

# 基于鉴别流形正则化最小二乘分类的钴结壳超声识别

杨 勃<sup>1,2</sup>, 卜英勇<sup>2</sup>

(1. 湖南理工学院信息与通信工程学院, 湖南岳阳 414006; 2. 中南大学机电工程学院, 湖南长沙 410083)

**摘 要:** 为解决富含非线性流形特征的水下钴结壳超声识别问题, 尝试引入一类鉴别流形正则化最小二乘机 (Discriminatively Regularized Least-Squares Classifier, DRLSC). 首先分析了原始 DRLSC, 指出其对应优化问题的非凸性. 然后结合 Ho-Kashyap 分类器, 提出了具有凸性的 DRLSC 模型, 并给出了该模型的核化版本 (Kernel DRLSC, KDRLSC). 最后, 将该模型应用于水下钴结壳超声识别中. 实验结果表明, 采用本文的 KDRLSC 进一步提高了钴结壳的识别分类正确率.

**关键词:** 流形学习; 鉴别流形正则化最小二乘机; Ho-Kashyap 分类器; 钴结壳识别

**中图分类号:** TP391.4 **文献标识码:** A **文章编号:** 0372-2112 (2011) 02-0448-05

## Ultrasonic Recognition of Cobalt Crust Based on Discriminatively Regularized Least-squares Classification

YANG Bo<sup>1,2</sup>, BU Ying-yong<sup>2</sup>

(1. Department of Information and Communication Engineering, Hunan Institute of Science and Technology, Yueyang, Hunan 414006, China;

2. College of Mechanical and Electrical Engineering, South Central University, Changsha, Hunan 410083, China)

**Abstract:** The surface of cobalt crust contains plenty of nonlinear manifold features. In order to solve ultrasonic recognition of cobalt crust using its manifold features, a kind of Discriminatively Regularized Least-Squares Classifier (DRLSC) is introduced in this paper. At first, the fact is found that the original DRLSC is not of convexity in general. And then, based on Ho-Kashyap least-squares algorithm, a modified DRLSC which is of convexity and its kernelized edition (Kernel DRLSC, KDRLSC) are proposed. At last, the proposed classifier is used in ultrasonic recognition of cobalt crust. The experimental results show that the echo recognition correct rates of cobalt crust is improved using the proposed KDRLSC classifier.

**Key words:** manifold learning; DRLSC; Ho-Kashyap classifier; cobalt crust echo recognition

## 1 引言

超声探测是水下沉积物探测的一种常用方法. 由于沉积物近似线性平整, 因此采用线性方法能以一定精度实现沉积物识别, 如商用探测系统 QTC-VIEW<sup>[1]</sup> 采用 PCA 方法抽取沉积物回波线性特征, 进而实现沉积物的识别. 近年来, 在模式识别领域, 出现了一类以 SVM 为代表的非线性学习方法<sup>[2~4]</sup>, 在不同模式识别应用领域<sup>[5,6]</sup> 内取得了不错的非线性识别效果, 如在水下沉积物探测研究领域, 文献[7]采用 SVM 提高了水下沉积物超声识别分类正确率.

SVM 通过最大化分类间隔来保证分类器的泛化性能. 其它核学习方法<sup>[8]</sup> 也借鉴了该思想, 通过引入正则化分类间隔项来改善泛化性能. 引入该正则项可在最优训练效果和降低分类器光滑度之间取得均衡, 并降低期望错误率与经验错误率之间的方差. 随着流形学习<sup>[9,10]</sup>

方法的兴起, 有研究者<sup>[11,12]</sup> 提出用正则化鉴别流形项取代分类间隔项, 利用数据的局部鉴别流形信息对分类器进行局部微调, 进一步提高了分类器的分类效果.

与水下沉积物机理不同, 钴结壳为海底基岩上的生长物, 其表面往往呈现出非常丰富的非线性流形结构特征, 因此我们尝试将 DRLSC 方法引入到钴结壳超声识别中. 首先, 我们分析了文献[12]中的 DRLSC 模型, 指出其在一般情况下不是一个凸优化问题, 无法得到全局最优解. 然后结合 Ho-Kashya 分类器, 给出了一个改进的凸 DRLSC 模型, 并设计了相应的优化算法. 为实现非线性分类, 进一步给出了该模型的核版本: KDRLSC 模型. 最后, 通过钴结壳超声识别实验验证了本文提出的 KDRLSC 模型的有效性.

## 2 DRLSC 简介

流形学习是近几年出现的一种新的数据可视化方

法.通过流形学习方法,可由局部几何结构发现嵌入在高维数据空间中的低维光滑流形结构.为更好的完成识别分类任务,有研究者提出了引入类别信息的鉴别流形学习方法<sup>[13,14]</sup>.本文所采用的是基于谱图方法<sup>[14]</sup>的鉴别流形信息.

## 2.1 基于谱图方法的鉴别流形信息

设包含  $N$  个样本的  $c$  类别  $l$  维样本集为  $\{(\mathbf{x}_i, \omega_j) | \mathbf{x}_i \in R^{l \times 1}, 1 \leq j \leq c, 1 \leq i \leq N\}$ , 则第  $i$  个样本的  $k$  类内邻域图  $ne_w(i)$  和  $k$  类间邻域图  $ne_b(i)$  可分别定义为:

$$ne_w(i) = \{\mathbf{x}_j^b | \mathbf{x}_i, \mathbf{x}_j^b, \mathbf{x}_a \in \omega_m\},$$

$$dis(\mathbf{x}_i, \mathbf{x}_j^b) = \min_b(dis(\mathbf{x}_i, \mathbf{x}_a)), 1 \leq m \leq c, 1 \leq b \leq k\}$$

$$ne_b(i) = \{\mathbf{x}_j^b | \mathbf{x}_j^b, \mathbf{x}_a \in \omega_n, \mathbf{x}_i \in \omega_m, m \neq n\},$$

$$dis(\mathbf{x}_i, \mathbf{x}_j^b) = \min_b(dis(\mathbf{x}_i, \mathbf{x}_a)),$$

$$1 \leq m \leq c, 1 \leq n \leq c, 1 \leq b \leq k\}$$

其中,  $\min_b$  表示第  $b$  个最小值,  $dis(\mathbf{x}_i, \mathbf{x}_a)$  表示样本  $\mathbf{x}_i, \mathbf{x}_a$  之间的距离.由  $k$  邻域图出发,可以确定样本之间的类内和类间局部几何结构,然后可通过类内和类间权值矩阵  $\mathbf{W}_w, \mathbf{W}_b$  按邻域结构进行加权.其中最为简单的一种权值取值方式如下所示:

$$W_{w(ij)} = \begin{cases} 1, & \mathbf{x}_j \in ne_w(i) \text{ 或 } \mathbf{x}_i \in ne_w(j) \\ 0, & \text{其它情况} \end{cases} \quad (1)$$

$$W_{b(ij)} = \begin{cases} 1, & \mathbf{x}_j \in ne_b(i) \text{ 或 } \mathbf{x}_i \in ne_b(j) \\ 0, & \text{其它情况} \end{cases} \quad (2)$$

由  $k$  邻域图以及类内和类间加权矩阵  $\mathbf{W}_w, \mathbf{W}_b$  出发,进一步可以得到描述全局几何信息的类内和类间流形散布矩阵  $\mathbf{S}_w, \mathbf{S}_b$ , 其定义如下:

$$\mathbf{S}_w = \frac{1}{2} \sum_{j=1}^n \sum_{i=1}^n (\mathbf{x}_i - \mathbf{x}_j)(\mathbf{x}_i - \mathbf{x}_j)^T W_{w(ij)} = \mathbf{X} \mathbf{L}_w \mathbf{X}^T \quad (3)$$

$$\mathbf{S}_b = \frac{1}{2} \sum_{j=1}^n \sum_{i=1}^n (\mathbf{x}_i - \mathbf{x}_j)(\mathbf{x}_i - \mathbf{x}_j)^T W_{b(ij)} = \mathbf{X} \mathbf{L}_b \mathbf{X}^T \quad (4)$$

其中  $\mathbf{L}_b = \mathbf{D}_b - \mathbf{W}_b, \mathbf{L}_w = \mathbf{D}_w - \mathbf{W}_w; \mathbf{D}_b, \mathbf{D}_w$  分别为对角元素  $D_{b(i)} = \sum_{j=1}^n W_{b(ij)}, D_{w(i)} = \sum_{j=1}^n W_{w(ij)}$  的对角矩阵.

由矩阵  $\mathbf{S}_w, \mathbf{S}_b$  的定义易知,类内和类间流形散布矩阵  $\mathbf{S}_w, \mathbf{S}_b$  均为对称半正定方阵.

## 2.2 DRLSC 模型

文献[10]将上述鉴别流形信息与最小二乘分类器结合,得到了 DRLSC 分类器.对 2 类别  $l$  维样本集  $\{(\mathbf{x}_i, y_i) | y_i \in \{+1, -1\}, 1 \leq i \leq N\}$ , 其优化准则定义如下:

$$J(\mathbf{w}, b) = \min \frac{1}{2} \sum_{i=1}^N e_i^2 + \frac{1}{2} \mathbf{w}^T (\eta \mathbf{S}_w - (1 - \eta) \mathbf{S}_b) \mathbf{w}$$

$$\text{s.t. } \mathbf{w}^T \mathbf{x}_i + b + e_i = y_i \quad (5)$$

其中,  $e_i$  为第  $i$  个样本在投影矢量  $\mathbf{w}$  和偏置  $b$  下与类别值  $y_i$  之间的误差,  $\eta$  为一个预先设定的参数,满足  $0 \leq \eta$

$\leq 1$ .

该分类器在最小化误差  $\sum_{i=1}^N e_i^2$  的同时,还要求最小化类内散布  $\mathbf{w}^T \mathbf{S}_w \mathbf{w}$  且最大化类间散布  $\mathbf{w}^T \mathbf{S}_b \mathbf{w}$ . 引入局部信息  $\mathbf{S}_w, \mathbf{S}_b$ , 可在一定程度上优化局部分类间隔.

## 3 改进的 DRLSC 与 KDRLSC 模型

### 3.1 改进的 DRLSC 模型

我们注意到式(5)关于  $\mathbf{w}$  的二阶 hessen 矩阵为:

$$\frac{\partial^2 J}{\partial \mathbf{w}^2} = (\eta \mathbf{S}_w - (1 - \eta) \mathbf{S}_b) \quad (6)$$

而矩阵  $\eta \mathbf{S}_w - (1 - \eta) \mathbf{S}_b$  在一般情况下并不能保证半正定性,因此该准则在一般情况下并不是关于  $\mathbf{w}$  的凸优化准则.为保证该优化问题的凸性,要求参数  $\eta$  取值必须足够大,这意味着类内散布信息  $\mathbf{S}_w$  的权重要远大于类间散布信息  $\mathbf{S}_b$  的权重,导致无法充分利用类间散布信息.为此,我们将准则(5)中的正则化项重新表达为:

$$\mathbf{w}^T (\eta \mathbf{S}_w + (1 - \eta) (\mathbf{S}_b + c \mathbf{I})^{-1}) \mathbf{w} \quad (7)$$

其中,  $c$  为一个小扰动量,  $\mathbf{I}$  为一个单位矩阵.在这里我们引入该小扰动对角阵  $c \mathbf{I}$  以保证  $\mathbf{S}_b$  可逆.矩阵  $\eta \mathbf{S}_w + (1 - \eta) (\mathbf{S}_b + c \mathbf{I})^{-1}$  显然满足半正定性要求.

此外,作为优化主项的最小二乘分类器,其严格限制期望输出值为  $\pm 1$ .实际上,我们只需所有正例的输出值为正,而所有反例输出值为负即可.基于此思路,有研究者提出了引入间隙裕量的 Ho-Kashyap 算法<sup>[8]</sup>改进最小二乘分类器.本文借鉴该算法思想,提出一个改进的 DRLSC 分类器,其优化准则如下:

$$J(\mathbf{w}, b) = \min \frac{1}{2} \sum_{i=1}^N e_i^2 + \frac{1}{2} \mathbf{w}^T (\eta \mathbf{S}_w + (1 - \eta) \cdot (\mathbf{S}_b + c \mathbf{I})^{-1}) \mathbf{w}$$

$$\text{s.t. } \mathbf{w}^T (y_i \mathbf{x}_i) + (y_i b) + e_i - d_i = 1 \quad (8)$$

其中,  $d_i$  为第  $i$  个样本的间隙裕量,  $d_i \geq 0$ . 该准则对应的 Lagrangian 优化式为:

$$L(\mathbf{w}, b, \mathbf{e}, \boldsymbol{\lambda}) = \frac{1}{2} \|\mathbf{e}\|_2^2 + \frac{1}{2} \mathbf{w}^T (\eta \mathbf{S}_w + (1 - \eta) (\mathbf{S}_b + c \mathbf{I})^{-1}) \mathbf{w}$$

$$- \boldsymbol{\lambda}^T (\mathbf{X}^T \mathbf{w} + b \mathbf{y} - \mathbf{d} - \mathbf{g} + \mathbf{e}) \quad (9)$$

其中,  $\mathbf{e}, \mathbf{y}, \mathbf{d}$  为第  $i$  个元素值分别为  $e_i, y_i, d_i$  的  $N$  维向量,  $\mathbf{g}$  为元素值均为 1 的  $N$  维向量, 矩阵  $\mathbf{X}^T = (y_1 \mathbf{x}_1 \cdots y_N \mathbf{x}_N)$ .

对准则式(9)分别关于变元  $\mathbf{w}, b, \mathbf{e}, \boldsymbol{\lambda}$  求其一阶导数 0 点可整理得到如下线性方程组:

$$\begin{pmatrix} 0 & \mathbf{y}^T \\ \mathbf{y} \mathbf{X}^T (\eta \mathbf{S}_w + (1 - \eta) (\mathbf{S}_b + c \mathbf{I})^{-1})^{-1} \mathbf{X}^T + \mathbf{I} \end{pmatrix} \begin{pmatrix} b \\ \boldsymbol{\lambda} \end{pmatrix} = \begin{pmatrix} 0 \\ \mathbf{g} - \mathbf{d} \end{pmatrix} \quad (10)$$

由该线性方程组可求得在特定间隙裕量矢量  $\mathbf{d}$  下的最优 Lagrangian 乘子矢量  $\boldsymbol{\lambda}$  和最优偏置  $b$ . 进而可求得最优投影矢量  $\mathbf{w} = (\eta \mathbf{S}_w + (1 - \eta)(\mathbf{S}_b + c\mathbf{I})^{-1})^{-1} \mathbf{X}' \boldsymbol{\lambda}$ , 并进一步可求得误差  $\mathbf{e}$ . 与 Ho-Kashyap 算法类似, 我们由误差  $\mathbf{e}$  更新间隙裕量矢量  $\mathbf{d}$ , 其表达式为:

$$\mathbf{d} = \rho(|\mathbf{e}| + \mathbf{e}) \quad (11)$$

其中,  $\rho$  为学习率, 其取值范围为  $0 < \rho < 1$ . 此时, 可设计如下迭代算法实现寻优:

(1) 设置  $0 < \rho < 1, \epsilon > 0$ , 初始化  $\mathbf{d}(s) \geq 0$ , 初始迭代数  $s = 1$ ;

(2) 由式(10)和(11)计算  $\mathbf{d}(s)$  下的最优向量  $\mathbf{w}(s)$  和最优偏置  $b(s)$ ;

(3) 更新误差  $\mathbf{e}(s) = \mathbf{X}'^T \mathbf{w}(s) + b(s) \mathbf{y} - \mathbf{g} - \mathbf{d}(s)$ ;

(4) 更新间隙裕量  $\mathbf{d}(s+1) = \mathbf{d}(s) + \rho(|\mathbf{e}(s)| + \mathbf{e}(s)), s = s + 1$ ;

(5) 若  $\|\mathbf{d}(s) - \mathbf{d}(s-1)\|_2 \geq \epsilon$ , 则转步骤(2), 否则程序结束.

### 3.2 KDRLSC 模型

当 2 类别  $l$  维样本集为  $\{(\mathbf{x}_i, y_i) | y_i \in \{+1, -1\}, 1 \leq i \leq N\}$  通过内积核函数  $k(\mathbf{x}, \mathbf{z}) = \phi(\mathbf{x})^T \phi(\mathbf{z})$  隐式映射为核样本集  $\{(\phi(\mathbf{x}_i), y_i)\}$  时, KDRLSC 分类器优化准则变为:

$$J(\mathbf{w}, b) = \min \frac{1}{2} \sum_{i=1}^n e_i^2 + \frac{1}{2} \mathbf{w}^T (\eta \mathbf{S}_w^\phi + (1 - \eta) \cdot (\mathbf{S}_b^\phi + c\mathbf{I})^{-1}) \mathbf{w} \quad (12)$$

s. t.  $\mathbf{w}^T (y_i \phi(\mathbf{x}_i)) + (y_i b) + e_i - d_i = 1$

其中, 核样本的类内和类间流形散布矩阵分别为  $\mathbf{S}_w^\phi = \phi(\mathbf{X}) \mathbf{L}_w \phi(\mathbf{X})^T$ ,  $\mathbf{S}_b^\phi = \phi(\mathbf{X}) \mathbf{L}_b \phi(\mathbf{X})^T$ ,  $\phi(\mathbf{X}) = (\phi(\mathbf{x}_1) \cdots \phi(\mathbf{x}_N))$ . 此时最优投影矢量为:

$$\mathbf{w} = (\eta \mathbf{S}_w^\phi + (1 - \eta)(\mathbf{S}_b^\phi + c\mathbf{I})^{-1})^{-1} \phi(\mathbf{X}') \boldsymbol{\lambda} \quad (13)$$

$$\phi(\mathbf{X}') = (y_1 \phi(\mathbf{x}_1) \cdots y_N \phi(\mathbf{x}_N))$$

由式(13)可知, 投影矢量  $\mathbf{w}$  一定在由样本  $\{y_i \phi(\mathbf{x}_i)\}_{1 \leq i \leq N}$  线性张成的空间中:

$$\mathbf{w} = \phi(\mathbf{X}') \boldsymbol{\alpha} \quad (14)$$

将之代入到式(12)中, 则对于正则化子项  $\mathbf{w}^T \mathbf{S}_w^\phi \mathbf{w}$  有:

$$\mathbf{w}^T \mathbf{S}_w^\phi \mathbf{w} = \boldsymbol{\alpha}^T \mathbf{K}' \mathbf{L}_w \mathbf{K}'^T \boldsymbol{\alpha} \quad (15)$$

其中,  $\mathbf{K}' = \phi(\mathbf{X}')^T \phi(\mathbf{X})$ ,  $\phi(\mathbf{X}) = (\phi(\mathbf{x}_1) \cdots \phi(\mathbf{x}_N))$ .

依矩阵求逆引理<sup>[15]</sup>可推知, 对正则化子项  $\mathbf{w}^T (\mathbf{S}_b^\phi + c\mathbf{I})^{-1} \mathbf{w}$  有:

$$\mathbf{w}^T (\mathbf{S}_b^\phi + c\mathbf{I})^{-1} \mathbf{w} = \boldsymbol{\alpha}^T \phi(\mathbf{X}')^T (\phi(\mathbf{X}) \mathbf{L}_b^{1/2} \mathbf{I}_{N \times N} \mathbf{L}_b^{1/2} \phi(\mathbf{X})^T + c\mathbf{I})^{-1} \phi(\mathbf{X}') \boldsymbol{\alpha} = \boldsymbol{\alpha}^T (1/c) (\mathbf{K}'' - \mathbf{K}' \mathbf{L}_b^{1/2} (\mathbf{L}_b^{1/2} \mathbf{K} \mathbf{L}_b^{1/2} + c\mathbf{I}_{N \times N})^{-1} \mathbf{L}_b^{1/2} \mathbf{K}'^T) \boldsymbol{\alpha} \quad (16)$$

其中,  $\mathbf{K}'' = \phi(\mathbf{X}')^T \phi(\mathbf{X}')$ ,  $\mathbf{K} = \phi(\mathbf{X})^T \phi(\mathbf{X})$ . 令  $(\mathbf{S}_b^\phi + c\mathbf{I}_{N \times N})^{-1} = (1/c) (\mathbf{K}'' - \mathbf{K}' \mathbf{L}_b^{1/2} (\mathbf{L}_b^{1/2} \mathbf{K} \mathbf{L}_b^{1/2} + c\mathbf{I}_{N \times N})^{-1}$

$\mathbf{L}_b^{1/2} \mathbf{K}'^T)$ ,  $\mathbf{S}_w' = \mathbf{K}' \mathbf{L}_w \mathbf{K}'^T$ , 则优化准则(12)可重写为:

$$J(\boldsymbol{\alpha}, b) = \min \frac{1}{2} \sum_{i=1}^n e_i^2 + \frac{1}{2} \boldsymbol{\alpha}^T (\eta \mathbf{S}_w' + (1 - \eta) \cdot (\mathbf{S}_b' + c\mathbf{I}_{N \times N})^{-1}) \boldsymbol{\alpha} \quad (17)$$

s. t.  $\boldsymbol{\alpha}^T (\phi(\mathbf{X}')^T y_i \phi(\mathbf{x}_i)) + (y_i b) - e_i - d_i = 1$

类似于 DRLSC 模型, 由一阶导数 0 点计算, 最终可得到以下线性方程组:

$$\begin{pmatrix} 0 & \mathbf{y}^T \\ \mathbf{y} \mathbf{K}''^T (\eta \mathbf{S}_w' + (1 - \eta)(\mathbf{S}_b' + c\mathbf{I}_{N \times N})^{-1})^{-1} \mathbf{K}'' + \mathbf{I}_{N \times N} \end{pmatrix} \begin{pmatrix} b \\ \boldsymbol{\lambda} \end{pmatrix} = \begin{pmatrix} 0 \\ \mathbf{g} - \mathbf{d} \end{pmatrix} \quad (18)$$

此时, 误差向量  $\mathbf{e}$  为:

$$\mathbf{e} = \mathbf{K}''^T \boldsymbol{\alpha} + b \mathbf{y} - \mathbf{g} - \mathbf{d} \quad (19)$$

此时, 由式(14), 式(18)和式(19)以及前述迭代算法最终可以求得核空间中最优的 KDRLSC 分类器.

## 4 钴结壳超声识别实验

在实验室环境下, 我们将三类底质材料(钴结壳, 玄武岩, 火山砾质岩)放置于实验水池底部, 距超声探测换能器约 1.5m. 整个实验采用正入射法收集底质回波样本. 其中, 窄带超声换能器中心频率为 500KHz, 波束角为  $1.5^\circ$ . 回波信号通过信号线传输至后台的数据采样卡中, 其采样频率为 8MHz. 本实验共进行 8 次. 在每次实验过程中, 对每一类底质共采集了 6 组回波信号, 每组回波信号中均包含了 30 个底质回波, 因此每次实验共采集有  $30 \times 6 \times 3$  个回波样本.

首先我们对采集到的 500 维回波数据进行特征提取. 在这里我们首先对两种针对水下沉积物识别效果较好的特征提取方法: 小波模极大值特征提取方法<sup>[16]</sup>和小波奇异值特征提取方法<sup>[7]</sup>进行实验比较. 对实验中的回波分别提取 32 维模极大值和 16 维奇异值特征. 用 fisher 方法将这两种特征样本集降至 2 维. 如图 1 所示, 对于钴结壳等三类底质, 显然其模极大值特征比之奇异值特征具有更优的类间类内分布. 因此, 本实验最后选用模极大值特征提取方法.

在识别分类阶段, 我们分别采用 SVM, 原始 KDRLSC 以及本文提出的 KDRLSC 对回波模极大值特征分类比较实验. 核函数选用高斯核函数. 对这三类分类器, 我们采用 10 重交叉验证来估计高斯核参数  $\sigma$  和权重参数  $\eta$ , 参数  $\eta$  在集合  $\{0, 0.1, \dots, 0.9, 1\}$  中选取. 对本文提出的 KDRLSC, 为保证  $\mathbf{S}_b^\phi$  可逆, 设定  $c = 0.000001$ . 此外, 我们采用一对余法实现三类别分类任务, 并采用 10 重交叉验证估计分类正确率. 8 次实验结果如表 1 所示.




图1 三种底质材料的两种特征fisher二维分布图 (上图:模极大值特征下图:奇异值特征)

表 1 8 次钻结壳识别分类实验的平均测试正确率

SVM	平均测试正确率(%)鉴别流形正则化核最小二乘	本文的鉴别流形正则化核最小二乘
1	85.88	91.78
2	84.92	89.76
3	87.69	90.74
4	82.47	88.05
5	87.45	92.27
6	86.53	92.56
7	86.79	92.98
8	87.01	91.38

表 1 表明,采用本文提出的 KDRLSC 取得了比原始 KDRLSC 更优的识别分类结果.此外,我们以第一次实验为例,计算了可调参数  $\eta$  在不同取值下对应的平均测试正确率,结果如图 2 所示.




图2 参数 $\eta$ 不同取值下的两种KDRLSC分类器下的钻结壳识别分类平均测试正确率

由图 2 可以看出,参数  $1 - \eta$  逐步增大,原始 KDRLSC 的平均测试正确率急速下降,说明了随着类间流形散布信息的权重增加,其优化准则不再具有凸性,此时求得结果并不是全局最优解.为保证问题的凸性,必须减小类间流形散布信息的权重.在实验中,当  $1 - \eta$

$= 0$  时,问题的凸性得到了保证,原始 KDRLSC 取得了较高的识别分类正确率,此时类间流形散布信息被完全抛弃.而本文提出的改进模型则不会出现该问题,能够充分利用类间流形散布信息.在实验中,当参数  $1 - \eta = 0.4$  时,本文提出的 KDRLSC 取得了最优识别分类正确率.

## 5 结论

与表面近似线性平整的沉积物不同,水下钻结壳表面呈现出非常丰富的非线性流形结构特征.为充分利用钻结壳表面流形信息以获取更优的识别分类效果,本文引入了 DRLSC 模型.然而,原始的 DRLSC 在一般情况下并不具备优化问题的凸性.为解决该问题,基于 Ho-Kashyap 算法本文提出了一种改进的 DRLSC 及其核化版本 KDRLSC.钻结壳识别实验表明,原始 KDRLSC 无法充分利用类间流形信息,而改进的 KDRLSC 则不存在此问题,因此能够得到更优的识别分类效果,提高了钻结壳的识别分类正确率.

## 参考文献:

- [1] Pierre L, et al. Acoustic seabed classification: improved statistical method [J]. Canadian Journal of Fisheries and Aquatic Sciences, 2002(59): 1085 - 1089.
- [2] Cristianini N, Taylor J S. An Introduction to Support Vector Machines and other Kernel-based Learning Methods[M]. Cambridge U K: Cambridge University Press, 2000.
- [3] Scholkopf B, et al. Nonlinear component analysis as a kernel eigenvalue problem[J]. Neural Computation, 1998, 10(5): 1299 - 1319.
- [4] Mika S, Ratsch G, et al. Fisher discriminant analysis with kernels [A]. Proceedings of the 1999 IEEE Signal Processing Society Workshop[C]. IEEE, 1999. 41 - 48.
- [5] 刘涵,郭勇,等.基于最小二乘支持向量机的图像边缘检测研究[J].电子学报,2006,34(7):1275 - 1279. Liu Han, Guo Yong, et al. Edge detection based on least squares support vector machines[J]. Acta Electronica Sinica, 2006, 34(7): 1275 - 1279. (in Chinese)
- [6] 艾玲梅,王珏.基于双谱分析和支持向量机的手震颤加速度信号识别[J].电子学报,2008,36(11):2165 - 2170. L M Ai, J Wang. Hand tremor recognition using bispectrum analysis of acceleration signals and support vector machine[J]. Acta Electronica Sinica, 2008, 36(11): 2165 - 2170. (in Chinese)
- [7] 刘建国,李志舜,等.基于平稳小波变换及奇异值分解的湖底回波分类[J].声学学报,2006,31(2):73 - 78. Liu Jianguo, Li Zhishun, et al. Features of underwater echo extraction based on SWT and SVD[J]. Acta Acustica, 2006, 31

- (2):73-78.
- [8] Leski J. Ho-Kashyap classifier with generalization control[J]. Pattern Recognition Letters, 2003, 24(14): 2281-2290.
- [9] Tenenbaum J B, Silva D V, et al. A global geometric framework for nonlinear dimensionality reduction[J]. Science, 2000, 290(12): 2319-2323.
- [10] Sam T, Roweis L K. Nonlinear dimensionality reduction by locally linear embedding[J]. Science, 2000, 290(12): 2323-2326.
- [11] Xue H, Chen S C, Zeng X. Classifier learning with a new locality regularization method[J]. Pattern Recognition 2008, 41(5): 1496-1507.
- [12] Xue H, Chen S C, Yang Q. Discriminatively regularized least-squares classification[J]. Pattern Recognition, 2009, 42(1): 93-104.
- [13] Zhang W, Xue X Y, Lu H. Discriminant neighborhood embedding for classification[J]. Pattern Recognition, 2006, 39(11): 2240-2243.
- [14] Yu W W, Teng X L, Liu C Q. Face recognition using discriminant locality preserving projections [J]. Image and Vision Computing, 2006, 24(3): 239-248.
- [15] 郭雷. 控制理论导论 - 从基本概念到研究前沿[M]. 北京: 科学出版社, 2005. 2-3.

- [16] 赵建平, 黄建国, 等. 用小波变换进行水下回波边缘特征提取与分类识别[J]. 声学学报, 1998, 23(1): 31-38.  
Zhao Jianping, Huang Jianguo, et al. Transient feature extraction and discrimination of wideband echos based on wavlet transform[J]. Acta Acustica, 1998, 23(1): 31-38. (in Chinese)

#### 作者简介:



**杨 勃** 男, 1974 年生于湖南岳阳. 博士, 湖南理工学院信息与通信工程学院讲师, 主要研究方向为水声信号处理、图像处理与模式识别理论.

E-mail: ybmegnshen@163.com



**卜英勇** 男, 1944 年生于安徽芜湖. 中南大学机电工程学院教授, 博士生导师, 研究方向为设备故障诊断, 设备管理信息系统, 深海钻结壳探测采集技术与装备.