

文章编号: 1007-4619(2008) 04-0579-07

基于核 Fisher 判别分析的高光谱遥感影像分类

杨国鹏,余旭初,陈 伟,刘 伟

(信息工程大学 测绘学院遥感信息工程系,河南 郑州 450052)

摘 要: 高光谱遥感技术,将反映目标辐射特性的光谱信息与反映目标空间位置关系的图像信息有机地结合在一起。高光谱影像具有丰富的光谱信息,较全色、多光谱影像能够更好的进行地面目标的分类识别。在介绍核 Fisher 判别分析算法的基础上,选用径向基核函数,使用一对一或一对余构造多类构造法,并利用交叉验证网格搜索法优化核函数参数,构建了快速稳定的多类核 Fisher 判别分析分类器。通过 OMIS 和 AVIRIS 影像的分类实验,表明了核 Fisher 判别分析与支持向量机的分类精度相当,但是所需的训练时间较短。

关键词: 高光谱遥感; 分类; 核 Fisher 判别分析; 核函数

中图分类号: TP751.1 **文献标识码:** A

1 引 言

20 世纪 80 年代初期出现的高光谱遥感技术,将反映目标辐射特性的光谱信息与反映目标空间位置关系的图像信息有机地结合在一起,续写和完善了光学遥感影像从黑白全色影像通过多光谱到高光谱的全部影像信息链^[1]。由于高光谱影像在光谱分辨率方面具有巨大优势,使得对地观测时可获取众多连续波段的地物光谱图像,从而能够达到直接识别地球表面物质的目的。高光谱遥感正由航空遥感为主转向航空和航天遥感相结合的阶段,成为地图制图、植被调查、海洋遥感、农业遥感、大气研究、环境监测等领域的有效技术手段^[1]。

高光谱影像为地物分类识别带来巨大机遇,也向传统的影像分类方法提出了挑战。统计模式识别与神经网络方法基于大数定理,由于高光谱影像包含的地面细节信息极其丰富,往往无法获得足够数量的训练样本点,影响各类别先验知识的估计,并且高光谱影像特征维数很高,分类时存在维数灾难。

最近几年,随着支持向量机 (SVM) 在各领域中的成功应用,通过核映射方法,使得经典的模式线

性方法能够处理非线性问题,这被称为第三次模式分析方法变革^[2]。

在核方法的一般过程中,首先将算法程序调整为输入向量之间的内积形式,然后用核函数计算特征空间的两个输入之间的映像的内积,从而使得在高维空间实现这一算法成为可能。

核方法分为核函数设计和算法设计两个部分,具体情况如图 1 所示。核方法的实施步骤,具体描述为: ① 收集和整理样本,并进行标准化; ② 选择或构造核函数; ③ 用核函数将样本变换成为核矩阵; ④ 在特征空间对核矩阵实施各种线性算法; ⑤ 得到输入空间中的非线性模型。

```
graph LR
    Data[数据] --> Kfn[核函数]
    Kfn --> Kmat[核矩]
    Kmat --> MA[模式分析]
    MA --> MF[模式函数]
    Data --> MF
```

图 1 核方法的一般步骤

Fig 1 The general process of kernel method

在核方法中,输入空间维数对核矩阵无影响,因此,核函数方法可以有效处理高维输入,避免了传统模式分析方法遇到的“维数灾难”。核函数的

收稿日期: 2007-02-08 修订日期: 2007-06-01
基金项目: 国家高技术研究发展计划 (2006AA7013 09)。

作者简介: 杨国鹏, (1982—), 男, 山东省聊城人。2007 年获信息工程大学测绘学院模式识别与智能系统专业工学硕士学位, 现为信息工程大学测绘学院摄影测量与遥感博士研究生。研究方向包括图像处理与模式识别、高光谱遥感技术, 已发表论文 5 篇。Email: magen@yahoo.com, yangguopeng@hotmail.com

(C)1994-2020 China Academic Journal Electronic Publishing House. All rights reserved. http://www.cnki.net

形式和参数的变化会隐式地改变从输入空间到特征空间的映射,进而对特征空间的性质产生影响,最终改变各种核函数方法的性能,无需求解非线性变换映射的具体形式和参数,减小算法的复杂度。核方法与不同分析算法相结合,形成不同的基于核函数的算法,且这两部分可以单独设计。

Gualtieri^[3]等利用基于核方法的非线性 SVM 进行高光谱影像分类,有效的避免了 Hughes 现象,提高了分类精度。夏建涛^[4]通过高光谱影像 SVM 分类实验指出,核函数参数和样本数量对 SVM 的分类性能影响较大。

文献[5—7]将核技术应用于经典的 Fisher 线性判别分析,提出了核 Fisher 判别分析方法。本文在介绍核 Fisher 判别分析算法的基础上,对其核函数及参数选择、多类分类构造进行了研究。本文将其应用于高光谱遥感影像分类,并与常用分类方法进行了比较。

2 核 Fisher 判别分类方法

2.1 线性 Fisher 判别分析

对于两类问题,设待分类的样本有 n 个: $x_1, x_2, \dots, x_n \in R^d$ 。在进行 Fisher 判别分析时,目标是找到线性投影方向(投影轴),使得训练样本在这些轴上的投影结果类内散度最小,类间散度最大。

设样本类内均值为 m_i , 则

$$m_i = \frac{1}{n_i} \sum_{x \in \omega_i} x, \quad i=1, 2 \quad (1)$$

设样本类间离散度矩阵为 S_b , 则

$$S_b = \sum_{i=1}^2 \sum_{x \in \omega_i} (x - m_i)(x - m_i)^T \quad (2)$$

设样本类内离散度矩阵为 S_w , 则

$$S_w = (m_1 - m_2)(m_1 - m_2)^T \quad (3)$$

最佳投影方向是通过最大化目标函数 $J(w)$

$$J(w) = \frac{w^T S_b w}{w^T S_w w} \quad (4)$$

式中, w 就是投影方向。

考虑到(4)式的尺度不变性,令分母为非零常数,用 Lagrange 乘子法求解得到下面的特征值问题:

$$S_b w^* = \lambda S_w w^* \quad (5)$$

式中, w^* 就是(4)式中的极值解,也就是矩阵 $S_w^{-1} S_b$ 的最大特征值对应的特征向量。测试样本在这个向量上的投影系数就是所提取的测试样本的特

征值。

则 FDA 的判别函数为

$$f(x) = w^* x + b \quad (6)$$

b 为偏移量,可以通过求解以下方程得到

$$w^* m_1 + b = -(w^* m_2 + b) \quad (7)$$

则对于一待测样本 x_j 求 Fisher 判别分析判别函数

$$f(x_j) = w^* x_j + b \text{ 通过 } f(x_j) \text{ 正负确定其归属。}$$

2.2 核 Fisher 判别分析

KFDA 算法的思想是:首先通过一个非线性映射,将输入数据映射到一个高维的线性可分的特征空间中,然后在这个特征空间中进行线性 Fisher 判别分析,从而实现相对于输入空间的非线性判别分析。

在进行 KFDA 时,首先通过非线性映射 ϕ 将输入数据映射到一个高维特征空间中,即

$$\phi: R^d \rightarrow F, \quad x \mapsto \phi(x)$$

这时,输入训练样本由原来的 x 变为 $\phi(x)$, 然后在这个特征空间 F 中进行线性 FDA。问题转变为在 F 中最大化目标函数 $J(w)$

$$J(w) = \frac{(w^\phi)^T S_b^\phi w^\phi}{(w^\phi)^T S_w^\phi w^\phi} \quad (8)$$

式中, $\omega \in F$, S_b^ϕ , S_w^ϕ 是 F 中相应的矩阵,分别为

$$S_b^\phi = (m_1^\phi - m_2^\phi)(m_1^\phi - m_2^\phi)^T \quad (9)$$

$$S_w^\phi = \sum_{i=1}^2 \sum_{x \in \omega_i} (\phi(x) - m_i^\phi)(\phi(x) - m_i^\phi)^T \quad (10)$$

$$m_i^\phi = \frac{1}{n_i} \sum_{j=1}^{n_i} \phi(x_j^i) \quad (11)$$

由于 F 空间的维数通常很高甚至是无穷维,因此(8)式直接求解很困难。借用非线性支持向量机的核方法,引入以下内积核函数^[2]

$$k(x_i, x_j) = k_{ij} = \phi^T(x_i) \phi(x_j) \quad (12)$$

来隐含地进行运算,定义核矩阵 K 为

$$K = [K_1 \quad K_2] \quad (13)$$

式中, $(K_i)_{pj} = k(x_j^i, x_j^i)$, $p=1, 2, \dots, n_i$ 是 $n \times n_i$ 矩阵 ($i=1, 2$), 是全体样本分别与类 1、类 2 的内积核矩阵。

由再生核理论可知^[2], F 空间的任何解 w^ϕ 都是 F 空间中的训练样本的线性组合,即:

$$w^T m_i^\phi = \frac{1}{n_i} \sum_{j=1}^{n_i} \sum_{k=1}^{n_i} \alpha_j k(x_j^i, x_k^i) = \alpha^T M_i \quad (14)$$

式中, $(M_i)_j = \frac{1}{n_i} \sum_{k=1}^{n_i} k(x_j^i, x_k^i)$, 是第 i 类各个样本

与总体的内积核的均值。由 (9) 和 (11) 式, 结合 (14) 式, 可将 (8) 式的分子写成:

$$w^T S_b w = \alpha^T M \alpha \quad (15)$$

其中

$$M = (M_1 - M_2)(M_1 - M_2)^T \quad (16)$$

由 (10) 和 (14) 式可将 (8) 式分母变换为:

$$w^T S_w w = \alpha^T N \alpha$$

其中

$$N = \sum_{i=1}^2 K_i(I - Y_i)K_i^T \quad (17)$$

式中, I 是 n 阶单位矩阵, Y_i 是全部元素为 $\frac{1}{n}$ 的 n 阶方阵。

在 F 空间中, 求解 Fisher 线性判别函数:

$$\max_{\alpha} J(\alpha) = \frac{\alpha^T M \alpha}{\alpha^T N \alpha} \quad (18)$$

该判别函数隐式地对应原空间的一个非线性判别函数, 因此, 它是一种非线性方法。求解矩阵 $N^{-1}M$ 的最大特征值对应的特征向量就可求得上式的最优解。

测试数据在特征向量 w^* 上的投影为

$$(w^* \cdot \phi(x)) = \sum_{i=1}^n \alpha_i k(x_i, x) \quad (19)$$

在实际应用中为了防止 N 非正定, 使解更稳定, 通常引入一个正则化参数 λ , 令 $N_{\lambda} = N + \lambda I$, I 是单位矩阵。则判别函数可以写为:

$$f(x) = (w^* \cdot \phi(x)) + b \\ = \sum_{i=1}^n \alpha_i k(x_i, x) + b \quad (20)$$

式中, b 可以通过求解具有 L_1 软边界的一维线性支持向量机 (SVM) 来确定。

2.3 KFDA 分类过程

核 Fisher 判别分析分类属于监督分类, 需要先利用训练样本进行训练, 然后将测试样本输入进行分类。具体步骤如下:

(1) 初始化算法参数, 选择核函数 $k(x, y)$ 及其参数, 正则化参数 λ 及一维线性支持向量机的惩罚系数 C

(2) 利用核函数 (12) 式求出核矩阵 (13) 式, 按照 (16) 式计算 M 按照 (17) 式计算 N

(3) 利用正则化参数 λ 求出正则化后的 N_{λ} , $N_{\lambda} = N + \lambda I$

(4) 利用 Lagrange 乘子法解优化问题 (18) 式, 求解出 α ;

(5) 将训练样本数据按照 (19) 式投影到一维空间;

(6) 利用 L_1 软边界的一维线性 SVM 求解判别函数中偏移量 b

(7) 按照式 (20) 对测试样本依次判别。

2.4 核函数与参数的选择

根据核函数理论, 只要一种核函数 $k(x, y)$ 满足 Mercer 条件, 它就对应某一空间中的内积核函数、映射函数及特征空间。核参数的改变实际上是隐含地改变映射函数, 从而改变样本数据子空间分布的复杂程度。常用的核函数有以下 3 种:

(1) d 阶多项式核函数

$k(x, y) = [(x \times y) + 1]^d$, d 为自定义参数; 若 $d=0$ 且 $d=1$ 称为线性核函数。

(2) 径向基核函数

$$k(x, y) = \exp\left(-\frac{\|x - y\|^2}{\sigma^2}\right), \text{ 参数 } \sigma^2 > 0$$

(3) 神经网络核函数

$$k(x, y) = \tanh(\mu(x \times y) + \nu), \mu, \nu \text{ 为参数。}$$

与多项式核函数及 RBF 核函数不同, 神经网络核函数只对参数 (μ, ν) 某些取值满足 Mercer 条件。

KFDA 分类中, 核函数的参数及一维线性 SVM 的惩罚系数的选择, 可以参照 SVM 分类中的核函数参数与惩罚系数的优化方法, 有网格搜索法、梯度下降法、进化方法和模拟退火算法。

2.5 多类 KFDA 分类

KFDA 与 SVM 一样都是二值分类器, SVM 多类分类构造取得了进展, KFDA 可以参照 SVM 多类分类的构造方法。

解决多类分类问题, 根据其指导思想大致有两种: 一是, 通过将原始最优化问题适当改变, 使得它能同时计算出多类分类决策函数, 从而“一次性”地实现多类分类; 二是, 将多类问题分解为一系列可直接求解的两类问题, 基于这一系列两类问题求解结果得出最终判别结果。

第一种指导思想看起来简单, 但由于它的最优化问题求解过程太复杂, 计算量太大, 实现起来比较困难, 因此未被广泛应用。基于第二种指导思想的多类分类方法主要有 5 种: 一对余法、一对一法、二叉树法、纠错输出编码 (ECCO) 法和有向无环图法。

3 高光谱影像分类实验

3.1 实验一

实验数据:采用中国科学院上海技术物理研究所研制的 OMIS 成像光谱仪获取的江苏太湖沿岸的影像,光谱覆盖范围 $0.46\text{--}12.85\mu\text{m}$ 共 128 波段,影像大小 347×513 实验中使用受噪声影响比较小的 6—64 113—128 共 75 个波段。通过对影像目视判读,主要存在 7 类地物:房屋、道路、树木、水体、农作物和土壤。训练样本的采集情况如图 2 其对应的地物名称与数量见表 1。




图 2 该 OMIS 影像训练样本采集情况
Fig 2 The distribution of training samples in the OMIS image

表 1 该 OMIS 数据样本采集数量
Table 1 The training samples of the OMIS image

类别	1	2	3	4	5	6	7
名称	植被一	道路	植被二	屋顶	土壤	农作物	水域
数量	235	225	220	234	188	222	241

实验中,将各类样本按数量随机等分成两部分作为训练、测试样本。选用 RBF-SVM, 初始化 $C_0 = 10^3$, $\sigma_0^2 = 10^7$, 将参数空间按对数离散化网格点 ($\log \sigma^2$, $\log C$), $\log C \in \{\log C_0 - 4, \log C_0 - 3 \dots, \log C_0 + 4\}$, $\log \sigma^2 \in \{\log \sigma_0^2 - 4, \log \sigma_0^2 - 3 \dots, \log \sigma_0^2 + 4\}$ 。




图 3 该 OMIS 影像 OAR-RBF-KFDA 交叉验证等值线
Fig 3 The cross validation isoline of the OMIS image based on OAR-RBF-KFDA

若选用 RBF-KFDA—对余构造法,采用 2 交叉验证网格搜索法,图 3 为 OAR-RBF-KFDA 交叉验证等值线,选取的最优参数为 $C = 10^7$, $\sigma^2 = 10^7$, 此时分类结果如图 4。




图 4 该 OMIS 影像 OAR-RBF-KFDA 分类
Fig 4 The classification result of the OMIS image based on OAR-RBF-KFDA

使用不同方法进行分类比较,见表 2 其中 SVM

与 KFDA使用径向基核函数, 经过交叉验证网格搜索确定其参数值。

表 2 该 OMIS 影像不同方法的分类精度与速度
Table 2 The classification accuracy and speed of the OMIS image based on different methods

分类器		错误率 /%	耗时 / s
最小距离分类		10.2	0.23
线性判别分类		1.41	0.35
决策树分类		4.61	0.47
OAR-SVM	$\sigma^2=10^9, C=10^6$	0.26	2266
OAO-SVM	$\sigma^2=10^7, C=10^5$	0.64	8.87
OAR-KFDA	$\sigma^2=10^7, C=10^7$	0.64	5.45
OAO-KFDA	$\sigma^2=10^3, C=10$	0.38	1.85

3.2 实验二

采用美国国家航空航天局 (NASA) 的机载可见 / 红外成像光谱仪 (AVIRIS) 获取佛罗里达州肯尼迪空间中心 (KSC) 1996 年 3 月 23 日的影像^[8], 可从 www.csr.utexas.edu/hyperspectral/data/KSC 下载。AVIRIS 将 0.4—2.45 μm 波段范围内划分出 224 个区段, 有着 10 nm 的光谱分辨率, 从海拔 20 km 左右获得, 地面分辨率为 18 m, 去除大气水分吸收及低信噪比波段后共 155 波段。样本采集参照肯尼迪空间中心地面覆盖图与 Landsat 专题制图仪 (TM) 影像。样本采集情况如图 5 具体数量如表 3。

表 3 该 AVIRIS 数据样本采集数量
Table 3 The training samples of the AVIRIS image

1	scrub	761
2	Willow	243
3	CP Hammock	256
4	CP/Oak	252
5	Slash Pine	161
6	Oak/Broadleaf	229
7	Hardwood swamp	105
8	Grainoid marsh	431
9	Spartina marsh	520
10	Cattail Marsh	404
11	Saltmarsh	419
12	Mud flats	503
13	water	927




图 5 该 AVIRIS 数据样本采集情况

Fig 5 The distribution of training samples in the AVIRIS image

实验中每类提取 50 个样本作训练样本, 剩下的作为测试样本。实验中 KFDA 采用径向基核函数一对余多类构造方法, 仅通过网格搜索法设置参数为 $\sigma^2=2.5 \times 10^6, C=120$ 。OAO-RBF-KFDA 分类结果如图 6。




图 6 该 AVIRIS 数据 OAO-RBF-KFDA 分类结果

Fig 6 The classification result of the AVIRIS image based on OAR-RBF-KFDA

使用不同方法进行分类比较, 见表 4 其中 SVM 与 KFDA 使用径向基核函数, 经过交叉验证网格搜索确定其参数。

表 4 该 AVIRIS 影像不同方法的分类精度与速度
Table 4 The classification accuracy and speed of the AVIRIS image based on different methods

分类器	错误率 /%	耗时 /s
最小距离分类	32.3	0.16
线性判别分类	24.82	0.35
决策树分类	59.3	0.55
OAR-SVM $\sigma^2=2\times 10^{10}$, $C=10^6$	18.97	4259
OAO-SVM $\sigma^2=2\times 10^6$, $C=10^5$	20.63	19.62
OAR-KFDA $\sigma^2=2.5\times 10^6$, $C=120$	19.23	11.67
OAO-KFDA $\sigma^2=4\times 10^6$, $C=10^6$	21.2	2.23

通过两个实验可以看出,核 Fisher 判别分析与支持向量机分类精度相差不大;但由于 SVM 需要求解二次优化问题,因此在训练样本较多的情况下需要的训练时间较长,而 KFDA 只计算矩阵的特征向量,计算量小,在消耗时间上具有明显的优势。

4 结 论

本文介绍了核 Fisher 判别分析分类的统计原理及求解过程,参考 SVM 分类中核函数及参数选择方法、多类构造方法。论文采用径向基核函数,使用一对一或一对余方法构造多类分类器,使用交叉验证网格搜索法对参数进行优化选择,构建稳定高性能的 KFDA 分类器。

KFDA 采用核函数映射方法,受输入样本特征维数的影响较小,在处理高光谱影像时,能有效地避免 Hughes 现象;在选择合适参数情况下,其分类精度与 SVM 分类器相当。

KFDA 分类在训练过程中,无需像 SVM 一样计算复杂二次优化问题,算法复杂度低,运算时间短;尤其在 一对余多类分类器构造方法中, KFDA 与 SVM 相比,在计算时间上的优势更为明显。

与 SVM 分类相似, KFDA 的分类性能受核函数及参数影响很大,核函数参数在特定的范围内才能得到良好的分类精度,使用交叉验证网格搜索参数选择方法能够有效提高 KFDA 分类的稳定性。

参考文献 (References)

[1] Tong Q X, Zhang B, Zheng L F. Hyperspectral Remote Sensing Theory, Technology and Application [M]. Beijing: Higher Education Press, 2006. 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. 1]

[2] John Shawe-Taylor, Nello Cristianini. Kernel Methods for Pattern Analysis [M]. Cambridge University Press, 2004.

[3] Gualtieri J A. Comp R F Support Vector Machines for Hyperspectral Remote Sensing Classification [A]. The 27th AIPR Workshop, Advances in Computer Assisted Recognition [C]. Washington D C 1998.

[4] Xia J T. High Dimensional Multispectral Data Classification by Machine Learning [D]. Xi'an: Northwestern Polytechnical University, 2002. [夏建涛. 基于机器学习的高维多光谱数据分类 [D]. 西安: 西北工业大学, 2002]

[5] Baudat G, Anouar F. Generalized Discriminant Analysis Using a Kernel Approach [J]. Neural Computation, 2000, 12 (10): 2385—2404.

[6] Mika Sebastian, Ratsch Gunnar, Weston Jason. Fisher Discriminant Analysis with Kernels [A]. Hu Y H, Larsen J, Wilson E. Neural Networks for Signal Processing IX [C]. Piscataway, N.J.: IEEE Press, 1999.

[7] Gan J Y, Zhang Y W. Generalized Kernel Fisher Optimal Discriminant in Pattern Recognition [J]. Pattern Recognition and Artificial Intelligence, 2002, 15 (4): 429—433 [甘俊英, 张有为. 模式识别中广义核函数 Fisher 最佳鉴别 [J]. 模式识别与人工智能, 2002, 15 (4): 429—433]

[8] Han J, Chen Y, Crawford M, et al. Investigation of the Random Forest Framework for Classification of Hyperspectral Data [J]. IEEE Trans on Geoscience and Remote Sensing, accepted for publication.

Hyperspectral Remote Sensing Image Classification
Based on Kernel Fisher Discriminant Analysis

YANG Guo peng YU Xu chu CHEN Wei LU Wei

(Institute of Surveying and Mapping Information Engineering University Henan Zhengzhou 450052 China)

Abstract The hyperspectral remote sensing technology which appeared early in 1980s combines the radiation information which relates to the targets' attribute and the space information which relates to the targets' position and shape completing the information continuum of optics RS image from panchromatic image to hyperspectral via multispectral image. The spectrum information which is rich in the hyperspectral image compared with panchromatic remote sensing image and multispectral remote sensing image can be used to classify the ground target better. It has become an important technique of map cartography vegetation investigation ocean remote sensing agriculture remote sensing atmosphere research environment monitoring and military information acquiring.

As Support Vector Machine (SVM) was applied to machine learning fields successfully in recent years the classic linear pattern analysis algorithms which was called the 3rd revolution of pattern analysis algorithms can cope with the nonlinear problem. Some references applied the kernel methods to linear Fisher Discriminant Analysis (FDA), and put forward Kernel Fisher Discriminant Analysis (KFDA).

Firstly this paper introduced the classification method based on the kernel fisher discriminant analysis. For the binary problem the aim of FDA is to find out the linear Projection (Projection axes) on which the intra class scatter matrices of the training samples are maximized and scatter matrices of inter class are minimized. For KFDA the inputted data is mapped into a high dimensional feature space by a nonlinear mapping while linear FDA in the feature space will be performed.

Secondly we researched on the selection methods of the kernel function and its parameter and studied on the multi-classes classification methods and then applied them to hyperspectral remote sensing classification. We use decomposition methods of multi-class classifier and method of parameter selection using cross validating grid search to build an effective and robust KFDA classifier.

Finally we carried out the hyperspectral image classification experiments based on KFDA and some other comparative experiments. Some conclusions can be drew as follows:

Using the kernel mapping the KFDA experiment on HH1 and AVIRIS image demonstrates that the KFDA is less affected by the dimension of input sample and can avoid the Hughes Phenomena effectively. The results show that it has more comparable classification accuracy than support vector machine classifier.

There is no need to compute the complicated quadratic optimizing problem in training KFDA classifier as SVM classifier does so this algorithm is not very complicated and costs less time. Especially in the one against rest decomposition comparing with the SVM KFDA is much faster.

The capability of KFDA classifier is affected a lot by kernel function and its parameters and a fine recognition precision can only be obtained when the kernel function's parameters are appropriate. The stability of classification can be effectively improved by parameter selection via cross validate grid search method.

Key words hyperspectral remote sensing classification Kernel Fisher Discriminant Analysis kernel function