

# 基于支持向量机的磁共振脑组织图像分割

徐海祥<sup>1)</sup> 喻莉<sup>1)</sup> 朱光喜<sup>1)</sup> 张翔<sup>2)</sup> 田金文<sup>2)</sup>

<sup>1)</sup>(华中科技大学电子与信息工程系,武汉 430074) <sup>2)</sup>(华中科技大学图像识别与人工智能研究所,武汉 430074)

**摘要** 脑组织图像分割在医学图像分析中具有重要的理论和应用价值。由于支持向量机被看作是对传统学习分类器的一个好的替代,特别是在小样本、高维情况下,具有较好的泛化性能,因此可采用支持向量机方法对磁共振脑组织图像进行分割研究。为了验证支持向量机分割磁共振脑组织图像的效果,利用支持向量机进行了脑组织图像分割实验。实验结果表明:核函数及模型参数对支持向量机的分割性能有较大的影响;支持向量机方法适合作为小样本情况下的学习分类器;对目标边界模糊、目标灰度不均匀及目标不连续等情况下的图像(如医学图像)分割,支持向量机方法也是一个好的选择。

**关键词** 支持向量机 分割 脑组织

中图分类号: TP391.4 R445 文献标识码: A 文章编号: 1006-8961(2005)10-1275-06

## Segmentation of Magnetic Resonance Brain Tissues Image Based on Support Vector Machines

XU Hai-xiang<sup>1)</sup>, YU Li<sup>1)</sup>, ZHU Guang-xi<sup>1)</sup>, ZHANG Xiang<sup>2)</sup>, TIAN Jin-wen<sup>2)</sup>

<sup>1)</sup>(Department of Electronics and Information Engineering, Huazhong University of Science and Technology, Wuhan 430074)

<sup>2)</sup>(Institute of Image Recognition and Artificial Intelligence, Huazhong University of Science and Technology, Wuhan 430074)

**Abstract** Segmentation of brain tissues is very important in medical image analysis. Support Vector Machines(SVM) is considered a good candidate because of its good generalization performance, especially for dataset with small number of samples in high dimensional feature space. This paper investigates the segmentation of magnetic resonance brain tissues image based on SVM. Experimental results show that the influence of kernel function and model parameters on the generalization performance of SVM is significant; SVM is suitably used as learning classifier of small sample size; To segment targets with blurry edges, intensity non-uniformity and discontinuity (such as medical images), SVM approach is a good choice.

**Keywords** support vector machines, segmentation, brain tissues

## 1 引言

由于医学图像分割是通过对医学图像上显示的人体某种组织或器官的形状、边界、截面面积以及体积等进行精确的测量来得到该组织病理或功能方面重要信息的必不可少的技术,同时也是计算机辅助治疗、医学图像3维重建和医学图像可视化的前提,

因此,医学图像分割的研究多年来一直受到人们的高度重视,分割算法也层出不穷。然而,由于医学图像的成像受到诸如噪声、场偏移效应、局部体效应以及组织运动等的影响,医学图像与普通图像相比,不可避免地具有各组织边缘模糊,区域灰度不均匀等特点。另外,人类各种组织在长期的进化过程中的个体差异很大,不同个体的同一组织很难用统一的模型来进行描述,这些都给医学图像的正确分割带

基金项目:湖北省自然科学基金项目(2005ABA254)

收稿日期:2004-06-17;改回日期:2005-04-15

第一作者简介:徐海祥(1975~),男。现为华中科技大学电子与信息工程系博士研究生。主要研究方向为图像处理、模式识别以及人工智能等。E-mail:qukaiyang@163.com

来了困难<sup>[1]</sup>。

由于医学图像成像的特殊性,致使基于区域或边缘的分割方法,如阈值法、区域生长法、边缘检测方法等很难得到满意的分割结果,而基于学习的分类方法,如贝叶斯分类器和神经网络分类器等则可以获得相对较好的分割结果,因此,在医学图像分割中得到广泛的应用<sup>[2]</sup>。由于传统的学习分类方法是以经验风险最小化(empirical risk minimization 简称 ERM)为基本准则,其在学习过程中无法控制模型的复杂性,因而容易导致过拟合而使泛化性能变差,特别在小样本的情况下更是如此。由 Vapnik 等人发展的支持向量机(support vector machines 简称 SVM)被看作是对传统学习分类器的一个好的替代,特别在小样本、高维非线性情况下更宜用支持向量机进行分类。支持向量机方法是建立在统计学习理论的 VC 维(vapnik-chervonenkis dimension)理论和结构风险最小化原理的基础上,根据有限样本信息在模型的复杂性和学习能力之间寻求最佳折衷,以期获得最好的泛化性能的分类方法<sup>[3]</sup>。

本文采用 SVM 方法对磁共振(magnetic resonance 简称 MR)脑组织图像进行了分割实验研究。为了评价核函数、模型参数及训练样本数对 SVM 分割性能的影响,还进行了一系列实验。

## 2 支持向量机方法

### 2.1 结构风险最小化

传统的学习分类方法是以最小化经验风险取代最小化期望风险,但这种取代一方面并没有可靠的理论依据,只是直观上合理的想当然<sup>[4]</sup>;另一方面,如果一味地追求最小化的经验风险,则可能导致分类器过拟合而使泛化性能变差,特别在小训练样本情况下更容易出现这种现象。这也是包括神经网络等分类方法在内的传统学习机器当前遇到的最大问题之一。20 世纪 70 年代,Vapnik 等人提出的统计学理论(statistic learning theory 简称 SLT),其是专门研究有限样本情况下机器学习规律的理论,它从 VC 维的概念出发,推导出经验风险  $R_{emp}(\alpha)$  与期望风险  $R(\alpha)$  之间的关系,即称作泛化性的界,其可以表示为

$$R(\alpha) \leq R_{emp}(\alpha) + \Phi\left(\frac{h}{n}\right) \quad (1)$$

式中,  $\Phi(\cdot)$  为单调递增实值函数,  $\alpha \in \Omega$  为分类器

的广义参数,  $h$  为反映分类器复杂性的 VC 维,  $n$  为训练样本数。

式(1)将期望风险分成以下两部分:一部分是经验风险,用于控制训练误差;另一部分称作置信范围,用于控制分类器的复杂性。基于统计学习理论的分类器的训练,就是在分类函数族中寻找经验风险和置信范围之和最小的子集,使得期望风险的上界最小,以致实现在有限样本信息模型的复杂性和学习能力之间寻求最佳折衷,这就是所谓的结构风险最小化。

### 2.2 支持向量机

SVM 方法是建立在统计学习理论的 VC 维理论和结构风险最小化原理上的具体实现<sup>[3,5-7]</sup>。

考虑  $K$  维两类非线性分类情况,首先给定训练样本集:  $\{(x_i, y_i), i = 1, 2, \dots, n\}$ , 其中  $x_i \in \mathbf{R}^k, y_i \in \{+1, -1\}$ 。然后通过一非线性映射将输入数据空间映射到高维特征空间,即

$$x \rightarrow \varphi(x) = (\varphi_1(x), \varphi_2(x), \dots, \varphi_n(x), \dots) \quad (2)$$

这样,在高维特征空间中,如果训练样本集线性可分,则可通过分类超平面  $\langle w, \varphi(x) \rangle + b = 0$  来将训练样本正确分开。通过规范化权向量  $w$  和偏移量  $b$ ,有下列不等式成立:

$$\begin{cases} \langle w, \varphi(x_i) \rangle + b \geq 1 & \text{如果 } y_i = +1 \\ \langle w, \varphi(x_i) \rangle + b \leq -1 & \text{如果 } y_i = -1 \end{cases} \quad (3)$$

将其合并可以写为

$$y_i [\langle w, \varphi(x_i) \rangle + b] \geq 1 \quad (4)$$

其中,  $i = 1, 2, \dots, n$ 。

高维特征空间中任意训练样本点到分类超平面的距离为

$$L(x_i, w, b) = \frac{|\langle w, \varphi(x_i) \rangle + b|}{\|w\|} \quad (5)$$

可见,由于两类训练样本中到分类超平面的最小距离均为  $1/\|w\|$ ,也即两类的分类间隔(margin)为  $2/\|w\|$ ,因此,寻找到的最优分类超平面,就是在式(4)约束条件下寻找到的分类间隔最大的超平面,也就是寻找到的权向量范数  $\|w\|$  最小的超平面。

在高维特征空间中,如果训练样本集线性不可分,或事先不知道它是否线性可分,此种情况将允许存在一定数量的误分类样本,并可引入非负松弛变量  $\xi_i, i = 1, 2, \dots, n$ ,则式(4)变为

$$y_i [\langle w, \varphi(x_i) \rangle + b] \geq 1 - \xi_i \quad (6)$$

式(6)中,若  $\xi_i = 0$ ,则表示对应的训练样本被正确地分类;若  $\xi_i > 0$ ,则表示对应的训练样本被误分类。

为了得到一个最大间距的分类超平面,可以将上述问题转化为如下线性约束条件下的二次规划问题:

$$\min \frac{1}{2} \langle \mathbf{w}, \mathbf{w} \rangle + C \sum_{i=1}^n \xi_i \quad (7)$$

$$\text{s. t. } y_i [\langle \mathbf{w}, \varphi(\mathbf{x}_i) \rangle + b] \geq 1 - \xi_i \quad (8)$$

$$\xi_i \geq 0 \quad (9)$$

其中,  $C > 0$  是一个自定义的惩罚因子,用于控制对误分样本的惩罚程度,即  $C$  越大,惩罚就越大,那么对误分样本的约束程度就越高。最小化式(7)的第 1 项相当于最小化分类函数的 VC 维,也相当于最小化式(1)的第 2 项,以便保证所求的分类函数具有最优的泛化性能;最小化式(7)的第 2 项可以控制训练过程中的经验风险,也即最小化式(1)的第 1 项,这样可保证误分的样本数最少。从上述分析可以看出,支持向量机能够在有限样本信息模型的复杂性和学习能力之间寻求最佳折衷。

通过 Lagrangian 乘法,式(7)~式(9)的约束问题就可以转化为如下的对偶问题:

$$\max F(\boldsymbol{\lambda}) = \sum_{i=1}^n \lambda_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \lambda_i \lambda_j y_i y_j \langle \varphi(\mathbf{x}_i), \varphi(\mathbf{x}_j) \rangle \quad (10)$$

$$\text{s. t. } \sum_{i=1}^n \lambda_i y_i = 0 \quad (11)$$

$$0 \leq \lambda_i \leq C \quad (12)$$

式中,  $\boldsymbol{\lambda} = (\lambda_1, \lambda_2, \dots, \lambda_n)$ 。

最优分类超平面的权向量为

$$\hat{\mathbf{w}} = \sum_{i=1}^n \hat{\lambda}_i y_i \varphi(\mathbf{x}_i) \quad (13)$$

其中,上标“ $\hat{\cdot}$ ”表示最优,相应的 KT (Karush-Kuhn-Tucher) 条件<sup>[8]</sup>为

$$\hat{\lambda}_i \{ y_i [\langle \hat{\mathbf{w}}, \varphi(\mathbf{x}_i) \rangle + \hat{b}] - 1 + \xi_i \} = 0 \quad (14)$$

$$\xi_i (\hat{\lambda}_i - C) = 0 \quad (15)$$

由式(14)、式(15)可知,当  $\xi_i = 0$ ,也即样本被正确分类时,  $0 \leq \hat{\lambda}_i < C$ ; 当  $\xi_i \neq 0$ ,也即样本被误分时,  $\hat{\lambda}_i = C$ 。又由式(13)可知,只有当  $0 < \hat{\lambda}_i \leq C$  时,所对应的向量  $\mathbf{x}_i$  对确定权向量  $\hat{\mathbf{w}}$  才有贡献,因此,将满足  $0 < \hat{\lambda}_i \leq C$  的向量称为支持向量 (support vector 简称 SV),它们位于距所求得的最优超平面  $1/\|\hat{\mathbf{w}}\|$  距离处,所以,支持向量是训练样本集的一个子集。

这样,最优分类函数可以写为

$$\begin{aligned} f(\mathbf{x}) &= \langle \hat{\mathbf{w}}, \varphi(\mathbf{x}) \rangle + \hat{b} \\ &= \sum_{i \in \mathbf{V}} \hat{\lambda}_i y_i \langle \varphi(\mathbf{x}_i), \varphi(\mathbf{x}) \rangle + \hat{b} \end{aligned} \quad (16)$$

由式(16)可知,由于计算分类函数只涉及高维特征空间中的输入向量与支持向量的内积,因此,甚至没有必要知道非线性映射  $\varphi$  的具体形式,而只需要进行它的内积运算即可。假定高维特征空间的内积为

$$K(\mathbf{x}_i, \mathbf{x}) = \langle \varphi(\mathbf{x}_i), \varphi(\mathbf{x}) \rangle \quad (17)$$

则称式(17)的内积为核函数,它可将高维特征空间的内积运算转化为低维输入空间上的一个简单的函数运算。统计学习理论指出,根据 Hilbert-Schmidt 原理,只要一种运算满足 Mercer 条件,它就可以作为核函数<sup>[9]</sup>。

通过上述变换,二值决策函数可以写为

$$g(\mathbf{x}) = \text{sgn} \left( \sum_{i \in \mathbf{V}} \hat{\lambda}_i y_i K(\mathbf{x}_i, \mathbf{x}) + \hat{b} \right) \quad (18)$$

式(18)中的偏移量  $\hat{b}$  可以利用任意支持向量  $\mathbf{x}_j$  在约束条件  $y_j f(\mathbf{x}_j) = 1$  下得到,即

$$\hat{b} = y_j - \sum_{i \in \mathbf{V}} \hat{\lambda}_i y_i K(\mathbf{x}_i, \mathbf{x}_j) \quad (19)$$

### 3 MR 脑组织图像分割

从本质上来说 SVM 方法是一种两类学习分类方法,而 MR 脑组织图像的分割属于多类(背景、脑灰质、脑白质及脑脊髓)分类问题,为此通过一对多 (one-against-all) 方法将其推广到多类情况<sup>[10,11]</sup>。

#### 3.1 特征提取

除了分类器的选择外,分割效果的好坏在很大程度上还取决于从图像中提取的特征。许多研究表明,对相对光滑的图像,如磁共振的医学图像,用一些局部灰度统计特征及局部纹理特征能够获得较好的分割效果<sup>[12]</sup>。本文将从实验图中提取的包括当前像素的灰度值  $I$ 、当前像素邻域的均值  $E$ 、当前像素邻域的中值  $M$  以及由当前像素邻域的灰度共生矩阵导出的局部纹理特征作为 SVM 的输入向量。

为了获取局部特征,需要将当前像素的邻域形成一个子图像,然后在子图像中提取相应的局部灰度统计特征和局部纹理特征。假设子图像尺寸为  $s \times s$ ,其中,  $s$  为奇数,则局部灰度统计特征如下:

$$(1) \text{ 灰度均值 } E = \frac{1}{s} \sum_{u=0}^{s-1} \sum_{v=0}^{s-1} I(u, v)$$

(2) 灰度中值

$$M = \text{median} \{ I(0, 0), I(0, 1), \dots, I(s-1, s-1) \}$$

其中,  $\text{median} \{ \cdot \}$  表示求中值运算。

设  $p(i, j)$  为由于图像生成的间隔为  $d$ 、方向为  $\theta$

的灰度共生矩阵,其中,  $i, j$  表示灰度等级,则由共生矩阵可导出 11 个纹理特征<sup>[13]</sup>如下:

$$(3) \text{ 对比度 } f_1 = \sum_i \sum_j (i-j)^2 p(i,j)$$

$$(4) \text{ 相关性 } f_2 = \frac{\sum_i \sum_j p(i,j)p(i,j) - \mu_x \mu_y}{\sigma_x \sigma_y}$$

$$(5) \text{ 熵 } f_3 = - \sum_i \sum_j p(i,j) \log(p(i,j))$$

$$(6) \text{ 角二阶矩 } f_4 = \sum_i \sum_j [p(i,j)]^2$$

$$(7) \text{ 反差矩 } f_5 = \sum_i \sum_j \frac{1}{1+(i-j)^2} p(i,j)$$

$$(8) \text{ 方差 } f_6 = \sum_i \sum_j [p(i,j) - \mu]^2 p(i,j)$$

$$(9) \text{ 和均值 } f_7 = \sum_{i=2}^{2N_g} i p_{x+y}(i)$$

$$(10) \text{ 和熵 } f_8 = - \sum_{i=2}^{2N_g} p_{x+y}(i) \log(p_{x+y}(i))$$

$$(11) \text{ 和方差 } f_9 = \sum_{i=2}^{2N_g} (i - f_7)^2 p_{x+y}(i)$$

$$(12) \text{ 差熵 } f_{10} = - \sum_{i=0}^{N_g-1} p_{x-y}(i) \log(p_{x-y}(i))$$

$$(13) \text{ 差方差 } f_{11} = \sum_{i=0}^{N_g-1} (i - f_{10})^2 p_{x-y}(i)$$

其中,  $p_x(i) = \sum_{j=1}^{N_g} p(i,j)$ ,  $p_y(j) = \sum_{i=1}^{N_g} p(i,j)$ ,  $\mu_x, \mu_y$ ,  $\sigma_x$  及  $\sigma_y$  分别是  $p_x(i)$  和  $p_y(i)$  的均值和标准差,  $N_g$  为图像的灰度等级。

因为 MR 脑组织图像表现为微观纹理特征,所以本文取  $s=5, d=1, \theta$  分别取  $0^\circ, 45^\circ, 90^\circ$  及  $135^\circ$  等值。这样,对每个要分类的像素,先从其邻域中提取了 3 个局部灰度特征和 44 个不同方向的局部纹理特征然后将其作为支持向量机的输入向量。

由于所提取的特征可能在量值上有很大的差异,为了避免大值特征淹没了小值特征对分类的贡献,对所提取的特征进行归一化非常重要。采用下式对特征进行归一化:

$$X_{\text{normal}} = \frac{2 \times X - X_{\text{max}} - X_{\text{min}}}{X_{\text{max}} - X_{\text{min}}} \quad (20)$$

经归一化处理,各特征值的范围被限制在  $[-1, 1]$  之间。

### 3.2 核函数及模型参数的选择

应用 SVM 分割图像,由于输入向量通过非线性映射到高维特征空间的分布结构由核函数决定,同时,最优超平面与最近的训练样本之间的最大

距离和最小分类误差通过惩罚因子  $C$  进行折衷,因此,核函数设计与惩罚因子  $C$  的选择将直接影响到图像分割效果。目前常用的核函数有:线性核  $K(\mathbf{x}, \mathbf{z}) = \langle \mathbf{x}, \mathbf{z} \rangle$ , 多项式核  $K(\mathbf{x}, \mathbf{z}) = (\langle \mathbf{x}, \mathbf{z} \rangle + 1)^c$  以及高斯径向核  $K(\mathbf{x}, \mathbf{z}) = \exp\left(-\frac{\|\mathbf{x} - \mathbf{z}\|^2}{2\sigma^2}\right)$ , 其中,  $c$  为多项式的阶数,  $\sigma$  为高斯分布的宽度<sup>[9,14]</sup>。比较上述 3 种核取不同参数时对 MR 脑图像的分割效果,并研究两种混合核的分割效果。

在参数  $C$  和  $\sigma$  的选择中,采用交叉验证法<sup>[15]</sup>。其具体做法是将所有训练样本分为  $k$  个子集,每次将  $k-1$  个子集用于训练,剩下的一个子集用于测试,重复上述过程,直到所有子集都参加了测试,再计算  $k$  次平均泛化误差,最后选取泛化误差最小的参数为模型参数。

### 3.3 实验结果及讨论

为验证 SVM 的分割效果,选用 McGill 大学 McConnell 脑图像中心的在线图像库 (<http://www.bic.mni.mcgill.ca/brainweb/>) 进行了分割实验。实验用体图像大小为  $181 \times 217 \times 60$ , 切片厚度为 3mm, 实验中对 2 维 T1 加权、3% 的噪声、40% 的灰度非均匀性的 MR 脑组织图像的  $26^*$  切片进行了脑灰质、脑白质及脑脊髓等脑组织的分割。实验用的训练样本都是随机地从参考图中选取。

表 1 为训练样本数为 1500, 在不同的核函数、各种模型参数下分割 MR 脑组织图像的泛化误差比较结果。从表中可以看出,在不同的模型参数下,混合核函数的泛化误差最大,线性核函数和多项式核函数次之,高斯径向核函数最小。另外还可见,对高斯径向核函数,一方面,当  $\sigma^2$  恒定时,泛化误差随着  $C$  增大而减小,其原因主要是随着  $C$  增大,训练错样本数减小的缘故,也即由于经验风险减小,从而使泛化误差减小;另一方面,当  $C$  恒定时,泛化误差随着  $\sigma^2$  增大基本上呈现出由大变小再变大的趋势,其原因主要是由于当  $\sigma^2$  较小时,分类器的 VC 维较大,出现了过学习而使泛化误差变大;当  $\sigma^2$  较大时,分类器的 VC 维较小,出现了欠学习而使泛化误差变大的缘故。可见,核函数类型及模型参数的选择对分割性能有较大的影响。

表 2 为采用高斯径向核 ( $\sigma^2 = 0.5, C = 1000$ ), 在不同训练样本数下的泛化误差比较结果。图 1 为采用高斯径向核 ( $\sigma^2 = 0.5, C = 1000$ ), 支持向量数随着训练样本数增大的变化趋势图。从表 2 和图 1

表 1 不同的核函数、各种模型参数下泛化误差比较

Tab.1 Comparative results in generalization error of different kernels and various model parameters

单位: %

核函数	参数	C			
		1	10	100	1000
$K(x, z) = \langle x, z \rangle$		13.12	11.87	11.38	10.86
	$d=2$	13.06	9.03	12.00	12.28
$K(x, z) = (\langle x, z \rangle + 1)^d$	$d=3$	9.56	12.16	12.96	13.73
	$d=4$	12.36	12.14	14.98	15.83
	$\sigma^2=2$	13.49	12.55	11.80	10.32
$K(x, z) = \exp\left(-\frac{\ x-z\ ^2}{2\sigma^2}\right)$	$\sigma^2=1$	12.81	12.43	11.53	9.78
	$\sigma^2=0.5$	11.71	10.23	9.76	8.68
	$\sigma^2=0.25$	11.91	10.61	9.69	8.77
	$d=2$	22.06	21.95	15.98	16.19
$K(x, z) = \frac{1}{2}\langle x, z \rangle + \frac{1}{2}(\langle x, z \rangle + 1)^d$	$d=3$	32.63	27.86	28.20	26.33
	$d=4$	17.11	15.32	15.27	15.02
	$d=2$	22.13	28.43	27.46	26.32
$K(x, z) = \langle x, z \rangle * (\langle x, z \rangle + 1)^d$	$d=3$	24.81	22.59	18.71	22.66
	$d=4$	23.31	18.46	17.22	16.43

表 2 不同训练样本数下的泛化误差比较

Tab.2 Comparative results in generalization error of different number of training examples

训练样本数	200	500	1000	1500	2000	2500	3000
泛化误差 (%)	10.24	8.59	9.58	8.68	8.85	8.49	9.10




图 1 支持向量数随训练样本数增大的变化趋势图

Fig.1 Tendency of number of support vectors with the increase of number of training examples

可以看出,随着训练样本数的增大,支持向量数变化较大,但泛化误差变化较小。可见,SVM 方法适合

作为小样本情况下的学习分类器。

表 3 为采用 BP-MLP<sup>[2]</sup>法(采用 3 层结构:其中输入层 47 个节点,隐含层 55 个节点,输出层 4 个节点,训练样本数为 1500)、多阈值法(阈值分别为 41、85 及 130)及 SVM 法(采用高斯径向核函数  $\sigma^2=0.5, C=1000$ ,训练样本数为 1500)对 MR 脑组织图像进行分割的错误率比较。

表 3 不同分割方法的错误率比较

Tab.3 Comparative results in error ratio of different approaches

分割方法	BP-MLP	多阈值	SVM
错误率 (%)	9.88	12.49	8.68

图 2 为 3 种不同方法对 MR 脑组织图像进行分割的结果图。对图 2 各图的比较结果表明:SVM 方法用于 MR 脑组织图像的分割可以获得较好的分割结果。




图 2 不同分割方法的分割结果图

Fig. 2 Visual segmentation results of different approaches

## 4 结 论

本文采用支持向量机方法对 MR 脑组织图像进行了分割实验研究。实验结果表明:(1)核函数及模型参数对支持向量机的分割性能有较大的影响;(2)训练样本数对支持向量机分割性能的影响较小,这就验证了支持向量机方法适合作为小样本情况下的学习分类器;(3)对目标边界模糊、目标灰度不均匀及目标不连续等情况下的图像(如医学图像)的分割,支持向量机方法是一个好的选择。

### 参考文献 (References)

- 1 Lin Yao, Tian Jie, Zhang Xiao-peng. Application of a new medical image segmentation method based on fuzzy connectedness and FCM [J]. Chinese Journal of Stereology and Image Analysis, 2001, 6(2): 103 ~ 108. [林瑶, 田捷, 张晓鹏. 基于模糊连接度的 FCM 分割方法在医学图像分析中的应用[J]. 中国体视学与图像分析, 2001, 6(2): 103 ~ 108.]
- 2 Reddick W E, Glass J O, Cook E N, et al. Automated segmentation and classification of multispectral magnetic resonance images of brain using artificial neural networks [J]. IEEE Transactions on Medical Imaging, 1997, 16(6): 911 ~ 918.
- 3 Vapnik V. The Nature of Statistical Learning Theory [M]. New York: Springer-Verlag, 1995.
- 4 Zhang Xue-gong. Introduction to statistical learning theory and support vector machines [J]. Acta Automatica Sinica, 2000, 26(1): 32 ~ 42. [张学工. 关于统计学习理论与支持向量机[J]. 自动化学报, 2000, 26(1): 32 ~ 42.]
- 5 Burges C. A tutorial on support vector machines for pattern recognition [J]. Data Mining and Knowledge Discovery, 1998, 2(2): 121 ~ 167.
- 6 Osuna E, Freund R, Girosi F. Training support vector machines: An application to face detection [A]. In: Proceedings of Computer Vision and Pattern Recognition [C], San Juan, Puerto Rico, 1997: 130 ~ 136.
- 7 Zhao Q, Principe J. Support vector machines for SAR automatic target recognition [J]. IEEE Transactions on Aerospace and Electronic Systems, 2001, 37(2): 643 ~ 654.
- 8 Lin C F, Wang S D. Fuzzy support vector machines [J]. IEEE Transactions on Neural Networks, 2002, 13(2): 464 ~ 471.
- 9 Genton M G. Classes of kernels for machine learning: a statistics perspective [J]. Journal of Machine Learning Research, 2001, 2(2): 299 ~ 312.
- 10 Weston J, Watkins C. Multi-class Support Vector Machines [R]. Technical Report, CSD-TR-98-04, Egham, UK: University of London, 1998: 1 ~ 9.
- 11 Hsu C W, Lin C J. A comparison of methods for multi-class support vector machines [J]. IEEE Transactions on Neural Networks, 2002, 13(2): 415 ~ 425.
- 12 Petersen M E, Pelikan E. Detection of bone tumours in radiographic images using neural networks [J]. Pattern Analysis & Application, 1999, 2(2): 172 ~ 183.
- 13 Haralick R M, Shanmugam K, Dinstein I. Textual features for image classification [J]. IEEE Transactions on Systems, Man and Cybernetics, 1973, 3(6): 610 ~ 621.
- 14 Brailovsky V L, Barzilay O, Shavah R. On global, local, mixed and neighborhood kernels for support vector machines [J]. Pattern Recognition Letters, 1999, 20(11-13): 1183 ~ 1190.
- 15 Muller K R, Mika S, Ratsch G, et al. An introduction to kernel-based learning algorithm [J]. IEEE Transactions on Neural Networks, 2001, 12(2): 181 ~ 201.