

基于变异系数和模糊集的活动轮廓图像分割模型

黄丽转, 刘国军, 魏立力

(宁夏大学数学统计学院, 银川 750021)

摘要: 由于图像分割具有模糊性, 提出了一个对灰度不均匀、高噪声图像的分割模型。该模型以模糊能量泛函为基础, 结合区域和边缘信息, 利用变异系数作为局部区域统计量, 避免了噪声对分割的干扰, 很好地提取了图像信息。区域能量可以平衡目标和背景的重要性, 驱使初始轮廓向目标边界移动。边缘能量对伪水平集函数进行正则化, 保持曲线演化过程中的平滑性。在求能量泛函极小值时, 直接计算新旧能量泛函的差值以更新伪水平集。对于高噪声以及混合噪声和强度不均匀的合成和真实图像的分割结果表明, 本文模型具有较好的分割效果。

关键词: 图像分割; 模糊隶属度; 变异系数; 活动轮廓; 伪水平集

中图分类号: O29; TN919.8 **文献标志码:** A

Image Segmentation of Active Contour Model Based on Coefficient of Variation and Fuzzy Set

HUANG Lizhuan, LIU Guojun, WEI Lili

(School of Mathematics and Statistics, Ningxia University, Yinchuan 750021, China)

Abstract: Due to the fuzzy property of image segmentation, this paper proposes a segmentation model for non-uniform gray and high-noise images. The model is based on the fuzzy energy functional which combines with the regional and edge information, and uses the coefficient of variation as the local regional statistics, thus avoiding the interference of noise on the segmentation and extracting the image information well. Regional energy balances the importance of the target and the background, and drives the initial contour toward the target boundary. The edge energy regularizes the pseudo-level set function to maintain the smoothness of the curve evolution. To find the minimum value of the energy functional, the difference between the old and new energy functional is calculated directly so as to update the pseudo level set. The segmentation results of synthetic and real images with high noise, mixed noise and uneven intensity show that the model has a good segmentation effect.

Key words: image segmentation; fuzzy membership; coefficient of variation; active contour; pseudo level set

引 言

图像分割在图像分析和计算机视觉中起着重要的作用,其目的是将特定图像划分为若干部分,通常每个部分在某一特征方面是均匀的,例如强度、颜色和纹理等。近年来,学者们提出了大量的图像分割算法来提高图像分割的精度和效率^[1]。其中,活动轮廓模型(Active contour model, ACM)已成为图像分割领域的一个有效框架,通常可分为基于边缘的活动轮廓模型^[2-3]和基于区域的活动轮廓模型^[4-6]。基于边缘的活动轮廓模型使用梯度信息来引导不断变化的轮廓向目标边界移动,此类模型对初始轮廓比较敏感,不能提取弱边缘或模糊的目标。基于区域的活动轮廓模型根据图像区域信息处理,当演化曲线到达真实目标边界时能量达到极小值。作为 Mumford-Shah(M-S)模型^[6]的一个特殊实例,Chan-Vese(C-V)模型^[4]是最具代表性的基于区域的 ACM 之一,该模型利用内外平均灰度值的差异而不是图像梯度来驱动演化曲线向边界运动。近几年,不少文献从不同方向对 C-V 模型进行改进^[7-8]:Zhang 等^[9]提出一个基于图像全局信息的活动轮廓(Selective local or global segmentation, SLGS)模型,提高了分割速度,然而由于依赖图像的全局信息,对灰度不均匀图像的分割效果不理想;Li 等^[10]提出基于图像局部区域的可变灰度拟合(Region-scalable fitting, RSF)模型,克服了基于全局模型在灰度不均图像分割中的不足,但从分割结果中可以看出,过度依赖图像的局部信息使得该模型对初始轮廓和噪声较为敏感。

为了解决基于区域的活动轮廓模型中能量泛函的最小化问题,通过将模糊集纳入活动轮廓模型,文献[11]首次提出了一种基于模糊能量的活动轮廓(Fuzzy energy-based active contour, FEAC)模型。之后,文献[12-14]提出了基于 FEAC 改进的模型,将局部图像信息纳入基于区域的 ACM。全局和局部 FEAC(Global and local FEAC, GL-FEAC)^[12-14]模型中的局部能量泛函将局部空间信息和强度信息结合到 ACM 中,降低了图像中灰度不均匀性的影响。文献[15-16]将图像的核度量和形状先验等特征融合到 FEAC 模型中,提高了分割性能。但是,这些模型没有正则化项,导致演化曲线不光滑,无法保持伪水平集的距离特征。此外,通过逐像素计算曲线演化过程中能量函数的变化值来更新隶属度,大大增加了计算复杂度。更重要的是,分割的图像中若包含弱边缘和低对比度,可能会出现边界缺失问题。Fang 等^[1]提出了一种新的基于混合和局部模糊区域边缘的主动轮廓模型(Hybrid and local fuzzy region-edge based active contour model, HLFRA),可以成功地从高噪声和强度不均匀的合成图像和真实图像中提取目标边界。Ahmad 等^[17]首次提出将变异系数(Coefficient of variation, CoV)与模糊隶属函数相结合,可以分割具有较高噪声、强度不均匀的图像和弱纹理图像。

受文献[1,17]的启发,本文构建的新能量泛函包括区域能量和边缘能量。区域能量由基于变异系数的混合模糊区域项和局部模糊区域项组成,可以平衡目标和背景的重要性,驱使初始轮廓向目标边界移动,而结合了局部空间信息的局部模糊区域项可以降低图像强度不均匀性的影响。另外,边缘能量对伪水平集函数进行正则化,保持曲线演化过程中的平滑性。本文模型在分割有较高噪声以及混合噪声和弱纹理的图像时,不仅速度快,而且分割性能较其他模型好。

1 相关知识

1.1 FEAC 模型

为了获得凸能量泛函,Krinidis 等^[11]将模糊思想引入 ACM 中,提出了 FEAC 模型。与流行的 ACM 不同,FEAC 模型用 0.5 水平集作为演化曲线。伪水平集定义为

$$\begin{cases} u(x) = 0.5 & I(x) \in C \\ u(x) > 0.5 & I(x) \in \text{in}(C) \\ u(x) < 0.5 & I(x) \in \text{out}(C) \end{cases} \quad (1)$$

式中: $I(x)$ 为输入图像; $\text{in}(C)$ 和 $\text{out}(C)$ 分别表示曲线 C 的内部和外部。式(1)定义的伪水平集将图像分割成两部分, 其能量泛函定义为

$$E^{\text{FEAC}}(c_1, c_2, u(x)) = \eta \text{Length}(C) + \lambda_1 \int_{\Omega} [u(x)]^m (I(x) - c_1)^2 dx + \lambda_2 \int_{\Omega} [1 - u(x)]^m (I(x) - c_2)^2 dx \quad (2)$$

式中: 常数 $\eta \geq 0, \lambda_1 > 0, \lambda_2 > 0$ 为3个固定的参数; m 为指数; $\text{Length}(C)$ 代表 C 的长度; c_1 和 c_2 分别代表曲线内外部的图像的平均灰度值, 保持 $u(x)$ 不变, 最小化式(2)可得

$$c_1 = \frac{\int_{\Omega} [u(x)]^m I(x) dx}{\int_{\Omega} [u(x)]^m dx}, c_2 = \frac{\int_{\Omega} [1 - u(x)]^m I(x) dx}{\int_{\Omega} [1 - u(x)]^m dx} \quad (3)$$

为了更新能量泛函, 保持 c_1 和 c_2 不变, 最小化式(2)可得隶属度为

$$u(x) = \frac{1}{1 + \left(\frac{\lambda_1 (I(x) - c_1)^2}{\lambda_2 (I(x) - c_2)^2} \right)^{\frac{1}{m-1}}} \quad (4)$$

但是, FEAC 模型中没有正则化项, 导致演化曲线不光滑, 无法保持伪水平集的距离特征。此外, 通过逐像素计算曲线演化过程中能量函数的变化值来更新隶属度, 大大增加了计算复杂度。更重要的是, 当分割的图像边缘较弱、对比度较低时, 可能会出现遗漏边界的问题。

1.2 HLFRA 模型

HLFRA 模型^[1]与 FEAC 模型类似, 演化曲线 c 由伪水平集表示, 将图像分为两部分, 能量泛函定义为

$$F^{\text{HLFRA}}(u, g) = F^{\text{R}}(u, g) + F^{\text{E}}(u, g) \quad (5)$$

式中区域能量 F^{R} 定义为

$$F^{\text{R}}(u, g) = F^{\text{HFR}}(u, g) + F^{\text{LFR}}(u, g) \quad (6)$$

式中: F^{HFR} 为混合模糊区域项; F^{LFR} 为局部模糊区域项; g 为边缘检测函数, 定义为

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

式中: ∇ 为梯度算子; $G_{\sigma} * I(x)$ 为图像 $I(x)$ 与标准差为 σ 的高斯核的卷积, 其目的是平滑图像, 降低图像噪声。

通过将局部和全局空间区域信息纳入 FEAC 模型, 混合模糊区域项 F^{HFR} 表示为

$$F^{\text{HFR}}(u, g) = \lambda_1 \int_{\Omega} [u(x)]^m g(I(x) - (f_b + c_1)/2)^2 dx + \lambda_2 \int_{\Omega} [1 - u(x)]^m g(I(x) - (f_s + c_1)/2)^2 dx \quad (7)$$

式中: λ_1 和 λ_2 为平衡 2 个模糊隶属度的正常数; f_b 和 f_s 分别为

$$f_b = \frac{\int_{\Omega} \int_{\Omega_x} \omega(x, y) I(x) [u(x)]^m dy dx}{\int_{\Omega} \int_{\Omega_x} \omega(x, y) [u(x)]^m dy dx}, \quad f_s = \frac{\int_{\Omega} \int_{\Omega_x} \omega(x, y) I(x) [1 - u(x)]^m dy dx}{\int_{\Omega} \int_{\Omega_x} \omega(x, y) [1 - u(x)]^m dy dx}$$

在局部模糊区域项中, 首先通过合并局部区域像素 x 的空间信息和局部信息来定义能量泛函为

$$\epsilon^{\text{loc}}(x) = \alpha_1 \int_{\text{in}(C) \cap \Omega_x} \omega(x, y) (I(y) - f_b)^2 dy + \alpha_2 \int_{\text{out}(C) \cap \Omega_x} \omega(x, y) (I(y) - f_s)^2 dy \quad (8)$$

式中: α_1 和 α_2 为2个正常数,用来平衡目标和背景的效果; $\omega(x,y)=\frac{1}{1+|x-y|}$ 。

可以看到,空间约束的值随着其与局部窗口内中心像素 x 的距离而变化。利用文献[7]中定义的模糊集,定义整个图像域 Ω 中的局部模糊区域项为

$$F^{LFR}(u,g)=\int_{\Omega}\epsilon^{loc}(x)dx \tag{9}$$

结合式(7,9),式(6)可写为

$$F^R(u)=\lambda_1\int_{\Omega}[u(x)]^mg(I(x)-(f_b+c_1)/2)^2dx+\lambda_2\int_{\Omega}[1-u(x)]^mg(I(x)-(f_s+c_1)/2)^2dx+\alpha_1\int_{\Omega}[u(x)]^m\int_{\Omega}\omega(x,y)g(I(y)-f_b)^2dydx+\alpha_2\int_{\Omega}[1-u(x)]^m\int_{\Omega}\omega(x,y)g(I(y)-f_s)^2dydx \tag{10}$$

保持 f_b 和 f_s 固定不变,最小化式(10)可得

$$u(x)=\frac{1}{1+A(x)} \tag{11}$$

式中

$$A(x)=\left(\frac{\lambda_1(I(x)-(f_b+c_1)/2)^2+\alpha_1\int_{\Omega}\omega(x,y)(I(y)-f_b)^2dy}{\lambda_2(I(x)-(f_s+c_2)/2)^2+\alpha_1\int_{\Omega}\omega(x,y)(I(y)-f_s)^2dy}\right)^{\frac{1}{m-1}}$$

对伪水平集进行正则化,并在演化过程中保持形状平滑的外观,边缘能量是由正则项和惩罚项组成,定义为

$$L(u=0.5)=\int_{\Omega}\delta(u-0.5)|\nabla(u-0.5)|dx \tag{12}$$

$$P(u=0.5)=\frac{1}{2}\int_{\Omega}(1-|\nabla(u-0.5)|)^2dx \tag{13}$$

式中 $(\nabla\varphi)_{x,y}=\left(\frac{\partial\varphi}{\partial x},\frac{\partial\varphi}{\partial y}\right)$ 为 $\varphi=u-0.5$ 的梯度。

虽然HLFRA模型结合了图像的区域和边缘信息,但在分割具有弱边缘的图像时仍存在丢失边缘信息的情况,且对混合噪声的分割性能并不好。

1.3 Ali Ahmad 模型

变异系数可称为信号的相对标准差,定义为SD/mean,它可以被认为是对给定观测数据的离散度(变异)的规范化测量。Ahmad等^[17]提出了一种基于变异系数的数据拟合项模型(Ali Ahmad模型)来处理真实图像的空间异质性。此外,模型采用模糊隶属度函数表示图像中每个像素对于前景或背景中的隶属度。为了降低模型的计算量,用高斯滤波代替长度项,它能更好地拟合非均匀图像中的数据。对于给定的图像 I_0 ,定义图像域 Ω ,Ali Ahmad模型^[17]的能量泛函为

$$E^{Cov}(v,v_1,v_2,C)=\lambda_1\int_{\Omega}[v(z)]^m\frac{(I_0(z)-v_1(z))^2}{(v_1(z))^2}dz+\lambda_2\int_{\Omega}[1-v(z)]^m\frac{(I_0(z)-v_2(z))^2}{(v_2(z))^2}dz+\mu\text{Length}(C) \tag{14}$$

式中: λ_1,λ_2,μ 均为正常数; m 为权重指数,文中取 $m=2;0\leq v(z)\leq 1$ 为度量一个像素属于曲线 C 内的隶属度, $1-v(z)$ 度量一个像素属于曲线 C 外的隶属度, $v_1(z)$ 和 $v_2(z)$ 分别表示曲线 C 内部和外部的平均灰度值,表达式为

$$v_1(z)=\frac{\int_{\Omega}(v(z))^m(I_0(z))^2dz}{\int_{\Omega}(v(z))^mI_0(z)dz},v_2(z)=\frac{\int_{\Omega}(1-v(z))^m(I_0(z))^2dz}{\int_{\Omega}(1-v(z))^mI_0(z)dz}$$

$$v(z) = \frac{1}{1 + \left(\frac{(v_2(z))^2 \lambda_1 (I_0(z) - v_1(z))^2}{(v_1(z))^2 \lambda_2 (I_0(z) - v_2(z))^2} \right)^{\frac{1}{m-1}}}$$

用伪水平集表示隶属度函数 $v(z)$, 可得

$$\mu \text{Length}(C) = \mu \int_{\Omega} \nabla H_{\epsilon} \left| \left(v(z) - \frac{1}{2} \right) \right| dz = \mu \int_{\Omega} \delta_{\epsilon} \left(v(z) - \frac{1}{2} \right) \left| \left(v(z) - \frac{1}{2} \right) \right| dz$$

该模型虽然可以分割具有弱纹理的灰度不均匀图像, 但对于复杂背景的图像分割性能并不好, 只能分割目标明显的图像。

2 本文模型

2.1 模型描述

基于上述分析, 本文提出了一种可用于分割具有较大噪声以及混合噪声和弱纹理的图像分割模型。理论研究表明, 变异系数对于探测不同的噪声区域也更有意义。模型用模糊隶属度函数测量前景和背景图像的隶属度。首先用HLFRA提取图像的局部和空间信息, 然后用变异系数法对数据项进行拟合。利用结合了像素空间信息的局部区域信息来近似给定图像中的灰度值。图像域中的像素是以像素 x 为中心的方形或圆形邻域内的像素。局部区域的平均灰度值定义为式(15), 具体含义如图1所示。

$$\begin{cases} f_s = \text{mean}(I(y) | y \in \Omega_x \cap u(y) < 0.5) \\ f_b = \text{mean}(I(y) | y \in \Omega_x \cap u(y) > 0.5) \end{cases} \quad (15)$$

式中 $u(y)$ 为局部图像区域 Ω_x 的模糊隶属度函数。

式中局部权重函数 $\omega(x, y)$ 用来提取图像的局部信息, 定义为

$$\omega(x, y) = \frac{1}{1 + |x - y|}$$

区域数据拟合项 F^{CR} 的能量泛函为

$$F^{\text{CR}} = F^{\text{CHFR}} + F^{\text{LFR}} \quad (16)$$

式中 F^{CHFR} 表达式为

$$F^{\text{CHFR}} = \lambda_1 \int_{\Omega} [u(x)]^m g \left(\frac{I(x) - (f_b + c_1)/2}{(f_b + c_1)/2} \right)^2 dx + \lambda_2 \int_{\Omega} [1 - u(x)]^m g \left(\frac{I(x) - (f_s + c_2)/2}{(f_s + c_2)/2} \right)^2 dx \quad (17)$$

式中: λ_1 和 λ_2 为正的加权参数; F^{CHFR} 为用变异系数法进行拟合的混合模糊区域项。结合式(9, 17), 代入式(16)可得

$$F^{\text{CR}} = \lambda_1 \int_{\Omega} [u(x)]^m g \left(\frac{I(x) - (f_b + c_1)/2}{(f_b + c_1)/2} \right)^2 dx + \lambda_2 \int_{\Omega} [1 - u(x)]^m g \left(\frac{I(x) - (f_s + c_2)/2}{(f_s + c_2)/2} \right)^2 dx + \alpha_1 \int_{\Omega} [u(x)]^m \int_{\Omega} \omega(x, y) g(I(y) - f_b)^2 dy dx + \alpha_2 \int_{\Omega} [1 - u(x)]^m \int_{\Omega} \omega(x, y) g(I(y) - f_s)^2 dy dx \quad (18)$$

保持 f_b 和 f_s 固定不变, 最小化式(18)可得

$$u(x) = \frac{1}{1 + B(x)} \quad (19)$$




图1 f_s 和 f_b 示意图

Fig.1 Schematic diagram of f_s and f_b

式中

$$B(x) = \left(\frac{\lambda_1 [I(x) - (f_b + c_1)/2]^2}{[(f_b + c_1)/2]^2} + \alpha_1 \int_{\Omega} \omega(x, y) (I(y) - f_b)^2 dy \right)^{\frac{1}{m-1}} \\ \frac{\lambda_2 [I(x) - (f_s + c_2)/2]^2}{[(f_s + c_2)/2]^2} + \alpha_1 \int_{\Omega} \omega(x, y) (I(y) - f_s)^2 dy$$

对伪水平集进行正则化,并在进化过程中保持形状平滑的外观,边缘能量是由正则项和惩罚项组成,与式(12,13)一致。

此模型利用变异系数作为局部区域统计量,在很大程度上避免了异常值和噪声对分割的干扰。区域能量可以平衡目标和背景的重要性,驱使初始轮廓向目标边界移动。边缘能量对伪水平集函数进行正则化,保持曲线演化过程中的平滑性。

2.2 数值实现

为了解决式(18)中区域能量的计算问题,目前流行的基于区域的ACM能量函数最小化是利用梯度下降法求解,但收敛速度较慢。受FEAC模型^[11]的启发,直接计算新能量与旧能量的差 $\Delta F^{CR} = \hat{F}^{CR} - F^{CR}$,以此来进行伪水平集的迭代。首先将式(18)中的能量泛函从连续空间转换到离散空间。然后为了提高计算效率,直接计算新能量和旧能量的差值。如果 ΔF^{CR} 为负值,则用新值替换旧值;否则,旧值保持不变。值得注意的是,当式(8)中定义的能量泛函为凸时,全局最小能量泛函很容易通过迭代的方式得到。在文献[1]中已经证明了它的凸性。

令 $P \in I$ 为图像域 Ω 中的一个给定的点,其强度值和隶属度分别为 I_0 和 u_0 ,旧的全局能量泛函为 F^{CR} ,对于点 P ,新的隶属度函数为 u_n ,用 $\hat{c}_1, \hat{c}_2, \hat{f}_s, \hat{f}_b$ 替代更新后的 c_1, c_2, f_b, f_s 的值,且当隶属度函数变为 u_n 时,全局能量泛函用 \hat{F}^{CR} 表示。能量泛函的变化形式为

$$\Delta F^{CR} = \hat{F}^{CR} - F^{CR} = (\hat{F}_A^{CHFR} + \hat{F}_B^{CHFR}) + (\hat{F}_C^{LFR} + \hat{F}_D^{LFR}) - (F_A^{CHFR} + F_B^{CHFR}) - (F_C^{LFR} + F_D^{LFR}) = \\ (\hat{F}_A^{CHFR} - F_A^{CHFR}) + (\hat{F}_B^{CHFR} - F_B^{CHFR}) + (\hat{F}_C^{LFR} - F_C^{LFR}) + (\hat{F}_D^{LFR} - F_D^{LFR}) \quad (20)$$

式中

$$F_A^{CHFR} = \lambda_1 \sum_{\Omega} [u(x)]^m g(I(x) - (f_b + c_1)/2)^2 \quad (21)$$

$$F_B^{CHFR} = \lambda_2 \sum_{\Omega} [1 - u(x)]^m g(I(x) - (f_s + c_2)/2)^2 \quad (22)$$

$$F_C^{LFR} = \alpha_1 \sum_{\Omega} [u(x)]^m \left[\sum_{\Omega} \omega(x, y) g(I(y) - f_b(x))^2 \right] \quad (23)$$

$$F_D^{LFR} = \alpha_2 \sum_{\Omega} [1 - u(x)]^m \left[\sum_{\Omega} \omega(x, y) g(I(y) - f_s(x))^2 \right] \quad (24)$$

$$\hat{F}_A^{CHFR} = \lambda_1 \sum_{\Omega} [\hat{u}(x)]^m g(I(x) - (\hat{f}_b + \hat{c}_1)/2)^2 \quad (25)$$

$$\hat{F}_B^{CHFR} = \lambda_2 \sum_{\Omega} [1 - \hat{u}(x)]^m g(I(x) - (\hat{f}_s + \hat{c}_2)/2)^2 \quad (26)$$

$$\hat{F}_C^{LFR} = \alpha_1 \sum_{\Omega} [\hat{u}(x)]^m \left[\sum_{\Omega} \omega(x, y) g(I(y) - \hat{f}_b(x))^2 \right] \quad (27)$$

$$\hat{F}_D^{LFR} = \alpha_2 \sum_{\Omega} [1 - \hat{u}(x)]^m \left[\sum_{\Omega} \omega(x, y) g(I(y) - \hat{f}_s(x))^2 \right] \quad (28)$$

8个常数分别表示为

$$c_1 = \frac{\sum_{\Omega} I(x) [u(x)]^m}{\sum_{\Omega} [u(x)]^m}, c_2 = \frac{\sum_{\Omega} I(x) [1 - u(x)]^m}{\sum_{\Omega} [1 - u(x)]^m} \quad (29)$$

$$f_b = \frac{\sum_{\Omega} \omega(x, y) I(x) [u(x)]^m}{\sum_{\Omega} \omega(x, y) [u(x)]^m}, f_s = \frac{\sum_{\Omega} \omega(x, y) I(x) [1 - u(x)]^m}{\sum_{\Omega} \omega(x, y) [1 - u(x)]^m} \quad (30)$$

$$\hat{c}_1 = \frac{\sum_{\Omega} I(x) [\hat{u}(x)]^m}{\sum_{\Omega} [\hat{u}(x)]^m}, \hat{c}_2 = \frac{\sum_{\Omega} I(x) [1 - \hat{u}(x)]^m}{\sum_{\Omega} [1 - \hat{u}(x)]^m} \quad (31)$$

$$\hat{f}_b = \frac{\sum_{\Omega} \omega(x, y) [I(x) [\hat{u}(x)]^m]}{\sum_{\Omega} \omega(x, y) [\hat{u}(x)]^m}, \hat{f}_s = \frac{\sum_{\Omega} \omega(x, y) [I(x) [1 - \hat{u}(x)]^m]}{\sum_{\Omega} \omega(x, y) [1 - \hat{u}(x)]^m} \quad (32)$$

式中 $\omega(x, y)$ 为空间加权系数。

从以上计算过程可以看出,本文可以通过计算新旧能量函数的差值来判断伪水平集是否需要更新。在计算过程中,FEAC模型^[11]中的伪水平集根据曲线演化过程中逐像素能量函数的变化进行更新。与FEAC模型不同的是,本文直接计算2个能量函数的变化:更新前的旧能量泛函和更新后的新能量泛函。

在计算边缘能量的过程中,计算了式(12,13)中能量泛函的导数,得到

$$\frac{\partial F^E}{\partial u} = \beta_1 \delta_{\epsilon}(u - 0.5) \operatorname{div} \left(\frac{\nabla(u - 0.5)}{|\nabla(u - 0.5)|} \right) + \beta_2 (\nabla^2(u - 0.5) - \operatorname{div} \left(\frac{\nabla(u - 0.5)}{|\nabla(u - 0.5)|} \right)) \quad (33)$$

式中: $\delta_{\epsilon}(u) = H'_{\epsilon}(u) = \frac{1}{\pi} \frac{\epsilon}{\epsilon^2 + u^2}$ 为 Dirac 函数; ϵ 为正的常数; $\operatorname{div}(\cdot)$ 为散度算子; ∇^2 为拉普拉斯算子。

2.3 算法步骤

本文算法的流程如下:

步骤 1 输入图像 I , 以及初始化参数 $\lambda_1, \lambda_2, \alpha_1, \alpha_2, \beta_1, \beta_2$ 和最大迭代次数 IterNum , 局部窗 $(2\omega + 1) \times (2\omega + 1)$ 以及边缘检测函数 g ;

步骤 2 初始化伪水平集函数, 令曲线外 $u_0(x) > 0.5$, 曲线内 $u_0(x) < 0.5$;

步骤 3 根据式(29, 30)计算初始值 c_1, c_2, f_b, f_s , 并根据式(21~24)计算区域能量 $F_A^{\text{CHFR}}, F_B^{\text{CHFR}}, F_C^{\text{LFR}}, F_D^{\text{LFR}}$;

步骤 4 更新参数: 根据式(19)更新隶属度函数 $u_n(x)$, 根据式(31, 32)更新 $\hat{c}_1, \hat{c}_2, \hat{f}_b, \hat{f}_s$, 根据式(25~28)计算区域能量 $\hat{F}_A^{\text{CHFR}}, \hat{F}_B^{\text{CHFR}}, \hat{F}_C^{\text{LFR}}, \hat{F}_D^{\text{LFR}}$;

步骤 5 根据式(20)计算新能源和旧能源之间的差 $\Delta F^{\text{CR}} = \hat{F}^{\text{CR}} - F^{\text{CR}}$, 若 $\Delta F^{\text{CR}} < 0$, 用 u_n 代替 u_0 , 否则保持 u_0 不变;

步骤 6 使用式(33)中定义的边缘能量来正则化和平滑伪水平集函数;

步骤 7 重复步骤3~6, 直至迭代结束。

3 实验结果与分析

本文共做6个实验来检验提出模型的分割性能。本文模型中有8个参数需要设置, 即: $\lambda_1, \lambda_2, \alpha_1, \alpha_2, \beta_1, \beta_2$, 最大迭代次数 IterNum 以及被大小为 $(2k + 1) \times (2k + 1)$ 的窗截断的局部加权系数 $\omega(x, y)$ 。在本文实验中将伪水平集内外的区域分别设置为0.7和0.3, 默认参数设置为 $m = 2$, 局部加权窗口 $k = 3$, 最大迭代次数 $\text{IterNum} = 100, \beta_1 = \beta_2 = 1$ 。目标越大, λ_1 越大, 若要保留图像边缘和细节信息, λ_2 也要越大。 α_1, α_2 与 λ_1, λ_2 的作用相同, 但都不宜取过大, 一般不超过5。自然图像来

自 Segmentation Evaluation 数据库^[18]和 Berkely Segmentation Dataset BSDS500^[19]。实验环境采用 Matlab (R2018b), Intel(R) Core(TM)2 Quad CPU Q9500 @ 2.83 GHz, 4 GB 内存, Windows 7 操作系统。

3.1 多目标图像分割

实验1验证了本文模型对多目标图像分割的有效性。实验中选取5幅图像进行分割,结果如图2所示。图2中第1列为原始图像加初始轮廓,第2列为分割结果,第3列为分割结果的二值图像显示,第4列为对应的水平集函数图像。从实验结果可以很明显地看出,本文模型可以对多目标图像进行准确分割。

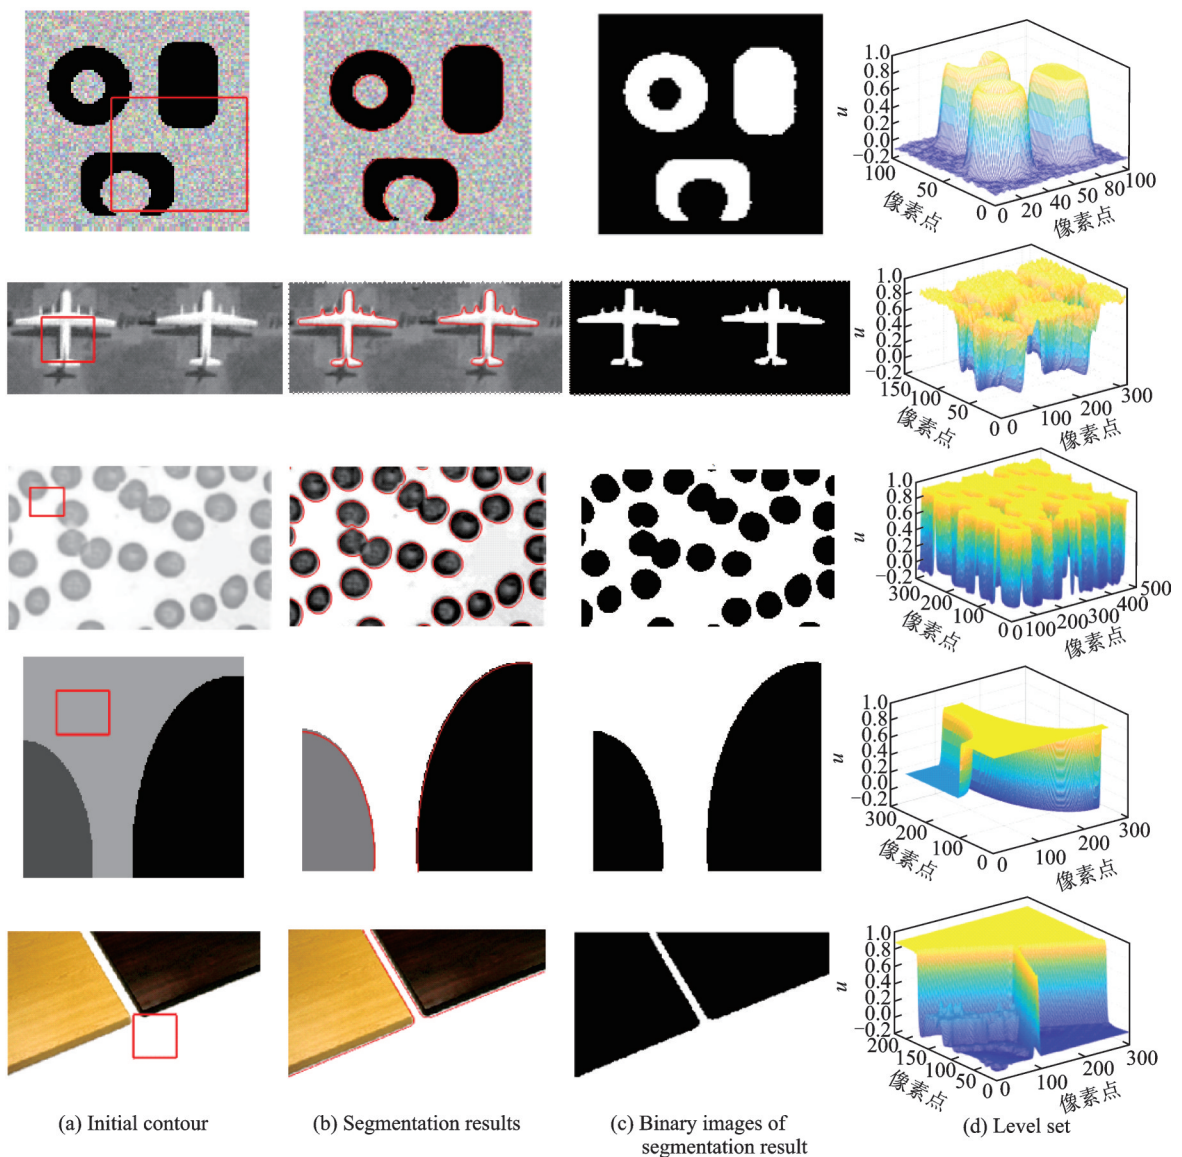


图2 本文模型对多目标图像的分割

Fig.2 Segmentation results of multi-target images by the proposed model

3.2 对比实验

实验2验证了本文模型对自然图像分割的有效性,并与FRAGL^[20]和HLFRA模型进行对比,结果如图3所示。图3中第1列为初始轮廓,第2列为FRAGL模型分割结果,第3列为HLFRA模型分割结果,第4列为本文模型分割结果。图3结果表明,虽然在对具有明显轮廓的图像进行分割时,HLFRA模型和本文模型的分割结果没有太大差距,但在对纹理稍微复杂一点的图像(如仙人掌)进行分割时,本文模型有明显优势,可以准确提取其轮廓。除此之外,本文也对比了3个模型的CPU运行时间,结果如表1所示。从表1可以看出,虽然3个模型用时都比较少(用时较短的用黑体已标出),但相对于FRAGL和HLFRA模型,本文模型更快、更具有优势。




图3 不同模型对自然图像以及合成图像分割的结果

Fig.3 Segmentation results for natural and synthetic images using different models

表 1 FRAGL, HLFRA 模型与本文模型图像分割的 CPU 时间对比

Table 1 Comparison of CPU time of FRAGL, HLFRA and the proposed models

图像	FRAGL	HLFRA	本文模型
图 2 第 1 行图像	3.009 465	0.177 466	0.174 586
图 2 第 2 行图像	2.420 788	0.580 330	0.561 513
图 2 第 3 行图像	6.640 785	1.733 259	1.681 279
图 2 第 4 行图像	4.121 511	0.410 820	0.392 672
图 2 第 5 行图像	3.774 158	0.873 604	0.767 772
图 3 第 1 行图像	4.726 040	2.169 857	1.854 279
图 3 第 2 行图像	4.698 897	2.631 733	2.570 861
图 3 第 5 行图像	0.811 692	1.899 670	1.766 023
图 3 第 6 行图像	3.574 319	0.479 671	0.455 031

3.3 初始轮廓鲁棒性验证

实验 3 对初始轮廓的鲁棒性进行验证。设置不同初始轮廓的位置和大小,在合成图像和灰度不均匀图像上对其进行验证,结果如图 4 所示,图(a~f)中左图为初始轮廓,右图为分割结果。图 4 结果表明,无论初始轮廓是否包含了目标,都可以对其进行准确分割。

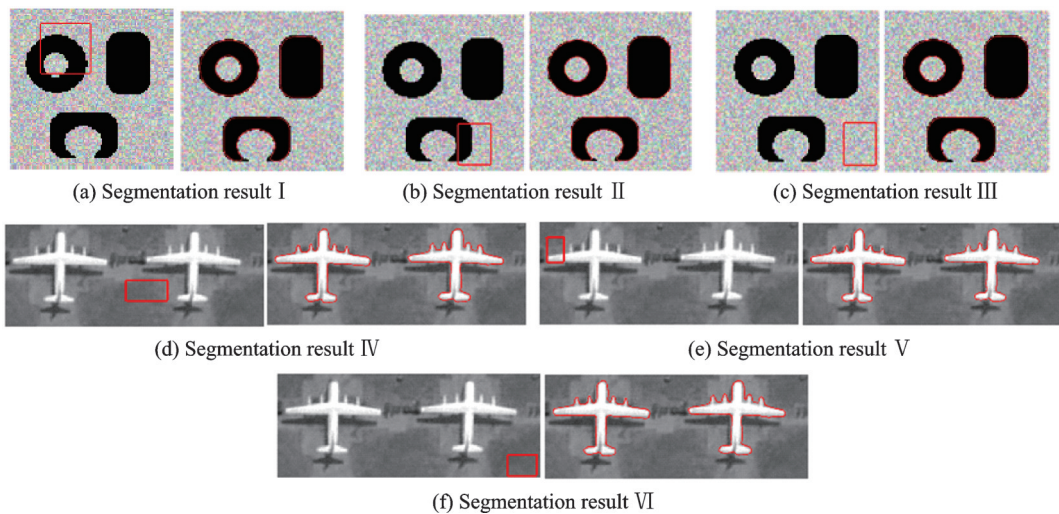


图 4 本文模型对初始轮廓的鲁棒性

Fig.4 Robustness of initial contour by the proposed model

3.4 轮廓演化过程

为了更直观地观察曲线演化过程,实验 4 对仙人掌的分割过程进行呈现,每经过 10 次迭代展示一次,结果如图 5 所示。当迭代 50 次时,就可精确分割出仙人掌的轮廓。

3.5 噪声鲁棒性验证

实验 5 使用 HLFRA 模型和本文模型对增加不同噪声的自然图像进行分割,结果如图 6 所示。为了验证本文模型的鲁棒性,在图 6 中加入了均值全为 0 和方差分别为 0.05 的高斯噪声(第 1 列),0.05 的斑

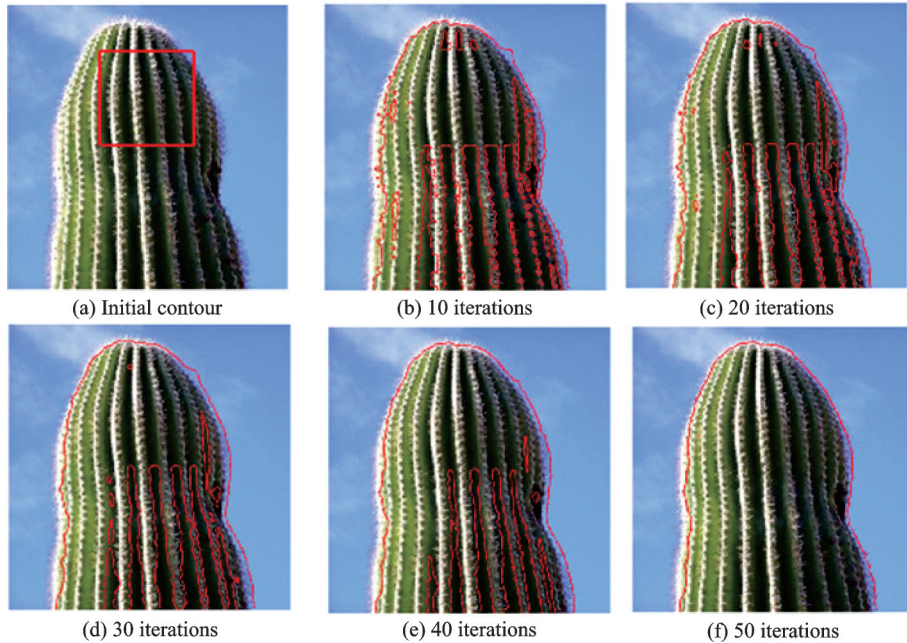
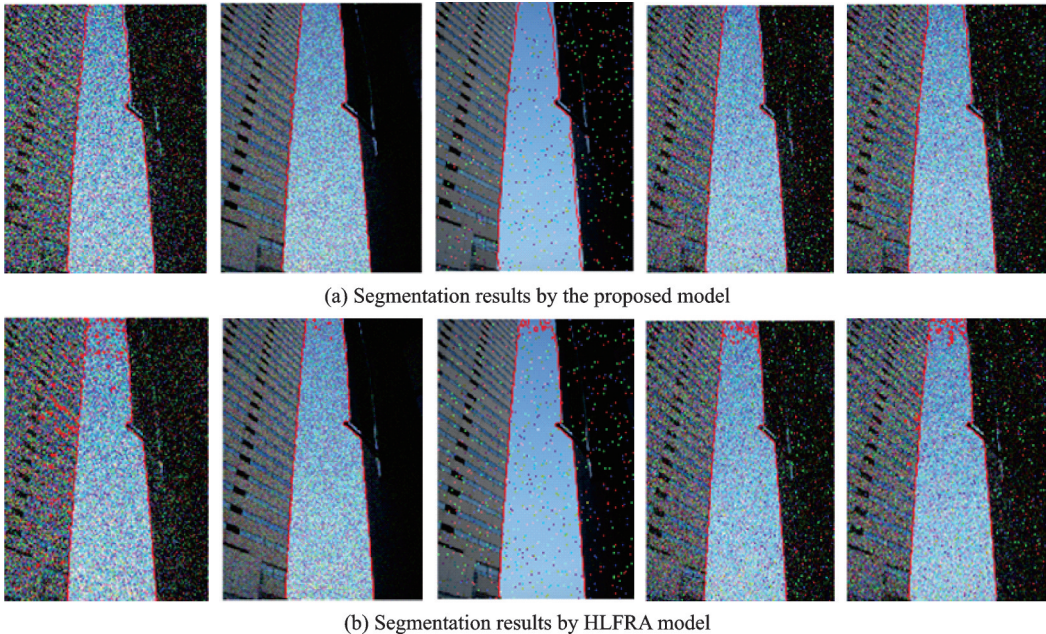


图5 对仙人掌进行分割时的曲线演化过程

Fig.5 Curve evolution process of partitioning Cactus image



(b) Segmentation results by HLFRA model

图6 噪声图像的分割结果

Fig.6 Segmentation results of noisy images

点噪声(第2列),0.02的椒盐噪声(第3列),方差为0.02的高斯噪声+方差为0.02的椒盐噪声(第4列),方差为0.02的高斯噪声+方差为0.02的椒盐噪声+方差为0.05斑点噪声(第5列)。图6中的分割结果表明,只有本文模型能准确地提取出5幅高噪声图像中的目标。

3.6 客观评价指标

本文采用Dice相似系数DSC和Jaccard指数JSC对分割结果进行评价。Dice系数是一种集合相似性度量指标,通常用于计算2个样本的相似度,取值范围为[0,1],分割结果越好,值越大。Jaccard指数是比较样本集的相似性和多样性的统计量,值越大说明相似度越高。2个指标定义为

$$DSC = \frac{2(S_1 \cap S_2)}{S_1 + S_2}$$

$$JSC = \frac{S_1 \cap S_2}{S_1 \cup S_2}$$

式中: S_1 表示真实轮廓; S_2 表示模型分割结果。在Berkely Segmentation Dataset BSDS500数据集选取3张图像(图7),并与HLFRA模型的分割结果进行比较,其指标对比如表2所示。表2结果验证了本文模型的优越性。




图7 用于客观评价的图像
Fig.7 Images for objective evaluation

表2 客观评价指标的比较
Table 2 Comparison of objective evaluation indexes

图像	DSC		JSC	
	HLFRA	本文模型	HLFRA	本文模型
图7(a)	0.755 1	0.958 9	0.606 6	0.921 1
图7(b)	0.964 0	0.965 0	0.930 4	0.932 3
图7(c)	0.981 6	0.987 6	0.963 8	0.975 6

4 结束语

本文基于变异系数和模糊集,提出一个针对活动轮廓图像的分割模型。该模型首先利用变异系数对结合了图像空间信息的局部灰度值进行拟合,得到区域能量泛函,驱使曲线向目标移动。然后结合边缘能量,保持演化曲线的光滑性,使其能精确地停在目标边界。最后,通过直接计算新旧能量函数之间的差异对伪水平集进行更新。实验结果表明,本文模型能够成功地从高噪声、混合噪声以及高强度不均匀性的合成图像和真实图像中提取目标,并且结果不受初始轮廓(位置和大小)的影响。

参考文献:

[1] FANG J X, LIU H X, ZHANG L T, et al. Region-edge-based active contours driven by hybrid and local fuzzy region-based energy for image segmentation[J]. Information Sciences, 2021, 546: 397-419.
[2] KASS M, WITKIN A, TERZOPOULOS D. Snakes: Active contour models[J]. International Journal of Computer Vision,

- 1988, 1(4): 321-331.
- [3] CASELLES V, KIMMEL R, SAPIRO G. Geodesic active contours[J]. *International Journal of Computer Vision*, 1997, 22(1): 61-79.
- [4] CHAN T, VESE L. Active contours without edges[J]. *IEEE Transactions on Image Processing*, 2001, 10(2): 266-277.
- [5] ZHU S C, YUILLE A. Region competition: Unifying snakes, region growing, and Bayes/MDL for multiband image segmentation[J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 1996, 18(9): 884-990.
- [6] DAVID M, SHAH J. Optimal approximation by piecewise smooth functions and associated variational problems[J]. *Communications on Pure & Applied Mathematics*, 1989, 42(5): 577-685.
- [7] 张洋, 唐克伦, 刘琰, 等. 一种改进的 C-V 主动轮廓模型[J]. *四川理工学院学报(自然科学版)*, 2014, 27(5): 33-36.
ZHANG Yang, TANG Kelun, LIU Yan, et al. An improved active contour model based on C-V model[J]. *Journal of Sichuan University of Science & Engineering (Natural Science Edition)*, 2014, 27(5): 33-36.
- [8] 朱雷, 杨璟, 黄席樾. 局部 C-V 主动轮廓模型快速图像分割算法[J]. *重庆大学学报*, 2012, 35(5): 33-36.
ZHU Lei, YANG Jing, HUANG Xiyue. A fast image segmentation algorithm with local C-V active contour model[J]. *Journal of Chongqing University*, 2012, 35(5): 33-36.
- [9] 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[J]. *Image and Vision Computing*, 2009, 28(4): 668-676.
- [10] LI C M, KAO C Y, GORE J C, et al. Minimization of region-scalable fitting energy for image segmentation[J]. *IEEE Transactions on Image Processing*, 2008, 17(10): 1940-1949.
- [11] KRINIDIS S, CHATZIS V. Fuzzy energy-based active contour[J]. *IEEE Transactions on Image Processing*, 2010, 18(12): 2747-2755.
- [12] SHYU K, PHAM V, TRAN T, et al. Global and local fuzzy energy-based active contours for image segmentation[J]. *Nonlinear Dynamics*, 2011, 67(2): 1559-1578.
- [13] MONDAL A, GHOSH S, GHOSH A. Robust global and local fuzzy energy based active contour for image segmentation[J]. *Applied Soft Computing*, 2016, 47: 191-215.
- [14] MONDAL A, GHOSH S, GHOSH A. Partially camouflaged object tracking using modified probabilistic neural network and fuzzy energy based active contour[J]. *International Journal of Computer Vision*, 2017, 122(1): 116-148.
- [15] SUN W Y, DONG E Q, QIAO H J. A fuzzy energy-based active contour model with adaptive contrast constraint for local segmentation[J]. *Signal Image & Video Processing*, 2017, 12(12): 1-8.
- [16] TRAN T T, PHAM V T, SHYU K K. Image segmentation using fuzzy energy-based active contour with shape prior[J]. *Journal of Visual Communication & Image Representation*, 2014, 25(7): 1732-1745.
- [17] AHMAD A, BADSHAH N, ALI H. A fuzzy variational model for segmentation of images having intensity inhomogeneity and slight texture[J]. *Soft Computing*, 2020. DOI:10.1007/s00500-020-04878-9.
- [18] SHARON A, MEIRAV G, ACHI B, et al. Image segmentation by probabilistic bottom-up aggregation and cue integration [C]//*Proceedings of IEEE Conference on Computer Vision & Pattern Recognition*. [S.l.]: IEEE, 2012: 315-327.
- [19] ARBELÁEZ P, MAIRE M, FOWLKES C, et al. Contour detection and hierarchical image segmentation[J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2011, 33(5): 898-916.
- [20] FANG J X, LIU H X, ZHANG L T, et al. Fuzzy region-based active contours driven by weighting global and local fitting energy[J]. *IEEE Access*, 2019, 7: 184518-184536.

作者简介:



黄丽转(1997-),女,硕士研究生,研究方向:图像分割,E-mail:lizhuanHuang@yeah.net。



刘国军(1978-),通信作者,男,博士,教授,博士生导师,研究方向:图像处理的小波和偏微分方程、图像质量评价、机器学习,E-mail:liugj@nxu.edu.cn。



魏立力(1965-),男,博士,教授,硕士生导师,研究方向:序贯分析、定性数据分析、模糊集理论及其应用。