

凸组合核函数的支持向量机高光谱图像分类

胡燕燕, 李东生, 张诗桂
(电子工程学院, 安徽 合肥 230037)

摘要:支持向量机的高光谱图像分类中,单核函数存在局限性。为了提高分类器的分类精度和支持向量机模型的泛化能力,利用高斯径向基核和多层感知核进行凸组合构造复合核函数支持向量机,证明了该函数满足作为核函数的判决 Mercer 条件,并进一步将凸组合核函数支持向量机应用到高光谱图像分类中,完成了建模和实验验证。实验结果表明,凸组合核函数具有较好的鲁棒性,且该类支持向量机的分类精度和 KAPPA 系数较单核 SVM 均得到了有效的提高,是一种解决多分类问题行之有效的分类器。

关键词:高光谱图像;支持向量机;核函数;凸组合

中图分类号:TP751 **文献标识码:**A **DOI:**10.3969/j.issn.1001-5078.2016.05.023

Classification of hyperspectral image by convex combination kernels function SVM

HU Yan-yan, LI Dong-sheng, ZHANG Shi-gui
(Electronic Engineering Institute, Hefei 230037, China)

Abstract:In support vector machine (SVM) hyperspectral image classification, monocyte function has its limitation. In order to improve the classifier accuracy and generalization ability of SVM model, a complex kernel function SVM using the convex combination of radial basis function kernel and sigmoid kernel was constructed, and it proves that the function satisfies a judgment called Mercer condition as a kernel function. Then, the convex combination of kernels SVM was applied to hyperspectral image classification, and the modeling and experimental validation were completed. The experimental results show that the convex combination kernel has better robustness. As the classification accuracy and KAPPA coefficient have been effectively improved compared to that of the single-core SVM, the new SVM is an effective solution to the problem of multi-classification.

Key words:hyperspectral image; SVM; kernel function; convex combination

1 引言

高光谱图像具有光谱分辨率高,图谱合一的优点,依据目标光谱维和空间维特征实现图像的识别和分类,在民/军用领域都有着广泛应用。但在高光谱图像的分类识别方面也存在一定的困难,如 Hughes 现象;因波段多、波段间相关性高而导致的所需训练样本数增多^[1],进而导致训练样本不足问

题;因数据量大导致的数据冗余以及数据预处理问题等,这些都会影响到分类精度。

高光谱分类方法众多,就分类能力而言,支持向量机(SVM)在小样本学习、抗噪性能、学习效率与推广性方面都有较大的优势,能够有效克服样本不足带来的 Hughes 现象,采用全部波段数据进行分类,不必经过数据降维,直接对高维数据进行处理,

基金项目:国家自然科学基金资助项目(No. 61179036; No. 61201379)资助。

作者简介:胡燕燕(1989-),女,博士生,研究方向为模式识别与遥感探测。E-mail: huyanyanzsg@163.com

收稿日期:2015-09-13

保证了光谱信息应用的充分性^[2]。SVM 是一种广义的线性分类方法,然而实际的分类问题大都是非线性的,即是线性不可分的,可以通过某种非线性映射将训练样本映射到另一个高维的特征空间,来增强样本的可分性,核函数正反映了这种映射关系。而决定 SVM 分类器分类性能的关键因素就是它的核函数,不同的核函数,SVM 的性能不同。因此在 SVM 的研究中,其核心问题就转化为了确定核函数的问题,本文以高光谱图像分类为研究对象,提出一种基于凸组合核函数的 SVM(Convex Combination of Kernels SVM,SVM-CCK)分类方法。

2 SVM_CCK 建模

样本分类问题实质是一个“相似度”问题,而核函数正是体现了“相似度”的不同含义。由于“相似度”有不同的度量(如辐角、距离、向量),因此需要选择不同的核函数。常用的核函数有^[3-5]:

1) 线性核函数(Linear Kernel,L-K):

$$K(x, x_i) = (x \cdot x_i) \quad (1)$$

2) 多项式核函数(Polynomial Kernel,Poly-K):

$$K(x, x_i) = [(x^T x_i) + 1]^q \quad (2)$$

3) 高斯径向基核函数(Radial Basis Function Kernel,RBF-K):

$$K(x, x_i) = \exp\left\{-\frac{\|x - x_i\|^2}{2\sigma^2}\right\} \quad (3)$$

4) 二次核函数(Quadratic Kernel,Qu-K):

$$K(x, x_i) = x^T x_i (x^T x_i + 1) \quad (4)$$

5) 多层感知器核函数(Sigmoid Kernel,Sig-K):

$$K(x, x_i) = \tanh[v(x^T x_i) + \gamma] \quad (5)$$

该核函数虽然是非半正定的核,但是当 $v > 0$, $r < 0$ 时,且足够小时,Sigmoid 核被证明是条件正定的^[6]。

有文献表示^[7],线性核函数的精度最低,高斯径向基核函数的精度最高。

下面从两个方面对核函数进行归纳分类:

(1) 基于样本相似性度量。从几何角度考虑原因,典型的核函数中,L-K、Poly-K 和 Sig-K 都是基于点积的核函数,RBF-K 是基于距离的核函数。




图1 映射向量角度和距离的几何关系

Fig.1 Geometric relational between mapping vector angles and distances

图1中,不同类的两样本 x 与 y 经过映射 $\phi(\cdot)$ 得到高维特征空间中两向量 $\phi(x)$ 与 $\phi(y)$,此时如果向量 $\phi(x)$ 与 $\phi(y)$ 的夹角 θ 非常小,那么用角度来判断相似性时这两个样本被归为一类;而如果用距离 $\phi(x) - \phi(y)$ 来衡量相似性,那么相对于角度而言,被错分的可能性较小。显然,单纯的由夹角作为相似性度量进行分类时,差分概率会比较大。

(2) 数据点的远近对核函数的作用大小,分为全局核函数和局部核函数。全局核函数允许相距很远的数据点对核函数的值有影响;局部核函数具有局部性,只有相距很近的数据点对核函数的值有影响。典型的,L-K 核函数是全局核函数,RBF-K 是局部核函数^[7-8]。

经典支持向量机在图像分类时只用单一的核函数和单一的数据源数据进行分类,但事实上通过核函数的不同组合也能得到一些有意义的核函数。

根据引理^[9],设 K_1 、 K_2 是在 $X \times Y$ 上的核函数, $X \in \mathbf{R}_n$,常数 $a \geq 0$,下面的函数仍是核函数:

$$K(x, x') = K_1(x, x') + K_2(x, x') \quad (6)$$

$$K(x, x') = a \cdot K_1(x, x') \quad (7)$$

针对高光谱数据的特点,本文根据式(6)和式(7)提出一种凸组合的核函数模型:

$$\begin{cases} K(x, x') = \lambda_1 K_1(x, x') + \lambda_2 K_2(x, x') \\ s. t. \lambda_1 + \lambda_2 = 1, 0 < \lambda_1, \lambda_2 < 1 \end{cases} \quad (8)$$

λ_1 、 λ_2 为权系数,反映两核函数对分类效果的影响程度。基于普遍认为 RBF-K 核函数分类精度较高,且当 Sig-K 函数中 v 和 γ 取值较小时,性能与 RBF-K 核函数相当。结合上文提到的核函数区分标准,本文选择 $K(x, x')$ 为 RBF-K 和 Sig-K 的凸组合,目的是充分利用两函数的优势,扬长避短。该模型也满足 Mercer 条件,证明如下:

$$\begin{aligned} & \iint [\lambda_1 K_1(x, x') + \lambda_2 K_2(x, x')] \phi(x) \phi(x') dx dx' \\ &= \iint \lambda_1 K_1(x, x') \phi(x) \phi(x') dx dx' + \\ & \iint \lambda_2 K_2(x, x') \phi(x) \phi(x') dx dx' \end{aligned} \quad (9)$$

又 $0 < \lambda_1 < 1$, $0 < \lambda_2 < 1$,得到:

$$\begin{aligned} & \lambda_1 \iint K_1(x, x') \phi(x) \phi(x') dx dx' + \\ & \lambda_2 \iint K_2(x, x') \phi(x) \phi(x') dx dx' \geq 0 \end{aligned} \quad (10)$$

该式明显符合 Mercer 条件,故凸组合核仍是核函数。结合到高光谱图像分类问题,SVM_CCK 建模如图2所示。




图2 SVM-CCK 高光谱图像分类建模

Fig. 2 Modeling the SVM-CCK classification of hyperspectral imagery

目前在 SVM 的学习中^[10],一方面,不同类核函数性能完全不同;另一方面,同类核函数,不同的参数分类效果也不同。SVM 模型中参数包括以下部分:1) 惩罚因子 C ; 2) 核函数中的参数。例如 RBF-K SVM 模型中的参数就 C 、 σ , σ 影响分类器的复杂程度, C 影响分类器的推广误差。一个 SVM 分类器总有一个使分类效果最优的惩罚因子 C , 下文将选定一个惩罚因子,分别从核参数和权参数的角度分析验证该模型的分类效果。

3 分类实验与结果

3.1 核函数特性分析

待测样本相距标准点的远近对核值的影响反映了该核函数的局部和全局特性,这种特性在建模时直接反映在系统对模型的泛化性能和拟合能力上。

(1) Sig-K 核函数特性分析

多层感知核函数:

$$K(x, x_i) = \tanh[v(x^T x_i) + \gamma] \quad (11)$$




图3 Sig-K 核函数曲线图

Fig. 3 Sigmoid kernel function graph

图3中, x 为测试输入, $x' = 0$ 为测试点,核参数: $\gamma = -1$, v 分别取 0.1、0.2、0.3、0.4; 得到四条曲线。图中可以看出,核函数值的变化满足全局性,相距很远的数据点对核函数的值有较大的影响。

当 $v > 0, r < 0$ 时, Sig-K 核是全局核函数,且从模型上看出是基于内积的核函数。

(2) RBF-K 核函数特性分析

RBF 核函数:

$$K(x, x_i) = \exp\left\{-\frac{\|x - x_i\|^2}{2\sigma^2}\right\} \quad (12)$$

图4中, x 为测试输入, $x = 0$ 为测试点,核参数: σ 分别取 0.2、0.59、1、2。图中可以看出,当 x 点在测试点附近时,核函数的值有明显变化,在远离测试点的时候,核函数值的变化值 Δk 是呈收敛趋势,即满足局部性,仅相距很近的数据点对核函数的值有较大的影响。

RBF-K 核是局部核函数,且从模型上看出是基于距离的核函数。




图4 RBF-K 核函数曲线图

Fig. 4 RBF kernel function graph

(3) 凸组合核函数特性分析

RBF 核和 Sigmoid 核的凸组合核函数:

$$\begin{cases} K(x, x_i) = \lambda_1 \exp\left\{-\frac{\|x - x_i\|^2}{2\sigma^2}\right\} + \lambda_2 \tanh[v(x^T x_i) + \gamma] \\ \text{s. t. } \lambda_1 + \lambda_2 = 1, 0 < \lambda_1, \lambda_2 < 1 \end{cases} \quad (13)$$




图5 RBF-K 核和 Sig-K 核的凸组合曲线图

Fig. 5 Convex combination of RBF and Sigmoid kernel function graph

图5中, x 为测试输入, $x = 0$ 为测试点,核参数: $v = 0.3$; $\gamma = -1$; $\sigma = 2$; 权参数: $\lambda_1 = [0.1, 0.2, 0.3, 0.5]$, data1 为 $\lambda_1 = 0.1$ 的曲线,以此类推。图中可以看出, x 点无论是远离测试点还是在附近,核函数的值都有明显变化。

凸组合核函数同时兼有局部和全局特性。

3.2 SVM_CCK 分类效果

在本文仿真实验中,航空高光谱图像选用 AVIRIS 获取的美国圣地亚哥某机场图像,其覆盖波长范围为 $0.4 \sim 2.5 \mu\text{m}$,空间分辨率为 $3.5 \text{ m}^{[10-11]}$ 。去掉水汽吸收与噪声较严重的波段,选取 189 个波段作为研究对象,总像素为 $60 \times 70 \times 189$ 。训练样本:飞机为 20×189 个样本,跑道: 56×189 个样本,荒地: 56×189 个样本。

参数设置:选定惩罚因子 $c = 160$;核参数: $v = 0.005$, $\gamma = -1$, $\sigma = 2$ 。实验 1 到实验 5 权参数 λ_1 、 λ_2 分别取不同的值进行对比分析权参数的调节对分类效果的影响。

图 6 为美国圣地亚哥某机场高光谱图像。图 7~图 11 为权重不同的凸组合 SVM 分类效果图。对应的图(a)为对飞机分类实验结果,图(b)为对跑道分类实验结果,图(c)为对荒地分类实验结果^[12]。



图 6 美国圣地亚哥某机场高光谱图像

Fig. 6 An airport hyperspectral image in San Diego

实验 1: 权参数 $\lambda_1 = 1, \lambda_2 = 0$




图 7 凸组合(RBF-K)分类效果图

Fig. 7 The Convex combination kernel function (actually RBF kernel) Categories renderings

实验 2: 权参数 $\lambda_1 = 0, \lambda_2 = 1$




图 8 凸组合(Sig-K)分类效果图

Fig. 8 The Convex combination kernel function (actually sigmoid kernel) Categories renderings

实验 1 实际上是单核 RBF-K SVM 对美国圣地亚哥某机场的分类情况;实验 2 实际上是单核 Sig-K SVM 对美国圣地亚哥某机场的分类情况。图 7 和图 8 进行对比,可以看出,单核 RBF-K SVM 比单核 Sig-K SVM 的分类效果好。

实验 3: 权参数 $\lambda_1 = 0.5, \lambda_2 = 0.5$




图 9 凸组合分类效果图

Fig. 9 The Convex combination kernel function Categories renderings

实验 3 是 RBF-K 和 Sig-K 权重各半的凸组合 SVM 对美国圣地亚哥某机场的分类情况,图 9 对比图 7、8 可以看出,飞机、跑道、荒地的分类都有明显的改善,总体分类效果优于单核。

实验 4: 权参数 $\lambda_1 = 0.8, \lambda_2 = 0.2$




图 10 凸组合分类效果图

Fig. 10 The Convex combination kernel function Categories renderings

实验 5: 权参数 $\lambda_1 = 0.3, \lambda_2 = 0.7$




图 11 凸组合分类效果图

Fig. 11 The Convex combination kernel function Categories renderings

实验 4 是增加 RBF-K 的权重的凸组合 SVM 对美国圣地亚哥某机场的分类情况,结合图 10 和表 1 可以看出,相比于 $\lambda_1 = 0.5, \lambda_2 = 0.5$,分类精度减小,分类错误增加,KAPPA 值减小,分类效果稍微变差。

实验 5 是增加 Sig-K 核的权重的凸组合 SVM 对美国圣地亚哥某机场的分类情况,结合图 11 和表 1 可以看出,相比于 $\lambda_1 = 0.5, \lambda_2 = 0.5$ 时,分类精度增加,分类错误减小,KAPPA 值增大,分类效果稍微变好。

具体分类精度、分类错误统计如表 1 所示。

实验 6 是凸组合核函数的鲁棒性分析。针对不同的核参数将 SVM_CCK 与 RBF-K SVM、Sig-K SVM 分类性能对比,讨论 SVM_CCK 对核参数变化的抗影响能力(限于篇幅,这里只讨论 RBF-K SVM 的参数 σ 和 Sig-K SVM 的一个参数 γ)。SVM_CCK 权参数为: $\lambda_1 = 0.3$, $\lambda_2 = 0.7$ 。

1) σ 对 SVM_CCK 和 RBF-K SVM 的影响




图 12 SVM_CCK 和 RBF-K SVM 分类效果对比图

Fig. 12 Classification results comparison between SVM_CCK and RBF Kernel SVM




图 13 SVM_CCK 和 RBF-K SVM 分类效果对比图

Fig. 13 Classification results comparison between SVM_CCK and RBF kernel SVM

图 12、图 13 保持 Sig-K SVM 核参数不变,改变 σ 值。一方面,横向比较,对于相同的 σ 值,组合核分类效果较单核更胜一筹;另一方面,纵向比较,由表 2 可以看出,当减小 σ 的值时,RBF-K SVM 分类精度减小,错误分类加大,KAPPA 值减小,分类效果急剧下降,而 SVM_CCK 算法增加了小飞机旁边的异质点,虽然分类精度和错误分类及 KAPPA 值也有微小变化,但效果比 RBF-K SVM 分类效果要好很多。说明 SVM_CCK 较 RBF-K SVM 有较好的鲁棒性,始终保持了良好的分类特性。

2) γ 对 SVM_CCK 和 Sig-K SVM 的影响




图 14 SVM_CCK 和 Sig-K SVM 分类效果对比图

Fig. 14 Classification results comparison between SVM_CCK and sigmoid kernel SVM




图 15 SVM_CCK 和 Sig-K SVM 分类效果对比图

Fig. 15 Classification results comparison between SVM_CCK and sigmoid kernel SVM

图 14 和图 15 保持 RBF-K SVM 核参数不变,改变 γ 值。一方面,横向比较,相同 γ 值,组合核分类效果较单核更胜一筹;另一方面,纵向比较,由表 2 可以看出,当减小 γ 的值时,Sig-K SVM 分类精度减小,错误分类加大,KAPPA 值减小,且变化值较大,分类效果随之变差;而 SVM_CCK 算法的相应指标变化较小,甚至变好,说明 SVM_CCK 较 Sig-K SVM 有较好的鲁棒性,保持了良好的分类特性。

3.3 分类结果评估

将分类结果与标准样本进行对比计算分类精度、分类错误和 KAPPA 值^[13](见表 1、表 2),结合实验图得出以下结论:

①凸组合后,KAPPA 值增加,SVM_CCK 要比单核 SVM 分类精度高。

②由表 1 可以看出随着权重 λ_1 减小,权重 λ_2 增加,SVM_CCK 分类精度逐渐增加,但取极值 $\lambda_1 = 0$, $\lambda_2 = 1$ 时效果变差,说明凸组合中适当增加 Sig-K

的权重更具有优越性。

③由表2可以看出,RBF-K SVM 和 Sig-K SVM 分类效果对核参数变化敏感,随着参数 σ 和参数 γ

的减小,分类效果急剧下降,而 SVM_CCK 对核参数变化不敏感,分类效果甚至更好,说明 SVM_CCK 算法具有很好的鲁棒性。

表1 实验1~实验5中不同核函数 SVM 实验数据统计表

Tab.1 Different kernel function SVM experimental data tables from experiment 1 to experiment 5

核函数		分类精度					分类错误					KAPPA
		飞机	跑道	荒地	平均	总	飞机	跑道	荒地	平均	总	
RBF-K		0.5040	0.6377	0.8402	0.6606	0.6842	0	0	0	0	0	0.6126
Sig-K		0.6080	0.7814	0.9467	0.7787	0.8080	0.0080	0.1228	0.0615	0.0641	0.0811	0.7213
凸组合	$\lambda_1 = 0.5, \lambda_2 = 0.5$	0.5600	0.9281	0.9713	0.8198	0.8777	0.0080	0.0240	0	0.0107	0.0128	0.8184
	$\lambda_1 = 0.8, \lambda_2 = 0.2$	0.7520	0.7725	0.9221	0.8155	0.8208	0.0320	0.0030	0	0.0117	0.0071	0.7583
	$\lambda_1 = 0.3, \lambda_2 = 0.7$	0.8560	0.8772	0.9754	0.9029	0.9075	0.0880	0.0180	0	0.0353	0.0242	0.8627

表2 实验6中 SVM_CCK 鲁棒性验证

Tab.2 SVM_CCK 's robustness verification in experiment 6

核函数	参数选择			分类精度		分类错误		KAPPA
	σ	γ	v	平均	总	平均	总	
Sig-K	*	-1	0.005	0.7787	0.8080	0.0641	0.0811	0.7213
	*	-0.5	0.005	0.7348	0.7169	0.4585	0.4893	0.3994
	*	-0.2	0.005	0.7463	0.7525	0.5662	0.4253	0.5204
SVM_CCK	2	-1	0.005	0.9029	0.9075	0.0353	0.0242	0.8627
	2	-0.5	0.005	0.8903	0.9147	0.0110	0.0085	0.8723
	2	-0.2	0.005	0.9497	0.9474	0.1420	0.0782	0.9147
	1	-1	0.005	0.9069	0.9018	0.0903	0.0526	0.8525
	0.59	-1	0.005	0.8538	0.8791	0.2293	0.1294	0.8065
RBF-K	2	*	*	0.6606	0.6842	0	0	0.6126
	1	*	*	0.3308	0.3428	0	0	0.3076
	0.59	*	*	0.1136	0.1010	0	0	0.0979

4 结 论

本文提出一种将 RBF-K 和 Sig-K 凸组合的复合核函数支持向量机(SVM_CCK),由权系数控制各自权重,应用于高光谱图像分类中,将分类效果与各自单核做比较,得出其分类性能优于单核,且能够兼顾两核函数。最后讨论了核参数对凸组合核函数 SVM 分类的影响,证明了复合核函数具有良好的鲁棒性。当然,虽然 SVM_CCK 在高光谱图像的分类中取得了较好的分类效果,但下一步仍存在一些亟待解决难题:目前对 SVM 的核函数及其核参数、权参数的选择仍缺乏统一的理论指导^[14];易出现构造的混合核函数比单一的核函数的性能差的情形。本文是依赖于一定的先验知识,凭借经验、实验对比、大范围搜索、交叉验证的方法来构造复合核函数的。

参考文献:

- [1] ZHANG Bing, GAO Lianru. Hyperspectral image classification and target detection [M]. Beijing: Science Press, 2012. (in Chinese)
张兵,高连如. 高光谱图像分类与目标探测[M]. 北京:科学出版社,2012.
- [2] DU Peijun, TAN Kun, XIA Junshi. Hyperspectral remote sensing image classification and support vector machine research [M]. Beijing: Science Press, 2012. (in Chinese)
杜培军,谭琨,夏俊士. 高光谱遥感影像分类与支持向量机应用研究[M]. 北京:科学出版社,2012.
- [3] Fang Leyuan, Li Shutao, et al. Classification of Hyperspectral Images by Exploiting Spectral Spatial Information of Super-pixel via Multiple K-ernels [J]. IEEE Trans -

- actions on Geoscience and Remote Sensing, 2015, 53 (12):6663 – 6674.
- [4] Li Jiayi, Zhang Hongyan, Zhang Liangpei. A nonlinear multiple feature learn-ing classifier for hyperspectral images with limited training samples[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2015, 8:1 – 11.
- [5] Abe, Bolanle Tolulope. Hyperspectral data classification based on local polynomial approximation [C]. ICPRAM 2015 – 4th. International Conference on Pattern Recognition Applications and Methods. 2015, 1:380 – 385.
- [6] Cortes C, Vapnik VN. Support vector networks [J]. Machine Learning, 1995, 20:273 – 297.
- [7] Bernabe, Sergio, Marpu, et al. . Spectral spatial classification of multispectral images using kernel feature space representation[J]. IEEE Geoscience and Remote Sensing Letters, 2014:288 – 292.
- [8] Bahria S, Essoussi N, Limam M. Hyperspectral data classification using geostatistics and support vector machines [J]. Remote Sensing Letters, 2011, 2(2):99 – 106.
- [9] Roli F, Fumera G. Support vector machines for remote – sensing image classification [J]. Proc. SPIE, 2001, 3584: 221 – 232.
- [10] TANG Xiaoyan, GAO Kun, et al. Nonlinear hyperspectral unmixing algorithm based on the optimal endmember subset [J]. Laser & Infrared, 2014, 44(9):1050 – 1054. (in Chinese)
- 唐晓燕, 高昆, 等. 基于端元优化的非线性高光谱分解算法[J]. 激光与红外, 2014, 44(9):1050 – 1054.
- [11] Fassnacht FE, Neumann C, et al. With hyper-spectral data on three central european test sites [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2014, 7(6):2547 – 2561.
- [12] Abdel-Rahman EM, Mutanga O, et al. Detect-ing Sirex noctilio grey-attacked and lightning-struck pine trees using airborne hyperspectral data, random forest and support vector machines classifiers [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2014, 88: 48 – 59.
- [13] HE Zijian, SHI Jiaming, WANG Jiachun, et al. Recognition of camouflaged target bu hyperspectral imaging system based on acousto-optic tunable filter[J]. Laser & Infrared, 2014, 44(7):796 – 800. (in Chinese)
- 何梓健, 时家明, 汪家春, 等. AOTF 高光谱探测系统对伪装目标的识别研究[J]. 激光与红外, 2014, 44(7): 796 – 800.
- [14] GAO Xiaojian, GUO Baofeng, YU Ping. Classification of hyperspectral remote sensing image based on spatial – spectral integration[J]. Laser & Infrared, 2013, 43(11): 1296 – 1300. (in Chinese)
- 高晓键, 郭宝峰, 于平. 高光谱空谱一体化图像分类研究[J]. 激光与红外, 2013, 43(11):1296 – 1300.