

# 一种基于一致性邻域超图模型的图象分割方法

耿伯英 杨静宇

(南京理工大学计算机科学与工程系, 南京 210094)

**摘要** 提出了一种将超图理论与图象的空-频域特征分析相结合的图象分割方法. 该方法是基于图象的多分辨率小波分析及高斯-马尔可夫随机场理论, 在抽取一组反映图象局部空间结构信息的特征矢量基础上, 根据同一区域的象素具有相似的特征矢量的原则, 将图象转换为一个关于特征相似性测度的邻域超图, 再利用覆盖-选择算法对该超图进行分割的方法. 实验证明, 该方法具有较好的稳定性和适应性, 尤其对于一些信噪比较低的图象, 也具有较好的分割效果.

**关键词** 多分辨率小波分析 空间结构特征 邻域超图 图象分割

中图分类号: TP391 O157.6 文献标识码: A 文章编号: 1006-8961(2000)04-0288-05

## An Approach for Image Segmentation Based on the Homogeneous Neighborhood Hypergraph

GENG Bo-ying, YANG Jing-yu

(Department of Computer Science and Engineering, Nanjing University of Science and Technology, Nanjing 210094)

**Abstract** In this paper, an approach for image segmentation incorporating the theory of hypergraph with the spatial-frequency features of image is proposed. Based on the multiresolution wavelet analysis and the theory of Gaussian-Markov random field, the features characterizing the local spatial structure of image are extracted, a neighborhood hypergraph with respect to the similarities of the features is constructed, segmentation is implemented via the adapted Covering-Selection algorithm. The adaptability and reliability have been tested through simulations. The approach is effective for segmentation of images with low SNR.

**Keywords** Multiresolution wavelet analysis, Spatial structure feature, Neighborhood-hypergraph, Image segmentation

## 0 引言

众所周知, 图象分割就是根据图象的某种特性(如灰度图象中的灰度, 距离图象中的深度等)将图象划分为一系列不相交的区域. 然而, 实际成象过程受各种环境因素(如光照, 反射, 视角等)的影响, 景物仅仅是以灰度形式表示出来, 这是一种多到一映射, 从而使图象存在不确定性和模糊性, 这种不确定性和模糊性在三维距离成象及医学成象等应用环境中尤为严重, 这使得一些仅基于图象灰度特征的分割算法的性能受到很大影响<sup>[1,2]</sup>.

由此可见, 一种分割算法的有效性和适应性依

赖于其所使用的图象的一致性特征. 本文提出了一种基于图象的多分辨率小波分析及高斯-马尔可夫随机场(GMRF)理论的特征提取方法, 这种特征用一组矢量来表示, 它反映了图象的局部结构信息<sup>[2,3]</sup>, 全体特征矢量构成了图象的一个特征集 $X_F$ . 一般来讲, 相同的区域内有相近的结构特征, 而不同区域的特征则存在较大的差异. 然后根据图象中象素之间的空间相邻关系以及局部结构特征的一致性来构造图象的一致性邻域超图, 从而把对原始图象的分割转化为对这个超图的分割, 其实质就是在分割过程中不仅考虑了图象的灰度特征, 而且还依据图象的局部结构特征. 本文还对覆盖-选择算法(CS算法)<sup>[4]</sup>进行了改进, 并使用改进后的算法对一致性

邻域超图进行分割.

# 1 图象的一致性邻域超图模型

## 1.1 超图及邻域超图

一个简单的无向图  $G$  可用二元组  $\langle S, E \rangle$  表示, 其中  $S$  为一非空点集, 而称  $E$  为边集, 其元素为二元点对  $(x, y), x, y \in S, E$  一般也为非空集. 如果将上述边的定义修改为  $S$  的任意子集, 即超边 (hyper-edge), 则就将图推广为超图 (hypergraph)<sup>[5]</sup>. 超图理论在诸如算法研究及网络设计中被看作是一种有效的工具. 本文将超图作为一种新的图象处理组合数学模型, 借助它来解决图象的分割问题.

为叙述方便起见, 首先引入与本文算法相关的几个概念.

**定义 1** 关于非空点集  $S$  的一个超图  $H$  是由一列  $S$  的子集  $E_i$  组成,  $i \in I$ , 且  $S = \bigcup_{i \in I} E_i$ , 也即  $H = \langle S, (E_i)_{i \in I} \rangle, E_i$  为超边.

**定义 2**  $\forall x \in S$ , 超图  $H$  的一个星是由一组超边所组成的集合, 用  $H(x)$  来表示, 其中每条边均包含  $\{x\}$ . 元素  $x$  叫做这个星的中心, 与普通图相类似, 可以定义节点  $x$  的度数  $d(x)$ , 它表示星  $H(x)$  中的超边数.

图 1 是一个超图, 一般地, 若超边  $e$  包含多于两个节点, 就用一个包含这些节点的闭合曲线 (如椭圆) 来表示, 若超边  $e$  包含两个节点, 则用一条连接这两点的直线来表示, 而用一个圈来表示只包含一个节点的超边.




图1 超图

**定义 3** 若  $G = \langle S, E \rangle$  为一个普通的无向图, 则关于  $G$  的邻域超图定义为  $H_c = \langle S, (E_x = \{x\} \cup T_n(x)) \rangle$ , 其中  $T_n(x)$  表示  $S$  中与  $x$  的距离不超过  $n$  的节点集.

## 1.2 数字图象的一致性邻域超图模型

上述的超图  $H_c$  描述了点集  $S$  中节点间的邻域关系, 它是图象处理中用得较多的一种关系, 若  $(x, y) \in E_x$ , 则反映了与像素  $x, y$  相应的景物上两点 (或区域) 空间上的相邻关系. 然而, 通常情况下, 图象中相邻的像素可能属于不同的物体 (或区域),

它们具有不同的特性. 因此, 对于一种确定的属性, 图象  $X$  中任意两个像素  $x, y$  之间还存在关于这种属性的一致性关系.

为了描述这种一致性关系, 首先定义样本图象  $X$  的特征集  $XF$ , 它包含了图象中我们感兴趣的某些特征, 在通常情况下,  $XF \subset R^p, p \geq 1$ , 即  $XF$  是  $p$  维向量集, 显然  $XF$  的定义与处理的目的有关. 设  $g$  为图象  $X$  到其特征集  $XF$  上的映射, 结合  $g$  和上述的邻域关系就可导出另一映射

$$T_{n,g}(x): X \rightarrow p(X),$$

$$T_{n,g} = g^{-1}\{g(x)\} \cap T_n(x), \forall x \in X$$

其中  $p(X)$  表示  $X$  的幂集,  $T_n(x)$  的意义同前. 进而可定义一致性邻域关系  $RS$  若  $y \in T_{n,g}(x)$ , 且  $x \in T_{n,g}(y)$ , 则  $(x, y) \in RS$ , 即像素  $x, y$  属于同一邻域且具有相同的某种属性, 则它们间存在关系  $RS$ .

于是可以构造一致性邻域超图  $H_{n,g} = \langle X, (\{x\} \cup T_{n,g}(x)) \rangle$ , 其中超边  $\{x\} \cup T_{n,g}(x)$  表示在像素  $x$  的某个邻域内与  $x$  具有相同特征的像素的集合. 这种研究方法与人类视觉系统在识别物体时总是离不开物体所在的周围环境的特点是相一致的.

# 2 图象空-频域特征的提取

## 2.1 图象的多分辨率小波分析

根据小波分析理论<sup>[6]</sup>, 设  $\{V_j\}_{j \in Z}$  是实直线  $R$  上的平方可积函数空间  $L^2(R)$  的一个多尺度分析,  $\varphi(x) \in L^2(R)$  是它的标准正交生成元, 令  $\varphi_k = 2^{j/2}(\varphi(x-k)), j, k \in Z$ , 并设  $\tilde{V}_j = V_j \otimes V_j$ , 则  $\{\tilde{V}_j\}$  是  $L^2(R^2)$  中的子空间, 且  $\dots \subset \tilde{V}_{-1} \subset \tilde{V}_0 \subset \tilde{V}_1 \subset \tilde{V}_2 \subset \dots, \bigcup_{j \in Z} \tilde{V}_j = L^2(R^2), \bigcap_{j \in Z} \tilde{V}_j = \{0\}$ . 另设  $\{W_j\}_{j \in Z}$  是  $L^2(R)$  中对应于  $\{V_j\}_{j \in Z}$  的正交小波子空间,  $\psi_{j,k}$  为其标准基, 则  $\bigoplus_{j \in Z} W_j = L^2(R), W_j \perp W_i, j \neq i, V_j \oplus W_j = V_{j+1}, W_j \perp V_j$ . 令

$\tilde{W}_j^1 = V_j \otimes W_j, \tilde{W}_j^2 = W_j \otimes V_j, \tilde{W}_j^3 = W_j \otimes W_j$ , 则  $L^2(R^2) = \bigoplus_{j \in Z} \tilde{W}_j^1 \oplus \bigoplus_{j \in Z} \tilde{W}_j^2 \oplus \bigoplus_{j \in Z} \tilde{W}_j^3$ , 且对于任何的  $f(x, y) \in L^2(R^2)$ , 都有

$$f(x, y) = \sum_{j,k,l} d_{j,k,l}^1 \varphi_{j,k}(x) \psi_{j,l}(y) + \sum_{j,k,l} d_{j,k,l}^2 \psi_{j,k}(x) \varphi_{j,l}(y) + \sum_{j,k,l} d_{j,k,l}^3 \psi_{j,k}(x) \psi_{j,l}(y)$$

其中

$$d_{j,k,l}^1 = \iint_R(x,y) \varphi_{j,k}(x) \psi_{j,l}(y) dx dy$$

$$d_{j,k,l}^2 = \iint_R(x,y) \psi_{j,k}(x) \varphi_{j,l}(y) dx dy$$

$$d_{j,k,l}^3 = \iint_R(x,y) \psi_{j,k}(x) \psi_{j,l}(y) dx dy$$

通过对上述分解算法的离散化处理(如采用 Mallat 提出的图象信号的小波分解及重构算法<sup>[6]</sup>), 可将原图象  $X$  在各个分辨率上分解为一列子图象  $\{X_j^i\}$ ,  $i=0, 1, 2, 3; j=0, 1, 2, \dots, N-1$ , 一般来讲, 在较低分辨率上分解所得的变换结果会反映出原图象中一些较明显和较大尺寸的结构特征, 而在较高分辨率上分解所得的子图象则反映了较细致的特征<sup>[6]</sup>.

然而, 在离散化处理的过程中, 我们只能以有限的精度记录和处理各个分辨率上的分解结果, 这样就不可避免地引入了频率分量的截断误差, 从而丢失了图象中的一些特征信息<sup>[6]</sup>. 而在空间域中, 图象中某一点的局部特征信息(如边缘、角点等)可以由该点的某个邻域内的有关信息来提供. 在完成了图象信号的多分辨率小波分解的基础上, 本文基于 GMRF 理论从各个子图象  $\{X_j^i\}$ ,  $i=0, 1, 2, 3; j=0, 1, 2, \dots, N-1$  中选取一组统计参数作为图象的局部特征矢量, 这种处理方法比单纯的小波分析能准确地揭示原始图象中各点的特征信息, 而且同一区域内的像素点有相近的特征向量<sup>[3]</sup>.

### 2.2 图象局部结构特征的提取

对图象  $X$  应用定义在网格  $L$  上的高斯-马尔可夫随机场模型来分析, 那么图象的每个像素点就可用一随机变量  $x_{ij}$  来表示(在下文中, 为方便起见, 有时也标为  $x_{(i,j)}$ ), 即  $X = \{x_{ij}, (i,j) \in L\}$ , 其中  $L = \{(i,j): 0 \leq i \leq M-1, 0 \leq j \leq N-1\}$ . 将二维图象  $X$  的元素以某种顺序重新排列, 形成一矢量  $\mathbf{x}$ , 那么图象  $X$  可以看作为一个高斯随机向量, 具有联合概率密度:

$$p(\mathbf{x} = \mathbf{x}) = (2\pi)^{-MN/2} |\det \Sigma|^{-1/2} \times \exp\left\{-\frac{1}{2}[\mathbf{x}]^T \cdot |\Sigma|^{-1} \cdot [\mathbf{x}]\right\}$$

其中,  $\Sigma$  是协方差矩阵, 且有

$$p(x_{ij} | x_{kl}, (k,l) \neq (i,j)) = p(x_{ij} | x_{(i,j)+(k,l)}, (k,l) \in \eta_{ij}) \quad (1)$$

这里,  $\eta_{ij}$  表示像素  $x(i,j)$  的某一邻域, 网格  $L$  上的每个像素的灰度值  $x(i,j)$  可以用其邻域  $\eta_{i,j}$  中诸像素灰度值的线性组合来估计<sup>[7]</sup>, 即

$$x_{ij} = \sum_{(k,l) \in \eta_{ij}} \theta_{kl} x_{(i,j)+(k,l)} + \delta_{ij} n, (i,j) \in L \quad (2)$$

其中,  $\theta_{kl}$  是线性组合的系数,  $\delta_{ij}^2$  是邻域内的方差,  $n$  是零均值方差为 1 的高斯白噪声. 对于确定的邻域系  $\eta$ , 式(2)中的线性组合系数可用最小二乘法来估计<sup>[8]</sup>. 如对于  $\eta^8$  邻域系(即 8-邻域系), 可取窗口为

$$q_{ij} = \begin{bmatrix} x_{(i-1,j)}, x_{(i+1,j)}, x_{(i,j-1)}, x_{(i,j+1)}, \\ x_{(i-1,j+1)}, x_{(i+1,j-1)}, x_{(i-1,j-1)}, x_{(i+1,j+1)} \end{bmatrix}^T \quad (3)$$

则用最小二乘法可以求出关于像素点  $x(i,j)$  的 8 个系数估计值

$$\hat{\theta}_{ij} = \left| \sum_{(k,l) \in \eta_{ij}} q_{kl} q_{kl}^T \right|^{-1} \sum_{(k,l) \in \eta_{ij}} q_{kl} x_{kl} \quad (4)$$

方差估计值 
$$\hat{\sigma}_{ij}^2 = \frac{1}{\omega^2} \sum_{(k,l) \in \eta_{ij}} (x_{ij} - \hat{\theta}_{ij}^T q_{kl})^2 \quad (5)$$

均值 
$$\hat{\mu}_{ij} = \frac{1}{\omega^2} \sum_{(k,l) \in \eta_{ij}} x_{kl} \quad (6)$$

上式中的  $\omega$  为窗口的尺寸, 矢量  $\hat{\theta}_{ij}$  中的每个参数表征了窗口内某个方向上其它像素对  $x(i,j)$  的影响程度, 因而这些估计参量  $(\hat{\theta}_{ij}, \hat{\sigma}_{ij}, \hat{\mu}_{ij})$  反映了图象的局部特征. 对各个分辨率上的子图象  $\{X_k^0\}$ , 利用式(4)~(6)可以从像素点  $x_{ij}^{(k)}$  周围某个小窗口内抽取一组估计参量  $(\hat{\theta}_{ij}^{(k)}, \hat{\sigma}_{ij}^{(k)}, \hat{\mu}_{ij}^{(k)})$ , 其中  $k$  表示分辨率,  $k=0, 1, 2, \dots, N-1$ , 共有  $N$  组. 这  $N$  组估计量表征了原图象  $X$  中像素  $x(i,j)$  处的局部特征. 为了减少计算量, 可以先对这  $N$  组估计量作一变换, 结果是一个维数较低的特征矢量  $\mathbf{f}_{ij}$ , 然后再进行后续的处理. 我们在仿真实验中, 将  $\hat{\theta}_{ij}^{(k)}$  的各分量累加, 得到统计量  $\hat{\gamma}_{ij}^{(k)}$ , 它是一个标量, 再结合另外两个统计估计参量  $\hat{\sigma}_{ij}^{(k)}, \hat{\mu}_{ij}^{(k)}$ , 最后所得的特征矢量  $\mathbf{f}_{ij}$  是  $3N$  维的.  $N$  的值应根据图象的大小来确定.

### 3 分割算法

采用上节中介绍的特征提取方法, 我们就定义了一个由图象  $X$  到其特征集  $XF$  的映射  $T_{n,g}$ . 由于特征向量  $\mathbf{f}_{ij}$  的各分量具有不同的量纲, 我们在算法中采用如下定义的距离  $d: \forall x, y \in XF \subset R^p$ , 
$$d(x,y) = \left| 1 - (1/p) \sum_{i=1}^p \exp(-3/4 (x_i - y_i)^2 / s_i^2) \right|^{1/2}$$
, 其中  $x_i, y_i$  中分别是向量  $\mathbf{x}, \mathbf{y}$  的第  $i$  个分量,  $s_i^2$  是第  $i$  个分量的方差.

另外, 由于  $XF$  的基数可能很大, 为使后面的分割不致形成过多的区域, 我们对映射  $T_{n,g}$  作如下修改: 令  $\alpha \in XF \subset R^p$ , 对于定义在  $R^p$  上的距离  $d$  及预

先确定的阈值  $\omega$  定义映射

$$T_{n,g,\omega}: X \rightarrow P(X),$$

$$T_{n,g,\omega}(x) = \bigcup_{d(g(x)) \leq \omega} g^{-1}\{\alpha\} \cap T_n(x)$$

这一步处理的实质就是将特征集  $XF$  中相近的特征矢量加以合并,这样可以大大减少后续处理的计算量.由特征集  $XF$  我们就可以构造一个一致性邻域超图  $H_{n,g,\omega} = \{X, \{x\} \cup T_{n,g,\omega}(x)\}$ ,若  $x, y$  属于同一超边  $E_i$ ,则表示  $x, y$  处于同一邻域内且具有相近的局部结构特征(它们特征间的相似程度用参数  $\omega$  来表示).本文采用 A. Bretto 等提出的所谓覆盖-选择分割算法(Covering & Selection Algorithm)(CS 算法)<sup>[4]</sup>进行下一步的分割处理,由于原算法是基于图象的灰度特征的,我们作了适当的修改,修改后的算法由以下 5 个步骤组成:

步骤 1 求图象的一个最小覆盖,  $E = \{H(x_1), \dots, H(x_N)\}$ .

对于预先确定的阈值  $\omega$  和邻域系  $\eta$ ,按超边及星的定义在超图  $H_{n,g,\omega}$  上求得图象  $X$  的一个具有以下性质的最小覆盖  $E: \forall x \in X$ , 则至多存在一条超边  $e \supset \{x\}$  且  $E$  中至少有一个星  $H(x_i) \supset e$ . 这一步处理的目的是限制后面各步骤中所处理星的数量.

步骤 2 合并星形成初始区域.令  $k = 1$ ,

(1) 对于所有的星  $H(x_i)$ , 其中  $k < i \leq N$ , 若  $H(x_i) \cap H(x_k) \neq \emptyset$ , 且  $d(g(x_k), g(x_i)) \leq \omega$  则  $H(x_k) \cup H(x_i)$ , 即合并它们(仅作合并标记).

(2)  $k = k + 1$ . 若  $k = N$ , 则转入下一步骤; 否则转(1).

步骤 3 对于第 2 步中形成的初始区域  $reg_1, reg_2, \dots, reg_m$ , 作区域合并处理. 令  $k = 1$ ,

(1) 对于所有的区域  $reg_i$ , 其中  $k < i \leq m$ , 若  $reg_k \cap reg_i = reg \neq \emptyset$ , 计算下列参数: 区域的重心  $p_i, p_k$ , 区域内各特征向量的均值  $\bar{\mu}_i, \bar{\mu}_k$ , 方差  $\sigma_i, \sigma_k$ . 若  $p_i \in reg$ , 且  $p_k \in reg$ ,  $d(\bar{\mu}_i, \bar{\mu}_k) \leq \alpha$ ,  $d(\sigma_i, \sigma_k) \leq \beta$ , 则  $reg_i \cup reg_k$ , 即合并它们(作合并标记), 其中的  $\alpha, \beta$  是预先取定的阈值.

(2)  $k = k + 1$ . 若  $k = m$ , 则转入下一步骤; 否则转(1).

步骤 4 将  $E$  中的每个星归并为步骤 3 所生成的区域  $R_1, R_2, \dots, R_i$  中的一个. 令  $k = l, A = \{1, 2, 3, \dots, l\}$ ,

(1) 计算区域  $R_i$  所包含星的数目  $\# R_i, \forall i \in A$ , 找出使得下式成立的  $j$ ,

$$\# R_j = \max_{i \in A} (\# R_i)$$

$A = A - \{j\}$ , 对于区域  $R_j$  中任意的星  $H(x)$ , 若存在  $t \in A$ , 使得  $H(x) \in R_t$ , 则修改区域  $R_t$  中有关星  $H(x)$  的标记, 使得区域  $R_t$  不包含星  $H(x)$ . 对区域  $R_j$  中任意的星  $H(x)$ , 赋予它们一个共同的标记  $l - (k - 1)$ , 该标记对应于这一个区域.


(2)  $k = k - 1$ . 若  $k = 1$ , 则转入下一步骤; 否则转(1).

步骤 5 孤立象素的处理

最后, 对于那些不属于任何超边的象素  $x$ , 作如下处理: 令与  $x$  相邻的象素集为  $A_x = \{x_{i1}, x_{i2}, \dots, x_{iN}\}$ , 分别计算象素  $x$  与它们之间的特征相似性测度  $d_{i1}, d_{i2}, \dots, d_{iN}$ , 因而可求得其中的最小值, 假设为  $d_{ij}, 1 \leq j \leq N$ , 找出该象素所属的区域  $R_k$ , 将  $x$  并入该区域.

## 4 仿真实验结果

在仿真实验中, 我们对两幅不同性质的图象分别采用几种目前较为典型的分割算法以及本文提出的分割算法作对比试验, 这些图象的大小都是  $160 \times 140$  象素, 灰度等级为 256. 图 2(a) 是一幅人体骨髓细胞灰度图的一部分, 我们首先采用 Abutaleb 提出的二维最大熵阈值法<sup>[1]</sup>(下文简称算法 2, 本文提出的算法为算法 1) 进行处理, 选取 5 个具有最大熵的阈值, 其结果为图 2(b), 图 2(c) 是采用算法 1 分割的结果(阈值分别是  $\omega = 0.05, \alpha = 0.075, \beta = 0.05$ ), 从图中可以看出, 算法 1 对原图象进行了正确的分割, 而且图 2(c) 还含有较多的细节.



(a) 原图象

(b) 算法 2

(c) 算法 1

图 2

图 3(a) 是一幅结构稍复杂的自然图象, 由于算法 2 对这一类图象处理的性能不理想<sup>[2]</sup>, 我们另选用两种分别称为基于曲面模型的混合型链结区域增长法(简称算法 3)和聚合法图象分割算法(简称算法 4), 这两种算法被认为是较有效的图象分割算法<sup>[9]</sup>. 其中, 图 3(b)、图 3(c) 分别是采用算法 3 和算法 1 处理后的结果) 算法 1 的阈值分别是  $\omega=0.05$ ,  $\alpha=0.075$ ,  $\beta=0.05$ . 为检验本文所提出的算法对低

信噪比图象的分割性能, 我们对图 3(a) 加入不同程度的噪声, 分别采用算法 1、算法 3 和算法 4 作对比试验, 分割所得的区域数列于表 1 中. 由于上述几种算法大都为迭代分割算法, 对它们在算法的复杂性及运算量方面作精确的比较较为困难. 我们在表 2 中列出了这几种算法的 PC 机仿真处理的时间花费. (表 1、表 2 中的  $\sigma$  为噪声方差值).




图 3

表 1

算法	阈值	原图象	$\sigma=5$	$\sigma=10$
算法 1	$\alpha=0.05, \beta=0.08, \omega=0.05$	514	549	716
算法 3	$\alpha=0.10$	485	823	1 348
算法 4	10, 迭代次数为 2	756	913	1 657

表 2

单位: s

算法	原图象	$\sigma=5$	$\sigma=10$	$\sigma=20$
算法 1	145	168	210	347
算法 3	135	359	421	571
算法 4	94	251	324	638

从上述实验可以看出, 无论是区域数还是分割速度, 对具有较高信噪比的图象, 基于超图理论的 CS 算法和算法 3、算法 4 大致接近, 而对于混有噪声的图象, 算法 1 具有良好的稳定性, 受噪声的影响较小.

## 5 结束语

本文介绍了一种新的图象处理图论模型——超图, 它使得人们能够借助组合最优化等一类数学工具来解决诸如图象分割、模式分析等问题. 应用这种数学模型的关键是根据研究对象及其目的建立恰当的关系, 继而构造出相应的超图. 本文应用该模型提出了一种基于图象的空-频域特征的图象分割方法. 仿真实验表明, 该算法具有较好的稳定性, 受噪声的影响较小.

## 参考文献

- 1 Abutaleb A S. Automatic thresholding of gray level pictures using two dimensional entropy. CVGIP, 1989, 47: 22~ 32.
- 2 张毅军, 吴雪菁, 夏良正. 二维熵阈值图象分割的快速递推算法. 模式识别与人工智能, 1997, 10(3): 257~ 264.
- 3 Derin H, Elliot H. Modelling and segmentation of noisy and textured images using Gibbs random field. IEEE Trans. PAMI, 1987, 9(1): 93~ 104.
- 4 Bretto A, Azema J, Cherifi H, et al. Combintorics and image processing. CVGIP: Graphical Models and Image Processing, 1997, 59(5): 265~ 277.
- 5 Berge C. Hypergraphs. North-Holland, Amsterdam, 1987.
- 6 Mallat S G. A theory for multiresolution signal decomposition: the wavelet representation. IEEE Trans. PAMI, 1989, 11(7): 674~ 693.
- 7 Chellappa R, Kashyap R L. Texture synthesis using 2-D non-causal autoregressive Models. IEEE Trans Acoust Speech Signal Process, 1985, 33(11): 194~ 203.
- 8 Chen C H, Lee G G. On digital mammogram segmentation and microcalcification detection using multiresolution wavelet analysis. Graphical Models and Image Processing, 1997, 59(5): 349~ 364.
- 9 徐建华. 图象处理与分析. 北京: 科学出版社, 1994.



耿伯英 1967年生, 讲师, 在职博士研究生, 合作编写大学教材两部, 在国内外学术期刊发表论文 10 余篇, 曾获军队科技进步二等奖一次. 主要从事人工智能模式识别以及不确定推理等领域的研究.