

非参数化区域竞争方法:一种新的 图像分割框架¹⁾

唐 明 马颂德

(中国科学院自动化研究所模式识别国家重点实验室 北京 100080)

(E-mail: tangm@nlpr.ia.ac.cn)

摘 要 提出了一种新的图像分割框架——非参数化区域竞争算法. 这种算法克服了基于尺度空间滤波的特征空间聚类法的缺陷, 提高了原区域竞争算法的性能, 并且采取了一种自动选取种子位置及大小的形式化策略. 非参数化区域竞争算法可以把图像分割成统计意义上并不具有一致性, 但在应用中更有意义的区域, 称这样的分割为语义一致(或均匀)的分割. 非参数化区域竞争算法把定量地控制分割结果中的区域个数和语义一致的分割结合起来, 从而净化了分割结果, 并且可以降低后继算法的复杂度.

关键词 主动边界, 区域增长, 区域竞争, 语义一致的分割.

NON-PARAMETRIC REGION COMPETITION: A NEW SCHEME FOR IMAGE SEGMENTATION

TANG Ming MA Song-De

(National Laboratory of Pattern Recognition, Institute of Automation, Chinese Academy of Sciences, Beijing 100080)

(E-mail: tangm@nlpr.ia.ac.cn)

Abstract This paper presents a non-parametric region competition scheme which combines scale-space clustering and region competition to segment the image. It also proposes a formal and general procedure to automatically find the initial regions. Our algorithm can segment an image into regions which are not homogeneous in the sense of statistics, but homogeneous in the sense of semantics with respect to the segmentation context. We call it semantically homogeneous segmentation of the image. Using both semantic homogeneity and quantitative control of the number of the resultant homogeneous regions, our algorithm may produce a 'clean' resultant image, thus simplifying the following procedures.

Key words Region competition, region growing, segmentation, semantic homogeneity.

1) 航天机电集团总公司第二院 207 所实体办资助课题.

收稿日期 1999-09-02 收修改稿日期 2000-09-10

1 引言

图像分割是计算机视觉中的经典难题之一,它的目的是把图像空间分割成若干个在某种意义下均匀的不重叠区域,为后继工作做准备.图像分割是建立在区域特征的相似性及非连续性两个概念上:

- 1) 相似性,同一区域中像素的特征是相似的;
- 2) 非连续性,不同区域间像素的特征存在突变,例如灰度的突然变化等.

目前还没有普遍适用的图像分割算法,现有的算法通常都是针对不同的图像类型,各有其适用范围和优缺点.粗略地讲,图像分割方法可以分为以下五大类^[1,2]:

- 特征空间分类法^[3,4],
- 基于边缘的分割方法^[5~7],
- 基于区域的分割方法^[8~10],
- 全局优化方法^[11,12],
- 综合边缘和区域方法的混合分割方法^[13,14].

特征空间分类法简便易行,因而得到广泛的应用;缺点是由于噪音的影响,其分割结果中区域边缘可能很不规则,并且通常会出现一些无意义的小区域.

一般来说,由于混合分割法综合考虑了边缘和区域信息,能对分割结果中边缘和区域的特征同时加以约束,因而往往可以得到较好的结果,例如,区域竞争方法^[14]综合了主动轮廓模型和区域增长算法的长处.在它的分割结果中,区域边缘可以保持规整性并且通常会大大减少分割结果中出现的无意义的小区域.但是这种方法无法定量地控制最终的区域个数,且区域的合并是组合优化问题,计算代价很高.

针对分割算法的上述缺陷,我们在本文中提出了一种新的混合图像分割方法——非参数化区域竞争算法.这种算法克服了特征空间分类法^[3,4]和区域竞争算法^[14]的缺陷,并且采取了一种自动选取种子位置及大小的形式化策略.非参数化区域竞争算法可以把图像分割成统计意义上并不具有一致性,但却在某种应用中更有意义的区域,我们称这样的区域为在某种语义上一致(均匀)的区域,这样的分割为在某种语义上一致(均匀)的分割,或简称为语义一致(均匀)的分割,而统计一致的分割只是语义一致的分割的特例.非参数化区域竞争算法把定量地控制分割结果中区域的个数和语义一致的分割结合了起来,从而净化了分割结果,并且可以降低后继算法的复杂度.

通过借鉴参数化区域竞争算法^[14]的基本思想,本文描述了非参数化区域竞争方法的基本理论,给出了选取种子的形式化方法,提出本算法所要用到的条件概率的近似计算方法.最后给出非参数化区域竞争的完整算法及实验结果.

2 基本理论

假设图像定义域 R 初始地被分为 l 个区域 $R_i (i=1, 2, \dots, l)$, 并且满足条件

$$R = \bigcup_{i=1}^l R_i, \text{ 且当 } i \neq j \text{ 时, } R_i \cap R_j = \emptyset.$$

设 $\Gamma_i = \partial R_i$ 为 R_i 的轮廓线. 对于 R_i 的外轮廓部分,其轮廓方向为逆时针;对于 R_i 的内

轮廓部分(如 R_i 包含小孔的情况),其轮廓方向为顺时针.所有这些边缘构成集合 $\Gamma = \bigcup_{i=1}^L \Gamma_i$.

为使分割结果中各区域的轮廓线平滑,并保证各区域的(统计或语义)相似性及非连续性,参考文[14],定义如下分割泛函

$$E[\Gamma] = \sum_{i=1}^L \left\{ \mu \oint_{R_i} ds - \log P(\{x(p) | p \in R_i\}) \right\}.$$

上式中第一项 $\oint_{R_i} ds$ 为区域 R_i 的轮廓线 Γ_i 的长度,它的作用是保持分割结果中各区域轮廓线的平滑, μ 为加权系数;第二项则反映了分割结果中各区域在某种(统计或语义)意义下特性的一致性,分割结果中各区域中这种一致性越强,此项值越小,这里 $x(p)$ 表示在像素 p 处的特征向量, $P(\{x(p) | p \in R_i\})$ 为区域 R_i 中全部像素的特征向量的总概率.

假设各像素的特征向量 $x(p)$ 相互独立,则有

$$\log P(\{x(p) | p \in R_i\}) = \int_{V_i} \log \hat{p}(x(p) | p \in R_i),$$

其中 $V_i = \{x(p) | p \in R_i\}$, $\hat{p}(x(p) | p \in R_i)$ 为在像素 p 属于区域 R_i 条件下 p 点特征向量 $x(p)$ 的条件概率.

为了得到较好的分割结果,需要使上述分割泛函极小化.极小化过程采用关于 Γ 的最速下降法来实现.在极小化过程中,根据统计或语义意义下的一致性,初始分割区域 R_i 可以变形.

根据最速下降法,对任意轮廓点 $p \in \Gamma$,其变化满足如下运动方程

$$\frac{dp}{dt} = - \frac{\delta E[\Gamma]}{\delta p}.$$

利用欧拉-拉格朗日方程,可以求得上述泛函变分的表达式

$$\frac{dp}{dt} = \sum_{i \in Q(p)} \{ -\mu k_{i(p)} + \log \hat{p}(x(p) | p \in R_i) \} n_{i(p)}.$$

这就是任一轮廓点 p 的运动方程,也称为 Γ 的运动方程.这里 $Q(p) = \{i | p \in \Gamma_i\}$.上式中的求和是在所有那些轮廓上含有像素 p 的区域上进行的, $k_{i(p)}$ 为轮廓点 p 所在的区域边缘 Γ_i 在该点处的曲率,而 $n_{i(p)}$ 则为上述区域边缘 Γ_i 在点 p 处的单位法向量.

初始分割区域上的所有轮廓点都依上述运动方程运动,当对任何 $p \in \Gamma$ 都有 $dp/dt = 0$ 时,分割泛函达到极小,各区域不再变化,于是分割终止.

要应用上述 PDE 来分割图像,必须解决两个问题.第一是如何确定初始分割区域;第二是怎样估算条件概率 $\hat{p}(x(p) | p \in R_i)$.在下两节中,将讨论它们的解决方案.

3 初始分割区域的确定

为了确定初始分割区域,我们首先提出以下两步分类算法^[15]对图像中的所有像素进行粗分类.

算法 1(基于尺度空间滤波的像素分类).令 k 为算法参数,表示最终结果中的区域数.

1) 选取适当的特征组,构造图像 I 的 n 维特征空间(即特征直方图) $\hat{p}_v(x)$,其中 x 为特征向量, n 为整数,且 $n \geq 1$.

2) 若 $\hat{p}_v(x) = 0$,则将此特征向量 x 记为空,亦即 I 中没有特征向量为 x 的像素.

3) 计算特征直方图 $\hat{p}_v(\mathbf{x})$ 的多尺度平滑结果 $\hat{p}_\sigma(\mathbf{x})$, 即

$$\hat{p}_\sigma(\mathbf{x}) = \hat{p}_v(\mathbf{x}) * G_\sigma(\mathbf{x}),$$

其中 $G_\sigma(\mathbf{x})$ 为相同维数的高斯滤波器, σ 为滤波器尺度. 从预先设定的初始滤波尺度 σ_0 开始, 按照一定步长 $\Delta\sigma$ 增大滤波器尺度, 得到 $\hat{p}_v(\mathbf{x})$ 的一系列多尺度平滑结果. 随着 σ 的增加, 在较大的尺度范围 T_σ 内 (可预先设定 T_σ 的长度阈值), $\hat{p}_\sigma(\mathbf{x})$ 的极大点数会保持不变. 取在 T_σ 中最小值 σ_1 下的平滑结果 $\hat{p}_{\sigma_1}(\mathbf{x})$ 作为图像特征的基本分布结构. 这里之所以取 σ_1 是因为此时的滤波尺度较小, 造成的极点漂移也较小, 从而使滤波对最终分割质量的影响也较小.

4) 求出 $\hat{p}_{\sigma_1}(\mathbf{x})$ 的所有局部极大值点集 M . 每个极大值点代表一个特征空间聚类.

5) 若 p_m 为特征向量 \mathbf{x} 利用梯度上升法达到的极大值点, 则把 \mathbf{x} 归入 p_m 所代表的聚类中. 重复这一步骤直至把所有特征向量都归入相应的聚类中.

6) 依据不同的分割要求, 选取适当的分类算法 (如 k 均值方法、非线性判别函数法等) 和距离度量 (如欧几里德度量等), 将 M 划分为 k 类 ($|M| \geq k$), 即将步骤 5) 所得到的 $|M|$ 个聚类 $\omega_i (i=1, 2, \dots, |M|)$ 划分到 k 个类 $c_j (j=1, 2, \dots, k)$ 中, 并记 c_j 中的聚类为 ω_{ij} . 若 $k=0$, 则指定 $k=|M|$.

7) 对于任意特征向量 \mathbf{x} , 若 $\mathbf{x} \in \omega_i$, 而 ω_i 又在步骤 6) 中被分入类 c_j , 则将 \mathbf{x} 分入 c_j .

8) 对于 I 中任一点 p , 若 $\mathbf{x}(p)$ 已被分入类 c_j , 则标记点 p 属于 c_j . 重复这一步骤直至完成所有像素的分类.

在算法 1 中, 如果 $k=0$, 则称结果为统计均匀的分割; 否则, 称结果为语义均匀的分割.

通过上述算法, 可以得到所有像素的一个粗分类. 由于对那些特征点位于特征直方图局部极大值点附近的像素而言, 误分类的可能性很小, 而且希望种子类别的确定应当没有或只有极少的误差. 因此, 只取特征点位于特征直方图局部极大值点附近的像素作为种子就是一个必然的选择.

下面给出确定初始分割区域的具体算法.

算法 2 (确定分割的种子区域).

1) 通过算法 1 将所有特征点分为 k 类, 记作 $c_j (j=1, 2, \dots, k)$. 记 $\omega_{ij} (i=1, 2, \dots, k_j)$ 为被分入类 c_j 的第 i 个聚类, k_j 为类 c_j 中的聚类总数. 这里不考虑在算法 1 中已被标记为‘空’的特征点.

2) 对任一聚类 ω_{ij} , 计算

$$\hat{p}_{ij}(\mathbf{x} | \mathbf{x} \in \omega_{ij}) = \frac{\hat{p}_{\sigma_1}(\mathbf{x})}{\sum_{z \in \omega_{ij}} \hat{p}_{\sigma_1}(z)},$$

式中 $\hat{p}_{\sigma_1}(\mathbf{x})$ 为由算法 1 得到的图像特征的基本分布结构. 对图像中任意像素 p , 若 $\hat{p}_{ij}(\mathbf{x}(p)) > P_{ij}$, 则在图像中以此点为中心取一个 $n_w \times n_w$ 的窗口, 若此窗口和其它类的种子区域无重叠之处, 则将此窗口中的点作为类 c_j 的一个种子区域. 这里 P_{ij} 和 n_w 为预先设定的阈值.

3) 若几个同一类的种子区域之间存在相互重叠的部分, 则将它们合并为一个新的种子区域.

4) 去掉太小的孤立种子区域 (这里的孤立指的是被其它类的种子区域所包围). 剩下的种子区域和背景区域 (即不被任何种子占据的像素) 构成了初始分割区域.

4 条件概率的估算

由算法 1,可以得到图像像素特征向量 \mathbf{x} 所属的各类 c_j 及其所含的 ω_{ij} . 对于所有的特征向量 \mathbf{x} 和聚类 ω_{ij} , 设

$$w_{ij}(\mathbf{x}) = \begin{cases} \hat{p}_{o_1}(\mathbf{x}), & \text{如果 } \mathbf{x} \in \omega_{ij}; \\ \epsilon, & \text{其它.} \end{cases}$$

这里 $\epsilon < 1$ 是一个充分小的正实数. 定义

$$\hat{p}(\mathbf{x} \in \omega_{ij}) = \frac{w_{ij}(\mathbf{x})}{\sum_{\omega_{pq} \in \Omega} w_{pq}(\mathbf{x})},$$

式中 Ω 是所有聚类所组成的集合.

得到以上各条件概率的估算表达式后,可以写出 Γ 运动方程中的条件概率表达式

$$\hat{p}(\mathbf{x}(p) | p \in R_i) = \sum_{\omega_{ij} \subset c_j} \hat{p}(\mathbf{x} \in \omega_{ij}),$$

式中 c_j 为初始分割区域 R_j 所对应的类别.

在 Γ 的运动过程中,为使背景 B (即没有被种子占据的区域) 在竞争中处于不利地位,定义

$$\hat{p}(\mathbf{x}(p) | p \in B) = \epsilon^2.$$

5 非参数化区域竞争算法

算法 3 (非参数化区域竞争算法).

1) 通过算法 1 和算法 2 得到初始分割区域.

2) 各区域轮廓点基于 Γ 的运动方程,使得不同类的各相邻区域间互相竞争而形变、膨胀或收缩. 重复此步骤直到 Γ 保持稳定,则算法终止.

由于采用了尺度空间滤波的方法(算法 1)来选取种子区域,本算法对噪声不敏感;由于在最终分割中采用了区域竞争策略,它克服了特征空间分类法的缺陷(实际上特征空间分类法只是本方法的一个特例);由于本算法实现了种子区域自动选取,以及把定量控制分割区域数量与语义一致的分割结合了起来,从而改进了现有的分割方法.

6 实验结果

6.1 SAR 图像的分割

图 1(a) 是一幅用于洪水监测的 SAR 图像. 我们选用均值和相关作为图像特征^[16], 并采用 5×5 窗口计算它们. 其特征直方图经滤波后共存在五个局部极大值点, 即 $M = \{(49, 25), (19, 25), (37, 72), (20, 135), (41, 137)\}$. 基于洪水监测的目的, 我们对以下三种语义一致的分割感兴趣: 1) 分为三类(天然水区, 水淹区和未淹区); 2) 分为两类(天然水区和其它); 3) 分为两类(有水区和其它).

对于分割 1), 采用 k 均值方法 ($k=3$) 把五个极大值点分为以下三类: $\{(49, 25), (19,$

25)}, {(37,72)}和{(20,135),(41,137)}. 基于这样的分类,可以得到本方法的最终分割结果如图 1(b)所示.

对于分割 2),根据语义意义下的一致性将上述五个极大值点分为以下两类:{(49,25),(19,25),(37,72)}和{(20,135),(41,137)}. 据此可以得到本方法的最终分割结果如图 1(c)所示.

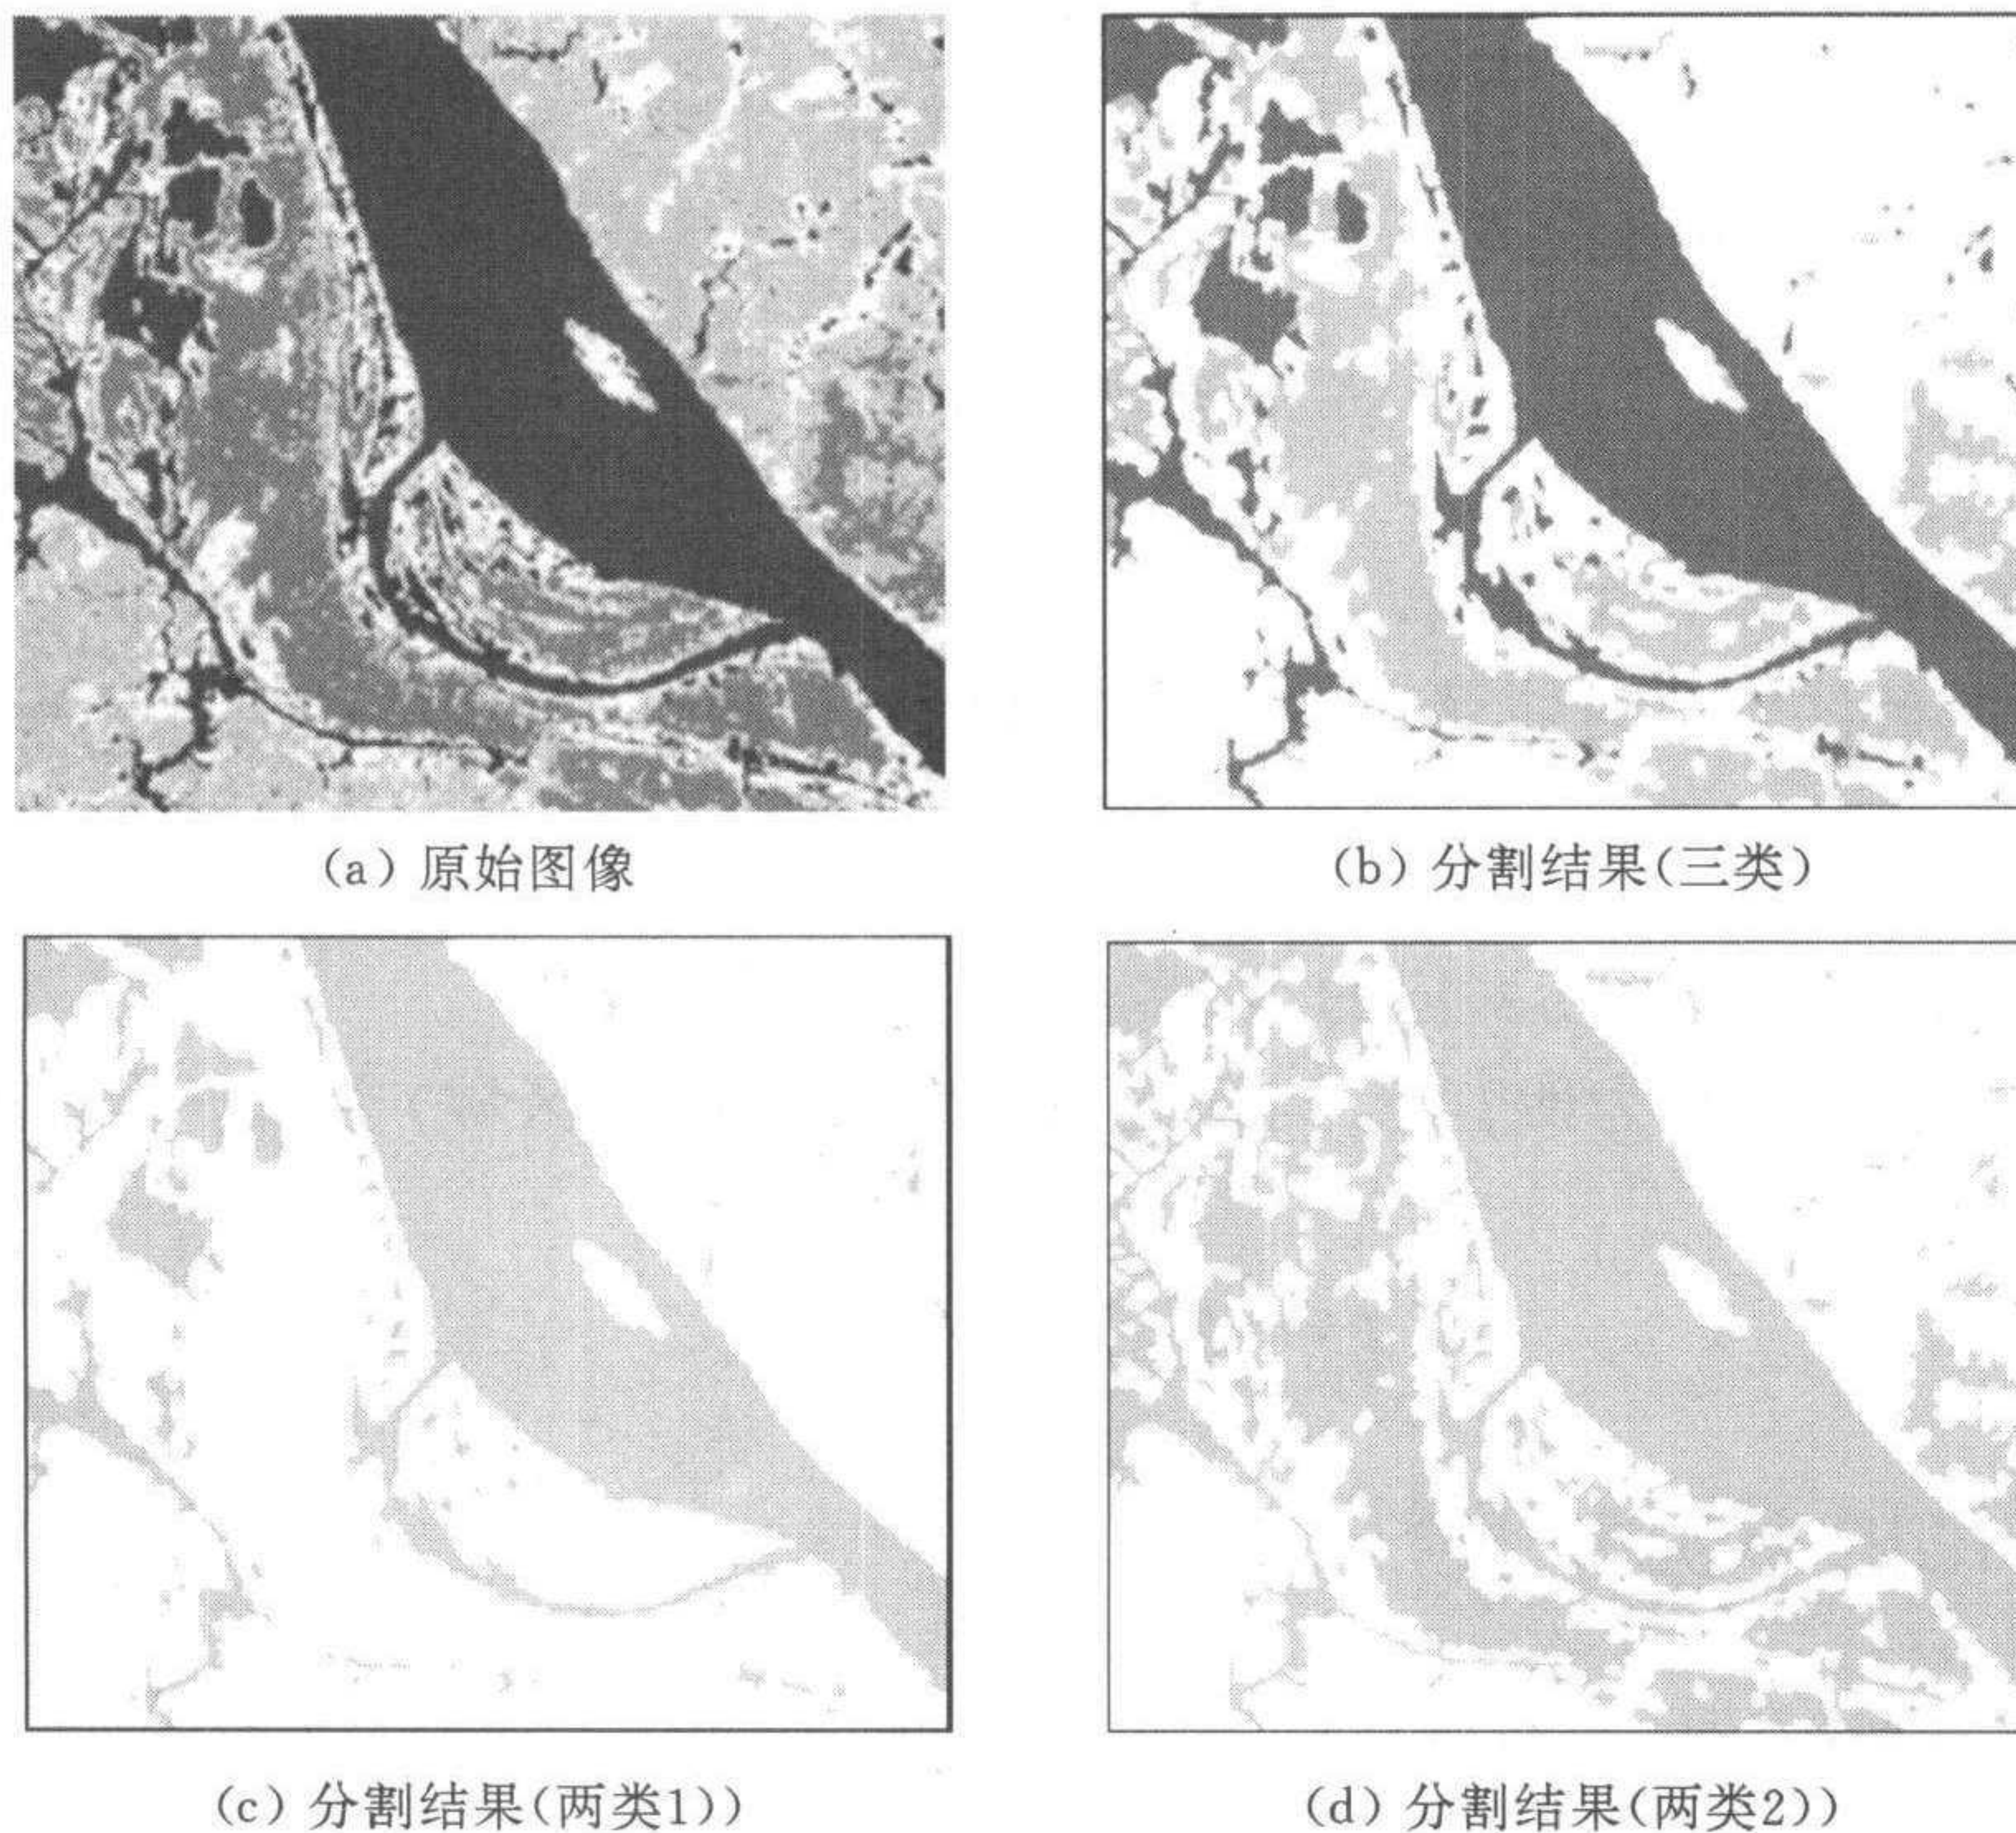


图 1 SAR 图像分割实验

对于分割 3),根据语义意义下的一致性将上述五个极大值点分为以下两类:{(49,25),(19,25)}和{(37,72),(20,135),(41,137)}. 据此可以得到相应的分割结果如图 1(d)所示.

6.2 人手图像的分割

图 2 是一幅关于人手和橡胶圈的彩色图像. 我们用每个像素的 5×5 高斯窗计算该点的平均强度、色度和饱和度,并就其作为分割图像的特征. 之所以不采用 RGB 为特征是因为强度、色度和饱和度更容易解释色彩感知,从而有利于算法中极大值点的分类. 在本实验中,我们对以下两种分割感兴趣:一个是统计一致的分割,图 2(b)所示为相应的分割结果;另一



图 2 人手图像实验结果(其中 t 表示竞争算法中的循环数)

个是语义一致的分割,即将橡胶圈单独为一类,其它部分为另一类,相应的分割结果如图 2(c)所示.由于获得第二种分割的循环次数低于第一种,从而获得第二种分割的时间也低于第一种.

如果分割图 2 的目的是为了识别橡胶圈,则上述语义一致的分割对于这种目的更有利.这不仅仅是由于获得第二种分割的时间较短,也因为利用语义一致的分割甚至不需要复杂的识别算法,而只需要找出边缘像素的位置.相反,如果使用统计一致的分割结果(图 2(b))来识别橡胶圈,就需要设计一种相对复杂的识别算法.

以上两个实验说明了把定量控制分割区域数量和语义一致的分割结合起来的意义.

7 结论

本文提出了一种新的图像分割框架——非参数化区域竞争框架.它首先利用基于尺度空间滤波的一种两步分类法^[15]和一种自动选取种子位置及大小的形式化策略确定初始分割区域,然后基于这些区域,采用合理的区域竞争策略求得最终的分割结果.本法通过把定量控制最终分割区域数量和语义一致的分割结合起来净化了分割结果.

参 考 文 献

- 1 Haralick R M, Shapiro L M. Image segmentation techniques. *CVGIP*, 1985, **29**:100~132
- 2 Pal N R, Pal S K. A review on image segmentation techniques. *PR*, 1993, **26**(9):1277~1294
- 3 Sahoo P K, Soltani S, Wong A K C. A survey of thresholding techniques. *CVGIP*, 1988, **41**:233~260
- 4 Roberts S J. Parametric and non-parametric unsupervised cluster analysis. *Pattern recognition*, 1997, **30**(2):261~272
- 5 Canny J F. A computational approach to edge detection. *IEEE Trans. PAMI*, 1986, **8**(6):679~698
- 6 Caselles V, Kimmel R, Sapiro G. Geodesic active contour. *IJCV*, 1997, **22**(1):61~79
- 7 Ma S D, Li B C. Derivative computation by multiscale filters. *Image and Vision Computing*, 1998, **6**:43~53
- 8 Cheevasuvit H, Maitre H, Vidal-Madjar D. A robust method for picture segmentation based on split-and-merge procedure. *CVGIP*, 1986, **34**:268~281
- 9 Chen S-Y, Lin W-C, Chen C-T. Split-and-merge image segmentation based on localized feature analysis and statistical tests. *CVGIP: GMIP*, 1991, **53**(5):457~475
- 10 Adams R, Bischof L. Seeded region growing. *IEEE Trans. PAMI*, 1994, **16**(6):641~647
- 11 Geman S, Geman D. Stochastic relaxation, gibbs distributions and the bayesian restoration of images. *IEEE Trans. PAMI*, 1984, **6**(6):721~741
- 12 Leclerc Y G. Constructing simple stable descriptions for image partitioning. *IJCV*, 1989, **3**:73~102
- 13 Pavlidis T, Liow, Y-T. Integrating region growing and edge detection. *IEEE Trans. PAMI*, 1990, **12**(3):225~233
- 14 Zhu S C, Yuille A L. Region competition: Unifying snakes, region growing and bayes/MDL for multiband image segmentation. *IEEE Trans. PAMI*, 1996, **20**(3):884~900
- 15 Tang M, Xiao J, Ma Song-De. Two-Step Classification Based on Scale Space, In: 15th ICPR, Barcelona, Spain, 2000
- 16 Haralick R M, Shapiro L M. *Computer and Robot Vision*, Vol. 1. Reading, MA: Addison Wesley, 1993

唐 明 男,1987年毕业于浙江大学,现为中科院自动化所模式识别实验室在职博士生.研究方向为计算机视觉、模式识别和图像处理.

马颂德 男,1968年毕业于清华大学,1983年获法国第六大学工程博士学位,1986年获该校国家博士学位,研究员,博士生导师,IEEE高级会员.现任国家科技部副部长.