA 优化后,特征子空间中 RVM、SVM 精度最高时所使用的特征数。直接在高维空间中分类,RVM 不如 SVM,当训练样本较少时(5%和 10%)较为明显。SA 提取的特

征空间中,RVM 和 SVM 的分类精度均出现增长,RVM 增长幅度较大,大于 SVM 的涨幅。训练样本比重为 5%时,经 SA 优化后 RVM 的精度从 77.16%上升到 82.79%,涨幅 5.63%。训练样本比重为 10%时,RVM 的精度从 81.78%上升到 87.98%,涨幅 6.2%。30%和 50%两套数据,原始空间中 RVM 分类精度较高,经 SA 优化后涨幅不如前两套数据,但涨幅也在 2.5%以上。SA 对 SVM 性能的提升不是很明显,特征空间中 SVM 精度的涨幅均在 2.5%以下。特征空间中,RVM 的精度较高,基本达到了 SVM 和 SA-SVM 的水平。图 5 为训练样本比重 50%时,RVM、SVM、SA-RVM 和 SA-SVM 分类效果示意图。SA 提取的特征空间中,5 种较难区分的农作物处,RVM 和 SVM 的误判明显减少。

实验过程中,也测试了 GA-RVM 算法的分类精度。训练样本比重大于 5%时,GA-RVM 训练时间过长,故未给出 10%、30%和 50%等 3 套数据 GA-RVM 的实验结果。可以看出,GA-RVM 搜索出 95 个特征组成最优特征子空间,但精度比 SA-RVM 低 2.79%。该现象说明 GA-RVM 的搜索结果中仍包含若干无效特征,致使性能提升有限。GA-RVM 训练时间非常长,即便使用实时性较好的 C++语言开发,5%这套数据仍需耗费 5~6 h,实时性较差^[13]。SA-RVM 耗时短,5%数据集的开销不到 5 min,实时性非常好。若使用 C++语言编写 SA-RVM 代码,其开销将进一步降低。

表 2 SA-RVM 等算法的总体分类精度

Tab. 2 Overall accuracies of SA-RVM, RVM, GA-RVM, SVM and SA-SVM (%)

实验数据	RVM	SA-RVM	GA-RVM	SVM	SA-SVM
5%	77.16	82.79(10)	80.00(95)	84.50	85.48(20)
10%	81.78	87.98(20)	测试时 间过长	87.81	90.04(20)
30%	88.82	91.65(20)		92.32	93.76(30)
50%	91.39	93.90(30)		94.77	95.12(30)

图 6 比较了 RVM 和 SVM 解的稀疏程度,每条柱代表关联向量(RV)或支持向量(SV)的个数。可以看出,不论在原始空间还是特征空间中,RVM 的稀疏程度远高于 SVM。预测过程中,仅 RV 和 SV 参与运算,RV 和 SV 越少,判别时间

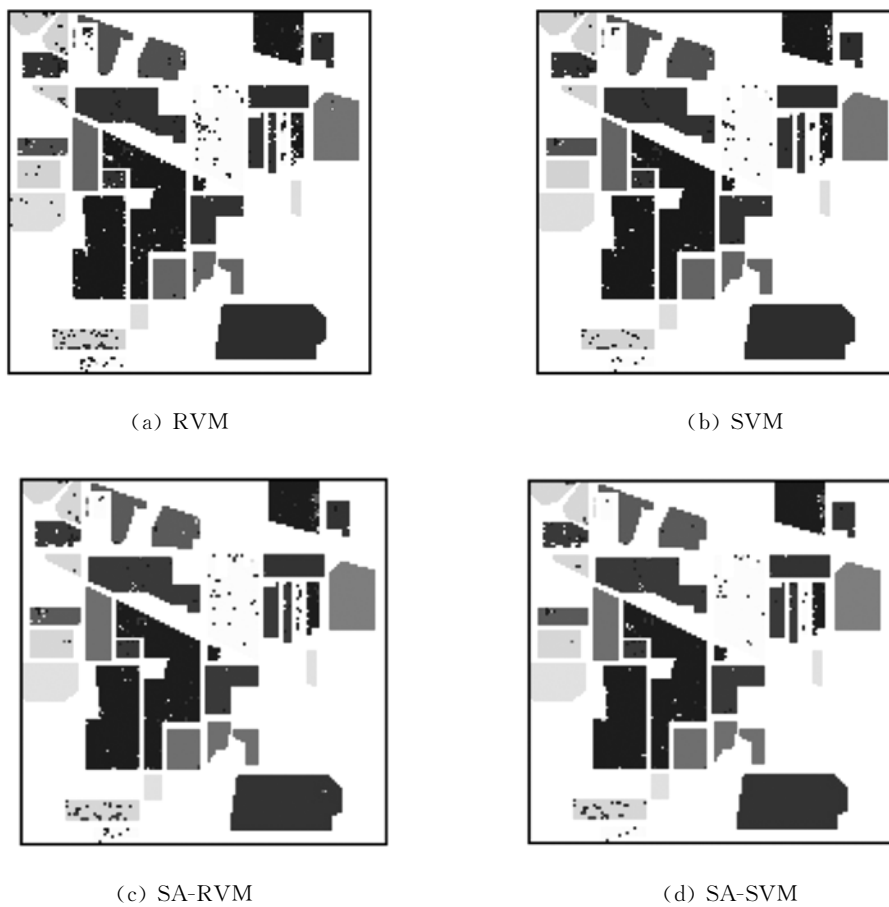


图 5 训练样本比例 50%时,RVM、SA-RVM、SVM 和 SA-SVM4 种算法分类结果示意图

Fig. 5 Classification maps of RVM, SA-RVM, SVM and SA-SVM for 50% data set

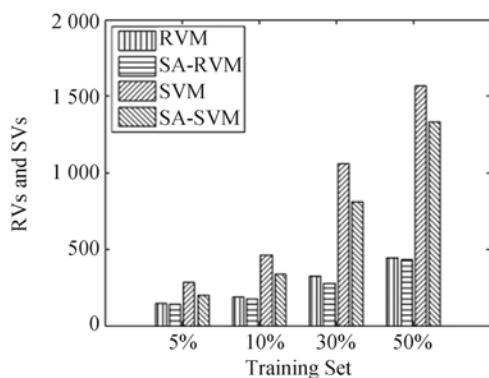


图 6 RVM、SA-RVM、SVM 和 SA-SVM 稀疏程度示意图

Fig. 6 Sparse levels of RVM, SA-RVM, SVM and SA-SVM

短,高稀疏性可以确保 RVM 处理大场景影像时效率较高。经 SA 优化后,RVM 和 SVM 的稀疏程度均有所提高,SVM 的变化幅度略大。SV 出现在决策面附近,Indian Pine 实验区地物相似度

高、决策面附近样本点较多,SV 必然多。SA 提取的特征空间中,类别可分性上升,原始空间中不同类别间重叠的部分样本点被分开,决策面附近的样本数量减少,导致 SVM 稀疏性的提高幅度较大。RV 反映各类本征信息,与决策面附近样本相比,本征样本数量相对较少,故 RV 总量较低。本征样本受特征影响相对较小,不论在哪个空间中皆出现在远离决策面的区域,因此 RV 衰减程度不明显,但 RVM 的稀疏性仍远优于 SVM。

6 结 论

本文提出 SA-RVM 高光谱影像分类算法,使用 SA 搜索最优特征子空间、剔除冗余波段,提高 RVM 的分类精度。对于实验所用数据,SA-RVM 选择的有效特征在 30 个以内,远低于 GA-RVM 的 95 个有效特征,特征子空间中 RVM 分

类精度提升显著。对 4 套测试数据, RVM 分类精度的涨幅均在 2.5% 以上, 对训练样本较少的两套数据(5% 和 10%), 提高了 5.63% 和 6.2%, 基本达到 SVM 的水平。和 SVM 相比, SA-RVM

解的稀疏程度更高, 判别未知样本类别属性所需的时间更短。综合分类精度和判别效率两方面因素, SA-RVM 精度高、实时性好, 适合处理大场景高光谱影像。

参考文献:

- [1] HUGHES G F. On the mean accuracy of statistical pattern recognizers [J]. *IEEE Transactions on Information Theory*, 1968, 14(1): 55-63.
- [2] TADJUDIN S, LANDGREBE D A. Covariance estimation with limited training samples [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 1999, 37(4): 2113-2118.
- [3] KUO B C, LANDGREBE D A. Nonparametric weighted feature extraction for classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2004, 42(5): 1096-1105.
- [4] SERPICO S B, BRUZZONE L. A new search algorithm for feature selection in hyperspectral remote sensing images [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2001, 39(7): 1360-1367.
- [5] DUNDAR M M, LANDGREBE D A. A cost-effective semisupervised classifier approach with kernels [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2004, 42(1): 264-270.
- [6] MELGANI F, BRUZZONE L. Classification of hyperspectral remote sensing images with support vector machines [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2004, 42(8): 1778-1790.
- [7] BAZI Y, MELGANI F. Toward an optimal SVM classification system for hyperspectral remote sensing images [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2006, 44(11): 3374-3385.
- [8] TIPPING M E. Sparse bayesian learning and the relevance vector machine [J]. *Journal of Machine Learning Research*, 2001, 1: 211-244.
- [9] DEMIR B, ERTURK S. Hyperspectral image classification using relevance vector machines [J]. *IEEE GeoScience and Remote Sensing Letters*, 2007, 4(4): 586-590.
- [10] FOODY G M. RVM-based multi-class classification of remotely sensed data [J]. *International Journal of Remote Sensing*, 2008, 29(6): 1817-1823.
- [11] CAMPS-VALLS G, GOMEZ-CHOVA L, MUÑOZ-MARI J, et al. Retrieval of oceanic chlorophyll concentration with relevance vector machines [J]. *Remote Sensing of Environment*, 2006, 105: 23-33.
- [12] 董超, 赵慧洁. 关联向量机在高光谱影像分类中的应用[J]. *遥感学报*, 2010, 14(6): 1279-1284.
- [12] DONG CH, ZHAO H J. Hyperspectral image classification and application based on relevance vector machine [J]. *Journal of Remote Sensing*, 2010, 14(6): 1279-1284. (in Chinese)
- [13] 董超, 田联房, 赵慧洁. 遗传关联向量机高光谱影像分类[J]. *上海交通大学学报*, 2011, 45(10): 1516-1520.
- [13] DONG CH, TIAN L F, ZHAO H J. Hyperspectral image classification by genetic relevance vector machine [J]. *Journal of Shanghai Jiao Tong University*, 2011, 45(10): 1516-1520. (in Chinese)
- [14] AVIRIS N W. Indiana's Indian Pines Data Set [DB/OL]. ftp://ftp.ecn.purdue.edu/biehl/MultiSpec/92AV3C, 1992.

作者简介:



董超(1982—),男,新疆哈密人,博士后,助理研究员,2010年于北京航空航天大学获得博士学位,主要从事图像处理、模式识别等方面的研究。E-mail: dcAuto@scut.edu.cn

导师简介:



田联房(1968—),男,山东济宁人,教授,博士生导师,1994年于山东工业大学获得硕士学位,1997年于哈尔滨工业大学获得博士学位,主要从事机器人、医学影像处理、智能控制系统等方面的研究。E-mail: chlftian@scut.edu.cn

●下期预告

磁力弹簧式压电共振型气泵的设计

谢海峰¹,吴越¹,接勳^{1,2},杨志刚¹,王兴元¹

(1. 吉林大学机械科学与工程学院,吉林 长春 130025;

2. 吉林化工学院机电工程学院,吉林 吉林 132022)

为了提高压电泵对气体的驱动能力,利用压电振子的振动激励相连接的隔膜共振原理,进行了磁力弹簧式压电共振型气泵的研究。首先,分析磁力弹簧式共振泵的工作原理,建立了共振泵的动力学模型,通过计算得出影响隔膜振幅的主要因素。接着设计和制作了样机,使用阻抗分析仪和激光测位移分别测得系统的共振频率及压电振子的位移放大倍数。最后,设计了对共振泵流量和输出压力测量的实验装置,得出了磁力弹簧轴向间距对输出流量和输出压力的影响。实验测试表明:当输入正弦电压为200 V,系统共振频率为134 Hz,磁力弹簧的轴向间距为9 mm时,压电振子的位移放大倍数约为4.3,其最佳输出流量为524 ml/min,最佳输出压力为9.2 kPa。本文提出的磁力弹簧式压电共振型气泵对气体的输送能力有了提高。