

基于边缘和区域信息的接力型活动轮廓图像分割模型^①

冯昌利^{②*} 张建勋^{③*} 代煜^{***}

(*南开大学信息技术科学学院机器人与信息自动化研究所 天津 300071)

(**哈尔滨工业大学机器人技术与系统国家重点实验室 哈尔滨 150001)

摘要 针对用于图像分割的传统单一和组合活动轮廓模型对初始轮廓敏感或者不能处理灰度不均匀图像的问题,提出了一种综合图像的全局、局部等区域信息和边缘信息的新的组合活动轮廓模型。该模型首先将全局灰度拟合能量、局部灰度拟合能量进行线性组合,组合后的能量再与由边缘探测算子构造的长度能量组成新的能量项;然后根据能量主体变化规律调整组合权重,继而用其分成的两种组合活动轮廓模型先后对图像分割;最后利用高斯滤波函数对水平集函数正则化。同时提出了模型转换、停止准则,实现了模型的自动转换和自动停止。对人工合成图像和真实图像的数值实验表明,该模型对噪声、各种初始轮廓均具有较好的鲁棒性,并具备分割灰度不均匀图像的能力。

关键词 活动轮廓模型,边缘探测函数,全局灰度,局部灰度,灰度不均匀,图像分割

0 引言

图像分割是图像处理的一个重要研究领域,它将整个图像区域分为若干满足某种条件的、互不相交的子区域,在理论研究和应用研究上都受到了广泛重视。活动轮廓模型是图像分割的重要方法,根据其表达方式和实现的不同可分为两类:参数活动轮廓模型和几何活动轮廓模型。前者由 Kass 等人^[1]于 1987 年提出,后者由 Caselles^[2]和 Malladi^[3]等分别独立提出。几何活动轮廓根据其使用的图像信息分为两类:基于图像边缘信息的模型^[4]和基于区域信息的模型。前者主要利用图像边缘信息使演化曲线停止在目标边界处,但其对图像的低对比度部分缺乏合理的处理机制,因而易边界泄漏。后者主要使用区域的统计信息,因而模型较多,其中 Chan-Vese(C-V)模型^[5]基于分割区域内部灰度一致的假设,利用全局灰度信息实现了图像的分割,但其不能分割带有不均匀灰度的图像。Li 等^[6]提出了区域尺度化拟合(region scalable fitting, RSF)模型,它利用尺度化区域匹配能量实现了对灰度不均

匀图像的分割,属于基于局部信息的模型。Zhang 等^[7]提出了局部图像拟合(local image fitting, LIF)模型,它利用局部匹配能量方程也实现了对灰度不均匀图像的分割。上述两种局部灰度信息模型对于初始轮廓的位置、大小、形状比较敏感。Zhang 等^[8]还提出了一种全局或局部分割可选择的活动轮廓模型,它根据不同的轮廓设置可选择实现全局分割或局部分割。同时,文献[9-12]尝试将边缘信息、区域信息和其他先验知识结合起来,组成了新的能量模型,它成功分割了灰度不均匀的图像。刘瑞娟等^[13]引入固定的权重将全局能量和局部能量线性组合实现了对灰度不均匀图像的分割,该方法对初始轮廓不敏感,权重值由实验得出,对各类型图像的适应性不强。

为了克服以上单一和组合模型对初始轮廓依赖度高或对灰度变化适应性差的缺点,本文提出了一种基于边缘和区域信息的接力型活动轮廓图像分割模型,该模型继承了 CV 模型和 RSF 模型的优点,对初始轮廓的位置、大小、形状不敏感,且具有分割灰度不均匀和含噪声的图像的能力。

① 863 计划(2009AA044001)及机器人技术与系统国家重点实验室开放研究(SKLR-S-2010-MS-01)资助项目。

② 男,1985 年生,博士生;研究方向:数字图像处理;E-mail: taichl@mail.nankai.edu.cn

③ 通讯作者,E-mail: zhjx@robot.nankai.edu.cn

(收稿日期:2012-06-04)

1 基于区域的活动轮廓图像分割模型

1.1 C-V 模型

基于全局灰度信息的 C-V 模型^[5]利用了前景区域和背景区域之间的灰度差异,使水平集演化停止在目标边界。C-V 模型假设图像的背景和前景具有均匀的灰度,其能量泛函为

$$E^{CV}(\phi) = \int_{\Omega} [u\delta(\phi) |\nabla \phi| + \lambda_1 |I - c_1|^2 H(\phi)] dX + \lambda_2 \int_{\Omega} |I - c_2|^2 (1 - H(\phi)) dX \quad (1)$$

其中, ϕ 是水平集函数, I 表示待分割的图像, c_1 和 c_2 分别为 $\phi > 0$ 和 $\phi < 0$ 区域的平均灰度, λ_1 和 λ_2 为权重系数, $u \geq 0$, $H(\phi)$ 和 $\delta(\phi)$ 分别为 Heaviside 函数和 Dirac 函数。

最小化上述水平集函数,得到水平集函数演化方程^[5]为

$$\frac{\partial \phi}{\partial t} = \delta(\phi) [u \cdot \text{div}\left(\frac{\nabla \phi}{|\nabla \phi|}\right) - \lambda_1 (I - c_1)^2 + \lambda_2 (I - c_2)^2] \quad (2)$$

其中, c_1 和 c_2 的计算方式为

$$c_1 = \frac{\int_{\Omega} I(x, y) H(\phi(x, y)) dx dy}{\int_{\Omega} H(\phi(x, y)) dx dy} \quad (3)$$

$$c_2 = \frac{\int_{\Omega} I(x, y) [1 - H(\phi(x, y))] dx dy}{\int_{\Omega} [1 - H(\phi(x, y))] dx dy} \quad (4)$$

式(1)和式(3)、(4)中引入了 Heaviside 函数和 Dirac 函数,但实际应用中使用各自的正则化函数 H_{ε} 和 δ_{ε} 代替^[14]:

$$H_{\varepsilon}(x) = \begin{cases} 1, & x > \varepsilon \\ \frac{1}{2} \left(1 + \frac{x}{\varepsilon} + \frac{1}{\pi} \sin\left(\frac{\pi x}{\varepsilon}\right) \right), & |x| \leq \varepsilon \\ 0, & x < -\varepsilon \end{cases} \quad (5)$$

$$\delta_{\varepsilon}(x) = \begin{cases} \frac{1}{2\varepsilon} \left[1 + \cos\left(\frac{\pi x}{\varepsilon}\right) \right], & |x| \leq \varepsilon \\ 0, & |x| > \varepsilon \end{cases} \quad (6)$$

C-V 模型充分利用了图像同质区域的全局统计信息,而未考虑具有灰度不均匀的图像的问题。灰度不均匀是指图像中某个子区域内图像灰度值随着位置的变化而改变。特别在医学图像中,很多图像具有灰度不均匀性,如超声图像、计算机断层扫描图像、核磁共振图像等。

图 1 所示为灰度均匀和不均匀图像。图 1(a) 为人造图像,无论前景区域还是背景区域灰度均保持一致,为灰度均匀图像;图 1(b) 为脑部核磁共振图像;图 1(c) 为图 1(b) 图像的灰度不均匀区域。从图 1(c) 图像可见图像内部区域不同位置处灰度值的变化,因此图 1(b) 图像为灰度不均匀图像。




图 1 灰度均匀和不均匀图像

由于 C-V 模型没有针对灰度不均匀图像的设计,因此该模型对于该类图像分割定位不准确,甚至得到错误的结果。

1.2 RSF 模型

RSF 模型是 Li 等^[6]提出的用于分割具有灰度不均匀图像的分割方法,该模型使用图像局部区域内的灰度统计信息作为局部拟合能量项。其能量泛函为

$$E^{RSF}(C, f_1, f_2) = v \int_{\Omega} \delta(\phi) |\nabla \phi| dX + \sum_{i=1}^2 \lambda_i \int_{\Omega_i} \left(\int_{\Omega_i} K_{\sigma}(x - y) |I(y) - f_i(x)|^2 dy \right) dx \quad (7)$$

其中 $\Omega_1 = \text{outside}(C)$, $\Omega_2 = \text{inside}(C)$, C 为演化中闭合轮廓曲线, K_{σ} 为标准差为 σ 的高斯核函数, $\delta(\phi)$ 为 Dirac 函数, $f_i (i = 1, 2)$ 为局部匹配函数

$$f_i(X) = \frac{K_{\sigma}(X) * [M_{\varepsilon}^i(\phi(X)) I(X)]}{K_{\sigma}(X) * M_{\varepsilon}^i(\phi(X))} \quad (8)$$

用以近似表示轮廓 C 内部和外部的灰度值。其中 $*$ 为卷积运算,下同。

最小化 E^{RSF} , 得到

$$\frac{\partial \phi}{\partial t} = \delta_{\varepsilon}(\phi) \left[v \text{div}\left(\frac{\nabla \phi}{|\nabla \phi|}\right) - (\lambda_1 e_1 - \lambda_2 e_2) \right] \quad (9)$$

其中 $M_{\varepsilon}^1(\phi) = H_{\varepsilon}(\phi)$, $M_{\varepsilon}^2(\phi) = 1 - H_{\varepsilon}(\phi)$, $e_1(x) = \int_{\Omega} K_{\sigma}(y - x) |I(x) - f_1(y)|^2 dy$, $e_2(x) = \int_{\Omega} K_{\sigma}(y - x) |I(x) - f_2(y)|^2 dy$ 。由式(8)可以看出, f_i 是像素 X 邻域中灰度的加权平均值, f_i 的引入使该模型具备了处理灰度不均匀图像的能力。但是,该模型

对初始轮廓比较敏感。如果初始轮廓设置不当,获得的分割结果可能不理想。

1.3 组合活动轮廓模型

刘瑞娟^[13]等提出了一种融合局部和全局图像信息的组合活动轮廓模型:

$$E = \omega E^{\text{RSF}} + (1 - \omega) E^{\text{CV}} \quad (10)$$

该模型将以上全局、局部能量模型线性组合,实现了对图像的分割。

但该模型使用固定的组合权重 w , 经大量实验取值 0.9。该模型虽然可以处理多数灰度不均匀图像,但是固定的权重使模型的适应能力不足,不能处理泛函能量比重发生变化的情况。

2 接力型的综合活动轮廓模型

2.1 模型及相关说明

综合 C-V 模型^[5]、RSF 模型^[6]、组合模型^[13]和由边缘探测函数构造的长度能量项^[14],本研究提出了一种新的“接力型”活动轮廓模型 (relay active contour model, RACM), 其能量泛函为

$$E^{\text{RACM}} = w' \sum_{i=1}^2 \lambda_i \int \left(\int_{\Omega_i} K_{\sigma}(x-y) |I(y) - f_i(x)|^2 dy \right) dx + w \sum_{i=1}^2 \lambda_i \int_{\Omega_i} |I - c_i|^2 M_{\sigma}^i(\phi) dX + \beta L_g(\phi) \quad (11)$$

其中 $\lambda_1 = 1, \lambda_2 = 1, \Omega_i, M_{\sigma}^i, K_{\sigma}$ 等同以上模型。可以看出,式(11)等号右侧第一项为式(7)等号右侧第二项^[6],用于计算局部灰度信息拟合能量;式(11)等号右侧第二项为式(1)等号右侧第二、三项^[5],用于计算全局灰度信息拟合能量;式(11)等号右侧第三项 L_g ^[14] 的定义见式(13),用于计算基于边界探测函数的长度能量。最小化上述能量项,得到如下的水平集函数演化方程:

$$\frac{\partial E^{\text{RACM}}}{\partial t} = \beta \delta_{\varepsilon}(\phi) \cdot \text{div} \left(g \cdot \frac{\nabla \phi}{|\nabla \phi|} \right) - w' \delta_{\varepsilon}(\phi) (e_1 - e_2) + 2w \delta_{\varepsilon}(\phi) \left[(c_1 - c_2) \left(I - \frac{c_1 + c_2}{2} \right) \right] \quad (12)$$

对于 RACM 中的梯度信息使用、权重设置、模型转换及停止准则,做以下 4 点说明:

(1) 基于边缘探测函数的长度能量项

边界信息对确定边界的位置有重要作用,故使用边缘探测函数可以提高边界定位、加快水平集轮廓向目标边界演化。同时为了保持演化的平滑性,本文模型采用了文献[6]中提出的基于边缘探测函

数的长度能量项

$$L_g(\phi) = \int_{\Omega} g \delta_{\varepsilon}(\phi) |\nabla \phi| dx dy \quad (13)$$

其中 g 为边缘探测函数,其定义方式如下:

$$g = \frac{1}{1 + |\nabla G_{\sigma} * I|^2} \quad (14)$$

其中 I 为待分割图像, G_{σ} 为标准差为 σ 的高斯核函数。

从式(13)可以看出,长度能量项 $L_g(\phi)$ 计算 g 沿着零水平线的线积分,因此只有当水平集轮廓到达目标边界时才达到最小。对比式(1)和式(7)的长度能量项,式(13)的能量项既保证了水平集轮廓平滑,同时又实现了边缘检测函数 g 的功能。

(2) 接力型的组合区域能量项

C-V 模型对初始轮廓的位置、大小、形状和噪声均不敏感。对灰度不均匀图像,水平集轮廓只能演化到实际边界的附近。RSF 模型能分割灰度不均匀图像,但对初始轮廓比较敏感,初始轮廓不合适模型易陷入局部极小点。但若将初始轮廓置于实际边界附近,该模型能很好地演化到目标边界。

文献[13]的方法是将全局和局部模型直接线性组合,组合权重固定,没有考虑演化过程中能量主体的变化。

针对这种情况,根据演化过程中能量主体的变化以及 C-V 模型、RSF 模型对轮廓位置的处理能力,本研究为式(11)设计了“两步走”的接力型组合模型。于是,式(11)可表示为

$$E^{\text{region}} = w E^{\text{CV}} + w' E^{\text{RSF}} \quad (15)$$

第一阶段(初始阶段):初始轮廓向目标边界附近区域演化。此阶段 C-V 模型起主要作用,故 $w \gg w' > 0$ 。不管初始轮廓如何,模型可使轮廓或部分轮廓向物体边界附近演化。局部能量项 E^{RSF} 的存在也使模型具备了分割灰度不均匀的图像的能力。

第二阶段(接力阶段):从上一阶段水平集轮廓出发确定精确边界。上一阶段水平集轮廓已经全部或部分位于物体边界附近,之后演化中只需局部灰度信息即可完成分割,故 $w = 0, w' > 0$, 即可使轮廓演化到达目标边界处。

通过以上模型接力可以有效分割灰度不均匀的图像并减少对初始轮廓的依赖,保证轮廓停止在全局最小点或者它的小邻域内。从本质上看,该接力型模型与人识别具体物体边界的过程相似。因此,该模型可视为对人工识别过程的一种模拟或近似。

(3) 模型转换

在“两步走”模型演化中,对何时进行模型转换以及如何转换提出了以下的判别标准以及变换策略:

在第一阶段中,曲线 C 相邻两次迭代中长度改变量 ΔL 若满足条件

$$\Delta L = |L_n(C) - L_{n-1}(C)| < \zeta_1 \quad (16)$$

的次数连续等于 N_1 , 即可判定第一阶段演化结束,需启动第二阶段,其中 ζ_1 为固定阈值。

启动第二阶段演化时需指定新的初始水平集函数如下:

$$\phi'_0(i, j) = \begin{cases} c_0 & \phi_1(i, j) \geq 0 \\ -c_0 & \phi_1(i, j) < 0 \end{cases} \quad (17)$$

其中 ϕ_1 为第一阶段演化结束时的水平集函数, c_0 为某固定值,一般取 1 或 2。

(4) 正则化方法及停止准则

Zhang^[7]等提出的高斯滤波函数既可以对水平

集函数正则化又可以保持水平集函数的光滑,故本文采用该方法正则化水平集函数并避免水平集函数重新初始化:

$$\phi' = G_{\sigma_1} * \phi \quad (18)$$

ϕ' 为正则化后的水平集函数, G_{σ_1} 为标准差为 σ_1 的高斯核函数。

算法停止准则为第二阶段演化曲线 C 相邻两次迭代长度改变量 $\Delta L'$ 满足

$$\Delta L' = |L'_n(C) - L'_{n-1}(C)| < \zeta_2 \quad (19)$$

的次数连续大于等于 N_2 次。若满足即可停止迭代。因为初始阶段轮廓不需要精确定位,而停止准则需要较高的位置精度,故 ζ_2 和 N_2 比 ζ_1 和 N_1 有更高的要求。在本研究中,令 $\zeta_1 = 4, N_1 = 5, \zeta_2 = 0.8, N_2 = 20$ 。

2.2 算法执行

本文提出的 RACM 模型的计算流程见算法 1, 其中, Ω_1 可以选取任意形状、任意区域。

算法 1 RACM 算法

-
- 步骤 1 初始化. 令 $w = 1, w' = 0.1$, 并初始化水平集函数 $\phi_0: \phi_0(x, t = 0) = \begin{cases} -c_0 & x \in \Omega_1 \\ +c_0 & x \in \Omega - \Omega_1 \end{cases}$.
- 步骤 2 更新水平集函数. 按照式(12)计算 ϕ_i 并更新水平集 $\phi_{n+1} = \phi_n + \Delta t \cdot \phi_i$, 再按式(18)正则化 ϕ_{n+1} .
- 步骤 3 模型转换判断. 判断是否满足模型转换条件, 满足则执行步骤(4), 否则返回步骤(2).
- 步骤 4 模型转换. 按照式(17)设置新的初始水平集函数 ϕ'_0 , 并令 $w = 0, w' = 1.1$.
- 步骤 5 更新水平集函数. 按照式(12)计算 ϕ_i 并更新水平集 $\phi_{n+1} = \phi_n + \Delta t \cdot \phi_i$, 再按式(18)正则化 ϕ_{n+1} .
- 步骤 6 停止准则判断. 判断是否满足停止准则, 满足则停止迭代并输出分割结果, 否则返回执行步骤(5).
-

3 数值实验与结果分析

本研究对人工合成图像和真实图像进行了图像分割实验。主要在如下方面对模型进行验证:(1)模型转换、权重调整及自动停止的有效性;(2)初始轮廓位置、大小、形状的适应性;(3)灰度不均匀图像分割能力;(4)噪声图像分割能力;(5)分割结果的准确率。实验条件为 PC 机 (CPU Intel Core2 T5670, 内存 3GB), 编程环境 Matlab7. 11, $\Delta t = 0.1$, $\sigma = 3, \sigma_1 = 1, \beta = 10, c_0 = 2$ 。 $w, w', \zeta_1, N_1, \zeta_2, N_2$ 等的设置按照前文所述。

为了验证 RACM 调整组合权重、自动转化及自动停止的有效性进行了数值实验,图 2 为相应的实验结果。其中,图 2(a) - 图 2(f)为提出的算法对 200×227 (像素,以下省略)的超声图像的实验结果 (文献[8]), $\varepsilon = 25$; 图 2(h) - 图 2(n)为提出的算

法对 472×127 的遥感图像的实验结果 (文献[8]), $\varepsilon = 19$ 。算法流程如下:

第 1 步:初始化水平集函数,见图 2(a)、图 2(b)和图 2(h)、图 2(i)。其中,立体图像中的零水平线为零水平集,对应于图 2(b)和图 2(i)中的圆形、矩形初始轮廓。

第 2 步:更新水平集函数。令 $w = 1, w' = 0.1$, 得到第一阶段的水平集演化方程为

$$\phi_{n+1} = G_{\sigma_1} * (\phi_n + 0.1 \times \phi_i), n = 0, 1, 2, \dots \quad (20)$$

$$\begin{aligned} \phi_i = & 2 \times \delta_\varepsilon(\phi) \cdot \left[(c_1 - c_2) \left(I - \frac{c_1 + c_2}{2} \right) \right. \\ & + \delta_\varepsilon(\phi) \cdot \left(10 \times \text{div} \left(g \cdot \frac{\nabla \phi}{|\nabla \phi|} \right) \right. \\ & \left. \left. - 0.1 \times (e_1 - e_2) \right) \right] \end{aligned} \quad (21)$$

按照式(20)演化,得到处于第一阶段的模型演

化结果。图 2(c)和图 2(j)为对应的结果,前者为第 15 次迭代,后者为第 10 次迭代。

第 3 步:自动转换模型。当第一阶段演化模型满足

$$\Delta L^1 = |L_n(C) - L_{n-1}(C)| < 4 \quad (22)$$

的次数连续等于 5 次时,满足模型转换条件。对应于图 2(d)和图 2(k),模型会自动转换,迭代次数分别为 29 和 37。由图可知,模型转换时的水平集轮廓已经演化到待分割区域的真实边界附近,甚至绝大部分轮廓已经位于真实边界上。这与建立模型时的假设相一致,由此验证了模型转换标准的合理性。

第 4 步:组合权重调整并开始第二阶段演化。模型转化后会自动调整组合权重: $w = 0, w' = 1.1$,

并按照式(17)重新初始化水平集函数。于是进行第二阶段演化:

$$\phi_{n+1} = G_{\sigma_1} * (\phi_n + 0.1 \times \phi_t) \quad (23)$$

$$\begin{aligned} \phi_t = 10 \times \delta_\epsilon(\phi) \cdot \text{div} \left(g \cdot \frac{\nabla \phi}{|\nabla \phi|} \right) \\ - 1.1 \times \delta_\epsilon(\phi) \cdot (e_1 - e_2) \end{aligned} \quad (24)$$

图 2(e)和图 2(m)为第二阶段时的模型演化效果,对应迭代次数分别为 40 和 90。

第 5 步:自动停止。停止条件为:

$$\Delta L' = |L'_n(C) - L'_{n-1}(C)| < 0.8 \quad (25)$$

当第二个阶段模型满足上述条件的次数连续等于 20 次时,满足算法停止条件,算法自动停止迭代。于是得到最后一列图像,即最终的分割结果。




图 2 超声图像和遥感图像的 RACM 算法仿真

为了验证模型对初始轮廓位置、大小、形状的适应性,对 X 光血管进行了分割实验,图 3 提供了分

割结果,同时比较了尺寸相同、位置不同的矩形初始轮廓下 LIF 模型和 RACM 模型的分割结果。




图 3 尺寸相同、位置不同的矩形初始轮廓下 LIF 模型和 RACM 模型分割结果比较

图 3 所示为尺寸为 111×110 的 X 光血管图像(文献[6])。实验中,矩形窗口的尺寸为 20×15 ,

矩形左上角点的坐标依次为: $(10, 10), (10, 70), (85, 10), (37, 85), (43, 65)$ 。LIF 算法采用文献[7]

中参数, RACM 模型中 $\varepsilon = 4$ 。从上数第 1 行为初始轮廓, 第 2 行为 LIF 模型分割结果, 第 3 行为 RACM 模型分割结果。从实验结果可看出, RACM 模型在不同位置均能得到准确的结果, 表现出良好的适应性; 而 LIF 模型在某些特殊位置分割结果不准确。特别是, 即使增加迭代次数, 算法结果依然没有改善。可见本文模型对在不同位置处的同形状初始轮廓能得到准确一致的结果, 体现出对轮廓位置的鲁棒性。

图 4 中图像为尺寸为 103×130 的 X 光血管图像(文献[6])。分别采用了大小不同、位置不同的 3 个轮廓, 它们的位置分别为 $(30:50, 30:50)$, $(70:90, 80:90)$, $(80:90, 20:50)$ 。文献[13]模型参数为原文值, RACM 模型 $\varepsilon = 4.5$ 。从实验结果可看出, RACM 模型不受轮廓形状、位置影响, 均能准确收敛到真实边界。而文献[13]模型依然依赖初始轮廓, 在某些位置时分割结果不太准确。可见, RACM 模型对不同形状的初始轮廓分割结果稳定一致, 体现出对轮廓形状的鲁棒性。




图 4 尺寸不同、位置也不同的初始轮廓下文献[13]模型和 RACM 模型的分割结果比较

图 5 中的被分割图像为图 3 中的 X 光血管图像, 但选取了圆心相同、半径却不同的 3 个圆形区域做初始轮廓。圆心坐标为图像的中心, 半径依次为 5, 20, 35。RACM 模型参数同上, RSF 模型采用原文献参数。分析分割结果依然可得到相同的结论。特别对比最后两列的结果可见, 虽然初始轮廓相差不大, 但 RSF 模型却呈现不同的敏感性; 而 RACM 模型克服了此问题, 得到了稳定一致的分割结果。

从以上分割结果可以发现, RACM 模型继承了 C-V 模型对初始轮廓不敏感性的特性, 面对各种轮廓形状、位置均可获得稳定一致的结果。由此可见,

本文算法具有对初始轮廓形状、位置等不敏感的特点。




图 5 圆心位置相同、半径不同的圆形初始轮廓下 RSF 和 RACM 模型的分割结果

为了验证 RACM 模型对灰度不均匀图像的分割能力, 选取了图 6 中两幅灰度不均匀的合成图片(文献[6,7])。这两幅图像均具有肉眼可见的明显的灰度不均匀性。从图 6(a)、(b)可见, 原图的背景区域存在三条带状的灰度变化区域; 图 6(c)、(d)的背景灰度均匀, 但是由 6 个圆形子区域组成的待分割目标区域总体上灰度不均匀。实验中, 我们均选取了位于背景区域的矩形初始轮廓, 矩形区域的大小分别为 $(10:15, 10:15)$ 和 $(10:15, 10:15)$ 。

其中, 图 6(a)、(c)为初始轮廓, 图 6(b)、(d)为 RACM 模型分割结果。前图尺寸为 79×75 , 实验中 $\varepsilon = 8, \Delta L' = 0.6$; 后图尺寸为 118×134 , 参数为 $\varepsilon = 5.2, \Delta L' = 3$ 。矩形区域的大小分别为 $(10:15, 10:15)$ 和 $(10:15, 10:15)$ 。从分割结果可看出, RACM 模型继承了 RSF 模型的优点, 克服了 C-V 模型在该方面的缺点, 具备了处理灰度不均匀图像的能力。




图 6 RACM 模型对灰度不均匀图像分割效果

为了验证 RACM 模型对含噪声图像的分割能力,对含噪声水平不同的图像做了图 7 中的分割实验。其中,两图像(文献[8])尺寸均为 114×101 。图 7(a)、(c)中图像为同一不含噪声的干净图像,图 7(b)、(d)的图像为在图 7(a)、(c)干净图像上添加了标准差为 0.05 的高斯噪声的两相同含噪声




图 7 RACM 对不同噪声水平图像分割结果对比

图像。图 7(a)、(b)的初始轮廓相同,置于物体内部,用较细的线表示;图 7(c)、(d)的初始轮廓置于物体外部的相同位置。两个轮廓位置分别为: (30:80, 30:80) 和 (4:20, 4:22)。在分割干净图像算法中, $\varepsilon = 19$; 对于分割含噪声的算法, $\varepsilon = 20$, $\Delta L' = 2$, 且 σ_1 需另设置为 4.5。实验结果用粗线标识在图 7(a)、(b)、(c)、(d)的相应位置,从实验结果可见, RACM 模型具有分割包含一定水平噪声图像的能力。

为直观了解算法执行中水平集函数的变化,对两幅图像进行了实验。图 8 中的图像为 136×132 人体左心室 MR 图像(文献[8]), $\varepsilon = 14$; 图 9 中的图像为 108×130 的二值图像(文献[7]), $\varepsilon = 10$ 。两图的前两列为初始轮廓,最后一列为分割结果。从分割结果可以看出, RACM 模型对这两类的图像均具有很好的分割能力,得到了稳定一致的分割结果。左心室和手二值图像分割中水平集轮廓位置在迭代过程中变化如图 9 所示:




图 8 左心室 MR 图像初始化和第 10、20、50、100 次迭代水平集轮廓位置




图 9 手型二值图像初始化和第 1、2、5、17 次迭代水平集轮廓位置

为验证 RACM 算法的准确性,通过 Livewire 算法^[15]结果计算了 RACM 分割结果的准确性。Livewire 算法是半自动的边界提取算法,该算法需要人为地在图像边界上点击鼠标设置若干标记点,算法会自动计算出沿标记点的图像边界。然后再将相应的待分割区域填充颜色,得到 Livewire 人工分割结果。由于人的介入,使该算法分割结果更加接近人类识别的结果。通过 Simon Fraser University 的 MIAL 实验室编写的 Livewire 软件获得各图像 Livewire 分割二值化结果如图 10 所示。RACM 模型分割的二值化结果如图 11 所示。

为计算 RACM 模型的分割准确率,将图 10 获得的分割结果作为金标准(gold standard)。因为分类结果比较类似时, Jaccard 相似性比率比 Dice 相似性比率更敏感^[16],故本文采用 Jaccard 相似性比率。Jaccard 相似性比率是集合 S_1 、 S_2 的交集和并集的比率,在计算中通常取 S_1 为得到的分割, S_2 为金标准的分割。其计算公式^[16]为

$$J(S_1, S_2) = \frac{|S_1 \cap S_2|}{|S_1 \cup S_2|} \quad (26)$$




图 10 各图像 Livewire 二值化分割结果




图 11 各图像 RACM 二值化分割结果

通过计算,各图像分割准确性比率值如表 1 所示(按照图 10 顺序)。

表 1 RACM 模型的分割准确性比率

图像	分割准确率(%)	图像	分割准确率(%)
Img1	96.45	Img6	96.80
Img2	93.94	Img7	95.84
Img3	98.41	Img8	81.98
Img4	91.71	Img9	90.86
Img5	91.86	Img10	87.69

从表 1 中看出,人体左心室 MR 图像模型只有 81.2% 的准确率。而从图 10 人体左心室图像中圆圈标记的位置来看,原图中该位置比较模糊,使得 Livewire 算法给出的分割结果未必完全准确,从而造成这样的结果。而其余图像均能得到接近和超过 90% 的准确性,可见 RACM 模型的准确性和有效性可以接受。

4 结 论

本文提出了融合全局、局部尺度化信息及梯度信息的接力型组合活动轮廓模型,其能量泛函为三者能量项的组合。通过分析演化能量主体变化,调整相应的组合权重系数,实现了两种组合分割模型顺利转换并依次分割图像,最后使用高斯核函数正则化水平集函数避免水平集重新初始化。组合后本文模型继承了 C-V 模型、RSF 模型的优点,且对初始轮廓位置、大小、形状不敏感,同时具备了分割灰度不均匀和含噪声图像的能力。

参考文献

- [1] Kass M, Witkin A, Terzopoulos D. Snakes: active contour models. *Int Journal of Computer Vision*, 1987, 1 (4):321-331
- [2] Caselles V, Kimmel R, Sapiro G. Geodesic active contours. *International journal of computer vision*, 1997. 22 (1): 61-79
- [3] Malladi R, Sethian J A, Vemuri B C. Shape modeling with front propagation: a level set approach. *IEEE Trans on Pattern Analysis and Machine Intelligence*, 1995, 17 (2):158-175
- [4] Li C M, Xu C Y, Gui C F, et al. Level set evolution without re-initialization: a new variational formulation. In: *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, Los Alamitos, USA, 2005. 430-436
- [5] Chan TF, Vese LA. Active contours without edges. *IEEE Trans on Image Processing*, 2001, 10(2):266-277
- [6] Li C M, Kao C Y, John C Fore. Minimization of region-scalable fitting energy for image segmentation. *IEEE Trans on Image Processing*, 2008, 17(10):1940-1949
- [7] Zhang K H, Song H H, Zhang L. Active contours driven by local image fitting energy. *Pattern Recognition*, 2010 (43):1199-1206
- [8] Zhang K H, Zhang L, Song H H, et al. Active contours with selective local or global segmentation: A new formulation and level set method. *Image and Vision Computing*, 2010, 28(4):668-676
- [9] 刘秀平, 常先堂, 李治隆. 一种基于边缘和区域信息的变分水平集图像分割方法. *大连理工大学学报*, 2008, 48(5):754-758
- [10] 何宁, 张朋. 基于边缘和区域信息相结合的变分水平集图像分割方法. *电子学报*, 2009, 37(10):2215-2219

- [11] 贾迪, 杨金柱, 张一飞等. 基于改进 C-V 模型的脑组织提取算法. 东北大学学报(自然科学版), 2011, 32(4):489-492
- [12] 周则明, 王洪元, 尤建洁等. 基于改进快速活动轮廓模型的左心室核磁共振图像分割. 计算机研究与发展, 2004, 41(1):136-141
- [13] 刘瑞娟, 何传江, 原野. 融合局部和全局图像信息的活动轮廓模型. 计算机辅助设计与图形学学报, 2012, 24(3):364-371
- [14] Li C M, Xu C Y, Gui C F, et al. Distance regularized level set evolution and its application to image segmentation. *IEEE Trans on Image Processing*, 2010, 19(12):3243-3253
- [15] Chodorowski A, Mattsson U, Langille M, et al. Color lesion boundary detection using live wire. In: Proceedings of SPIE Medical Imaging: Image Processing, Bellingham, USA, 2005. 1589-1596
- [16] Vovk U, Pernus F, Likar B. A review of methods for correction of intensity inhomogeneity in MRI. *IEEE Transactions on Medical Imaging*, 2007, 26(3):405-421

A relay active contour model for image segmentation based on edge and region information

Feng Changli, Zhang Jianxun, Dai Yu

(Institute of Robotics & Automatic Information System, Nankai University, Tianjin 300071)

Abstract

Seeing that a conventional single or combined active contour model for image segmentation is sensitive to initial contours and can not handle the images with inhomogeneous intensity information, the paper proposes a new relay active contour model (RACM) that combines edge information and region information. Firstly, the new model linearly combines the local intensity fitting energy and the global intensity fitting energy, and then a new energy term is constructed by using the combined energy and an edge term which is made up of edge detection function. Secondly, the combined weight is adjusted according to the state of the evolution model, which can realize image segmentation with two combined active contours models one by one. At last, the Gaussian kernel function is used to regularize the level set function. The criteria for model conversion and stopping are proposed to implement the automatic conversion and automatical stop of a model. The results of the experiment on synthetic images and real images show the proposed model is robust to initial contours and noises, and can segment the images with inhomogeneous intensity information.

Key words: active contours model, edge detection function, global intensity information, local intensity information, intensity inhomogeneity, image segmentation