

结合全局与局部信息的主动轮廓分割模型*

赵丽科¹, 郑顺义^{1,2}, 魏海涛¹, 桂力^{1,2,3}

(1. 武汉大学 遥感信息工程学院, 湖北 武汉 430079; 2. 地球空间信息技术协同创新中心, 湖北 武汉 430079;
3. 武汉大学 电子信息学院, 湖北 武汉 430072)

摘要:针对传统的基于区域的主动轮廓模型在分割灰度不均匀图像和噪声图像存在效果不佳的问题,提出结合全局项与局部项的主动轮廓分割模型。全局项由 CV(Chan-Vese)模型的保真项构成,局部项的构建考虑局部区域信息的同时引入反映图像灰度特性的局部熵信息。依据图像灰度的特点,选择合理的全局项和局部项参数,并加入正则项保证曲线在演化过程中保持平滑,保障分割结果的可靠性。通过变分水平集方法最小化能量泛函,依据梯度下降流迭代更新水平集,完成曲线演化。采用模拟图像和实际图像进行实验分析,结果表明,所提出的结合全局项和局部项的主动轮廓模型可以高效地分割噪声严重以及灰度分布不均匀的图像。

关键词:灰度不均匀; 图像熵; 局部项; 水平集
中图分类号:TP391.41 **文献标志码:**A **文章编号:**1001-2486(2018)01-099-08

An active contour segmentation model combining global and local region-based information

ZHAO Like¹, ZHENG Shunyi^{1,2}, WEI Haitao¹, GUI Li^{1,2,3}

(1. School of Remote Sensing and Information Engineering, Wuhan University, Wuhan 430079, China;
2. Collaborative Innovation Center of Geospatial Technology, Wuhan 430079, China;
3. School of Electronic Information, Wuhan University, Wuhan 430072, China)

Abstract: Aimed at the problem of the traditional region-based active contour model, which was difficult to segment the noisy images and intensity inhomogeneous images, an active contour model, including global term, local term and regularization term, was proposed. Global term was derived from the data fidelity items of Chan-Vese model. Meanwhile, the construction of local term took the local intensity information into account and the image local entropy that reflected the grey characteristics was introduced. According to the characteristics of different images, the reasonable parameters of global item and local item were selected. The regularization term was added to ensure the smoothness of curve evolution and to guarantee the reliability of segmentation. A variable level set was used to minimize the energy function to get the gradient descent flow. Experimental results of synthetic images and real images demonstrate that the proposed approach is efficient in segmenting the noisy images and inhomogeneity images.

Key words: intensity inhomogeneity; image entropy; local term; level set method

图像分割是图像分析、图像识别和计算机视觉领域的重要研究内容,通过将图像划分为若干个特定的、具有独特性质的区域,以达到为后续应用提供基础的目的^[1-2]。采用不同的分类依据可以将图像分割分为不同的类别,依据分割方法的特点图像分割可以分为:阈值化、基于边缘的分割、基于区域的分割、基于马尔科夫随机场的分割、基于主动轮廓模型的分割、基于模糊聚类的分割和基于神经网络的分割等^[3]。阈值化的方法适用于灰度差异较大的图像,但忽略了图像的空

间信息,分割灰度差异较小的图像时易产生错分误分;基于边缘的图像分割方法当区域间灰度差异较大时分割效果较好,但由于未考虑空间信息,该方法抗噪能力差;基于区域的图像分割是利用图像的灰度、纹理等特征划分像素,该类方法抗噪性较好,但运算量和所需存储空间较大;基于马尔科夫随机场模型的方法具有严密的数学理论,可扩展性好,可以便捷地融入多种特征,但需要合理的初始值,否则容易陷入局部最优;基于主动轮廓模型的方法具有自动处理拓扑变化的能力,具有

* 收稿日期:2016-11-28
基金项目:国家自然科学基金资助项目(41671452);中央高校基本科研业务费专项资金资助项目(2042016k012);湖北省科技支撑计划资助项目(2015BCE080)
作者简介:赵丽科(1990—),女,河南新乡人,博士研究生,E-mail:zlk_lenci@163.com;
郑顺义(通信作者),男,教授,博士,博士生导师,E-mail:syzheng@263.net

捕捉局部形变等优点,但对初始曲线较为敏感;基于模糊聚类的图像分割不需要训练集,但需要事先确定类别数目,对噪声敏感;基于神经网络的分割需要大量的训练样本集,计算速度较慢。

近年来,许多学者^[4-5]将水平集与活动轮廓模型结合进行图像分割的研究,凭借其优势成为图像处理领域的研究热点。依据分割所使用图像的特征可以将基于水平集分割的主动轮廓模型分为:基于边缘信息的方法^[6-7]和基于区域信息的方法^[8-9]。其中,利用边缘信息的方法通过图像的梯度信息控制曲线的演化,使曲线停止在目标的边界位置。该方法可以有效地分割出图像中具有强边缘的物体,但由于该类方法依赖于图像的梯度,对噪声敏感,不能够检测出物体的弱边缘,并对初始轮廓敏感^[10]。基于区域的方法利用图像的区域统计信息控制曲线的演化,该类方法与基于边缘的方法相比,具有抗噪性好,能够分割图像中的弱边缘以及模糊图像中目标物体的优势,同时对曲线的初始位置不敏感。

CV 模型^[8]是基于区域方法中的典型方法之一,该方法是假定图像中目标和背景均是同质区域,与图像中梯度无关,具有基于区域方法的优点。但在处理灰度不均匀图像时,由于曲线内部和外部的图像灰度不同质,不能得到较好的分割结果。为了解决这一问题,许多学者提出了不同的解决思路,Vese 和 Chan^[11]采用 2 个光滑函数表示区域不同位置的灰度,解决了 CV 模型无法处理灰度不均匀图像的问题。但该方法计算复杂度高,限制了其应用。局部二值拟合模型(Local Binary Fitting, LBF)^[12]通过采用图像的局部灰度信息,具有一定的分割不均匀图像的能力,但该方法对初始位置以及图像的噪声较为敏感。这些方法在分割灰度分布严重不均匀、噪声较严重的图像时,并不能取得令人满意的分割效果。近年来,一些学者^[9, 13-14]将具有不同特性的模型进行结合,提出了具有两者优势的混合模型。Wang 等提出的 LCV(local Chan-Vese)模型^[9]采用全局与局部区域信息相结合进行图像分割,但该模型本质上可以被看作在原始图像以及其变换图像上的 CV 模型,仍旧不能摆脱分割灰度不均匀图像的缺陷。Yuan 等提出的 LBG 模型^[13]则采用区域信息以及局部梯度信息组合构建能量函数,该模型对初始轮廓敏感。Zhao 等^[14]将全局能量项与局部梯度项进行结合构建能量函数,由于模型受到梯度信息的影响,该模型对初始曲线敏感,耗时较长。Fox 等^[15]结合边缘和区域信息对图像进行

分割,该方法在一定程度上保障了分割的可靠性,但对初始曲线较敏感。这些方法在一定程度上提高了图像分割的效果,但仍旧未能兼顾全局项和局部项的优势以及未充分考虑图像灰度特点,在分割灰度不均匀图像、噪声图像时仍旧存在问题。

本文提出一种基于区域的主动轮廓分割模型,该模型由全局能量项、局部能量项和正则项三部分构成。全局能量项可以提高模型的抗噪能力,并对初始曲线位置不敏感;结合局部熵构建局部能量项,局部熵反映邻域内灰度变化的特点,保证了处理灰度不均匀图像时的可靠性;正则项则控制曲线在演化过程中保持平滑。不同于以往结合全局项和局部项的方法,本文的局部项考虑了图像的局部熵信息,充分利用图像灰度分布的特性,并分割模拟和实际图像来验证提出模型的可靠性。

1 结合全局与局部信息的主动轮廓模型

本文提出一种结合全局和局部信息的主动轮廓模型,由全局项、局部项和正则项三部分构成,能量泛函如式(1)所示。

$$E = \alpha E^G + \beta E^L + E^R \quad (1)$$

其中: E^G 表示全局能量项; E^L 为局部能量项; E^R 是正则项; α 、 β 则分别表示全局能量项和局部能量项的参数,用以权衡全局能量项和局部能量项在曲线演化中所发挥的作用。 α 、 β 的取值依据图像的灰度不均匀情况设定,同质图像应选用较大的 α 值和较小的 β 值;当图像存在灰度不均匀情况时, α 取较小的值, β 取较大的值。

1.1 全局能量项

全局能量项来源于 CV 模型^[8]的保真项,设 I 是定义在区域 $\Omega \subset R^2$ 的灰度图像, C 表示闭合活动轮廓曲线,全局能量项如式(2)所示。

$$E^G(C) = \lambda_1 \int_{\text{inside}(C)} |I(x) - c_1|^2 dx + \lambda_2 \int_{\text{outside}(C)} |I(x) - c_2|^2 dx \quad (2)$$

其中,闭合曲线 C 将图像划分为目标(曲线内部 $\text{inside}(C)$)与背景(曲线外部 $\text{outside}(C)$)两部分, c_1 、 c_2 分别表示图像在闭合曲线内部和外部的灰度平均值, λ_1 、 λ_2 均是非负常数,通常取 $\lambda_1 = \lambda_2 = 1$ 。

采用水平集的方法,零水平集函数 $\phi: \Omega \rightarrow R$ 可以表示演化曲线 $C \subset \Omega$,即 $C = \{x \in \Omega \mid \phi(x) = 0\}$,则全局能量泛函可以表示为如式(3)所示。

$$E^G(\phi, c_1, c_2) = \int_{\text{inside}(C)} |I(x) - c_1|^2 H(\phi(x)) dx + \int_{\text{outside}(C)} |I(x) - c_2|^2 [1 - H(\phi(x))] dx \quad (3)$$

其中, c_1, c_2 的具体计算方式如式(4)所示。

$$\begin{cases} c_1 = \frac{\int_{\Omega} I(x) H_{\varepsilon}(\phi(x)) dx}{\int_{\Omega} H_{\varepsilon}(\phi(x)) dx} \\ c_2 = \frac{\int_{\Omega} I(x) [1 - H_{\varepsilon}(\phi(x))] dx}{\int_{\Omega} [1 - H_{\varepsilon}(\phi(x))] dx} \end{cases} \quad (4)$$

其中, H 表示 Heaviside 函数, 实际应用中, Heaviside 函数 H 采用近似的正则化平滑 H_{ε} 函数, H_{ε} 函数的导数为 δ_{ε} , 如式(5)所示, 其中 ε 为正常数。

$$\begin{cases} H_{\varepsilon}(z) = \frac{1}{2} \left[1 + \frac{2}{\pi} \arctan\left(\frac{z}{\varepsilon}\right) \right] \\ \delta_{\varepsilon}(z) = H'_{\varepsilon}(z) = \frac{1}{\pi} \frac{\varepsilon}{\varepsilon^2 + z^2} \end{cases} \quad (5)$$

待分割图像为灰度同质图像时, 上述能量项可以很容易地将图像的目标和背景区域分割。但对于灰度不均匀图像, 很难将图像的背景和区域分割出来, 此时需要考虑图像的局部信息。

1.2 局部能量项

Shannon^[16]首先提出信息熵的概念, 在图像处理中, 图像熵统计图像的灰度信息, 可以表征图像灰度的分布情况^[17]。图像的灰度变化相对丰富时, 图像熵较大; 反之, 图像灰度相对单一情况下图像熵较小^[18]。由香农第二定理^[16], 图像的局部熵定义如式(6)所示。

$$h_x(P_x(y)) = - \int_0^L P_x(y) \log_2 P_x(y) dy \quad (6)$$

其中, h_x 为像素 x 的局部熵, 灰度级 y 满足 $0 \leq y \leq L$, 定义以 x 为中心的窗口 W , $P_x(y)$ 为像素 $x \in \Omega$ 的局部图像灰度概率密度估计, 具体定义如式(7)所示。

$$P_x(y) = \frac{|\{z \in W \cap \Omega: I(z) = y\}|}{|W \cap \Omega|} \quad (7)$$

为了避免在灰度单一和丰富情况下出现局部熵过小与过大的问题, 将图像局部熵的值域归一化到区间 $[1, 2]$, 图1为图像局部熵示意图。通常的基于局部区域的主动轮廓模型中, 未能充分考虑图像的灰度变化, 由于图像熵信息反映了灰度变化的特点, 本文将图像局部熵信息引入到局部能量项中。




图1 图像局部熵示意图

Fig. 1 Schematic diagram of image local entropy

局部能量项的构建在考虑局部区域灰度的同时加入局部熵信息, 局部灰度信息采用像素点和邻域像素点差值进行拟合, 局部能量项如式(8)所示。

$$E^L(C) = \int_{\text{inside}(C)} h_x \cdot [I(x) - f_1(x)]^2 dx + \int_{\text{outside}(C)} h_x \cdot [I(x) - f_2(x)]^2 dx \quad (8)$$

文中所有实验采用计算局部熵的窗口均为 9×9 , $f_1(x), f_2(x)$ 为像素 x 局部邻域信息的加权平均值, 如式(9)所示。

$$\begin{cases} f_1(x) = \frac{\int_{\Omega} g_k(x-y) [I(y) H(\phi(y))] dy}{\int_{\Omega} g_k(x-y) H(\phi(y)) dy} \\ f_2(x) = \frac{\int_{\Omega} g_k(x-y) \{I(y) [1 - H(\phi(y))]\} dy}{\int_{\Omega} g_k(x-y) [1 - H(\phi(y))] dy} \end{cases} \quad (9)$$

其中, g_k 为高斯核函数。高斯核函数具有局部性, 当 y 距离 x 较远时, $g_k(x-y)$ 值较小, 灰度 $I(y)$ 对 $f_1(x)$ 与 $f_2(x)$ 的作用越小。

采用水平集方法, 局部能量泛函如式(10)所示。

$$\begin{aligned} E^L(\phi, f_1, f_2) \\ = \int_{\text{inside}(C)} h_x \cdot [I(x) - f_1(x)]^2 H(\phi(x)) dx + \int_{\text{outside}(C)} h_x \cdot [I(x) - f_2(x)]^2 [1 - H(\phi(x))] dx \end{aligned} \quad (10)$$

1.3 正则项

为了曲线在演化过程中保持零水平集的平滑, 需要在能量泛函中加入长度约束项, 可以限制曲线的长度, 当能量泛函达到最小值时, 闭合曲线尽可能地保持较短的长度。曲线的长度惩罚项如式(11)所示。

$$L(\phi) = \int_{\Omega} |\nabla H(\phi(x))| dx \quad (11)$$

其中, ∇ 为梯度算子。

然而,随着曲线演化的进行,水平集函数会发生震荡不能保持平滑,为了避免重新初始化,考虑能量惩罚项,如式(12)所示。

$$P(\phi) = \int_{\Omega} \frac{1}{2} (|\nabla \phi(x)| - 1)^2 dx \quad (12)$$

正则项由长度惩罚项和能量惩罚项构成,如式(13)所示。

$$E^R = \nu L(\phi) + \mu P(\phi) \quad (13)$$

其中, $\mu > 0, \nu > 0$ 。

2 水平集与算法实现

2.1 水平集

采用水平集的方法,整个能量泛函可以用式(14)表示。

$$E(\phi, f_1, f_2, c_1, c_2) = \alpha E^G(\phi, c_1, c_2) + \beta E^L(\phi, f_1, f_2) + E^R \quad (14)$$

采用梯度下降流的方法最小化能量泛函,依据变分水平集的方法,可以得到式(15)、式(16)。

$$\frac{\partial \phi}{\partial t} = \delta_{\varepsilon}(\phi) (F_1 + F_2) + \nu \delta_{\varepsilon}(\phi) \operatorname{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) + \mu \left[\nabla^2 \phi - \operatorname{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) \right] \quad (15)$$

$$\begin{cases} F_1 = -\alpha(I - c_1)^2 - \beta h_x(I - f_1)^2 \\ F_2 = \alpha(I - c_2)^2 + \beta h_x(I - f_2)^2 \end{cases} \quad (16)$$

其中, $\operatorname{div}(\cdot)$ 表示散度, $\operatorname{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right)$ 为水平集曲面的曲率。

当曲线距离目标较远时,全局项起主导作用,当曲线距离目标边界较近时,局部项发挥主要作用,全局能量项和局部能量项协同作用,使曲线演化到目标的边界位置。

2.2 算法实现步骤

经过上述对图像分割算法的描述,可以将分割步骤概括如下:

- ①初始化水平集函数 ϕ , 同时初始化各项参数 $\alpha, \beta, \sigma, \varepsilon, \mu, \nu$, 并且初始化局部熵的窗口尺寸以及时间步长;
- ②依据式(6)计算局部熵信息;
- ③按照式(4)、式(9)计算 c_1, c_2, f_1 和 f_2 ;
- ④将水平集函数依照式(15)进行更新;
- ⑤检查曲线的演化是否稳定,若稳定则结束,不稳定则返回步骤③继续更新水平集。

3 实验分析

本文在 CPU i5 2.8 GHz、8 GB 内存、Windows7 64 位操作系统的 PC 机上使用 MATLAB R2015a 编程实现所有算法。采用本文提出的分割模型对模拟和实际图像分别进行实验,验证所提方法的可靠性。

3.1 同质图像分割

首先,将本文方法用于分割同质图像,同质图像分割时,全局信息起主导作用,设置 $\alpha = 0.9, \beta = 0.1$, 图 2 为分割同质图像的结果。其中,图 2(a)为曲线的初始位置,图 2(b)为与之对应的图像分割结果。从图 2 可以看出,当曲线初始位置不同时,本文方法可以有效地分割出同质图像,对初始曲线不敏感。




图 2 本文方法分割同质图像

Fig. 2 Results of homogeneity images of proposed method

验证本文方法对含有噪声的同质图像的分割能力,并与 CV 模型和 LBF 模型进行对比,图 3 为噪声图像的分割结果,分割时采用参数 $\alpha = 0.9, \beta = 0.1$ 。




图 3 不同方法对噪声图像的分割结果

Fig. 3 Results of noisy images of different methods

图 3 (a) 为图像的初始位置,图 3 (b)、图 3 (c)、图 3 (d) 分别为 CV 模型、LBF 模型和本文所提方法的分割结果。可以看出,CV 模型抗噪性强,LBF 模型对于噪声图像不能保证分割的可靠性,受初始曲线影响,存在未能有效分割的情况;本文所提模型与 CV 模型结果相当,但分割含有噪声的灰度不均匀图像时能取得较好的结果。本文所提方法保留了 CV 模型对初始曲线不敏感以及抗噪性好的特点。这是由于 CV 模型考虑了全局信息,全局信息对初始曲线不敏感以及鲁棒性好。本文模型同时考虑了全局能量项和局部能量项,当全局项和局部项的参数设为 $\alpha = 1$, $\beta = 0$ 时,本文模型与 CV 模型是相同的。当全局能量项的参数设置较大,局部能量项的参数设置较小时,全局能量项发挥主导作用,保证了本文所提出的模型对初始曲线不敏感,且抗噪能力强。

3.2 灰度不均匀图像分割

将 CV 模型、LBF 模型以及本文所提模型分别分割灰度不均匀图像,验证本文方法分割灰度不均匀图像的能力,如图 4 所示。




图 4 不同方法对灰度不均匀图像分割结果
Fig. 4 Results of the segmentation of intensity inhomogeneity images of different methods

图 4 (a) 为不同初始位置,图 4 (b)、图 4 (c)、图 4 (d) 分别为采用 CV 模型、LBF 模型和本文所提分割模型的结果。前两行本文模型采用参数 $\alpha = 0.05$, $\beta = 0.95$, 后两行采用参数 $\alpha = 0.3$, $\beta = 0.7$ 。由 CV 模型的分割结果可以看出,无论初始位置在何处,CV 模型得到的结果均不能有效地完成分割,这是由于只考虑了全局信息,造成分割灰度不均匀图像失败。LBF 模型考虑了灰度局部

信息,可以分割出第四幅图像,但前三幅图像难以得到可靠结果。前两幅图像灰度不均匀程度较严重时分割失败,可以完成第四幅的分割但不能有效分割第三幅图像,这表明 LBF 模型受初始位置的影响较严重。本文所提模型根据图像的灰度不均匀程度选取合适的 α 与 β 的值,分割灰度不均匀图像时,选取较小的 α 值与较大的 β 值,即全局信息保证初始轮廓较快的收敛到目标位置附近,局部信息在轮廓收敛到目标位置附近时发挥主导作用确保轮廓分割的正确性。依据灰度分布特性选择合理的参数,考虑图像的全局信息和局部信息,对灰度不均匀图像能够分割获取满意结果,且对曲线的初始位置不敏感。

采用含有噪声的灰度不均匀图像进一步验证本文模型进行分割的可靠性,如图 5 所示。图 5 (a) 表示曲线初始轮廓,图 5 (b) 为本文模型的分割结果。从分割结果可以看出,本文方法具备分割含有噪声的灰度不均匀图像的能力,同时具有全局能量项的抗噪性和局部能量项分割灰度不均匀图像的优势,验证了本文模型分割含有噪声的灰度不均匀图像的可靠性。




图 5 灰度不均匀图像的分割结果
Fig. 5 Results of the proposed method of segmenting intensity inhomogeneity noisy images

3.3 引入局部熵的作用

为了分析局部项中引入局部熵的作用,不考虑全局项的情况下,即将参数设置为 $\alpha = 0$, $\beta = 1$ 时,比较局部能量项在未引入和引入局部熵的分割实验。图 6 为图像分割结果示例,图 6 (a) 表示初始轮廓,图 6 (b)、图 6 (c) 分别为未引入局部熵和引入局部熵迭代 60 次的曲线,图 6 (d)、图 6 (e) 分别为未引入局部熵和引入局部熵的分割结果。从图中可以直观地看出,灰度不均匀图像在未引入局部熵时,没有

获取满意的分割结果。引入局部熵充分考虑了图像的灰度不均匀特性,因而得到了满意的分割结果。在未引入局部熵时,迭代次数为

298 次;加入局部熵时,迭代次数减少为 114 次,引入局部熵在改善分割结果的同时提高了分割的速度。




图 6 引入局部熵的作用
Fig. 6 Influence of image local entropy

3.4 α, β 参数选取

为了分析探讨如何选取合适的 α, β 参数,依次选取不同的 $\alpha, \beta (\beta = 1 - \alpha)$ 值对同质图像以及灰度不均匀图像进行实验,图像大小为 300×300 。图 7(a)是对同质图像采用不同参数获取的分割结果,图 7(b)是对灰度不均匀图像采用不同参数获取的分割结果。图 7(a)分别为 $\alpha = 0, \alpha = 0.1$ 和 $\alpha = 1$ 的分割结果,图 7(b)分别为 $\alpha = 0, \alpha = 0.01$ 和 $\alpha = 0.1$ 的分割结果。上述参数均可以完成图像分割,表 1 为对应图 7 的迭代次数以及耗时情况。




图 7 不同 α, β 参数结果

Fig. 7 Segmentation results of different parameters of α, β

从表 1 中可以看出,当分割同质图像时,虽然采取不同的参数取值均可以获得满意的分割结果,但当全局能量参数即 α 越大,迭代次数越少,耗时越短。 $\alpha = 0$ 时虽然能得到满意的分割结果,但是

耗时较长,将 α 值设为 0.1 时速度就有了很大的提升,这表明了加入全局项的重要性。分割灰度不均匀图像时,文中选用的几组参数均可得到满意的分割结果,总体上局部能量项的参数 β 值较大,但仍需加入全局能量项,将 α 设为 0.01,迭代次数相较于 $\alpha = 0$ 时明显减少,速度明显提升,全局能量项的加入可以加快分割速度。从中可以看出,对于同质图像可以设置较大的 α 值,较小的 β 值,否则容易造成分割耗时过长,理论基础和相关实验得出 α 取区间 $[0.7, 1]$ 的值时,在保障分割可靠性的同时又确保了分割速度较快。对于灰度不均匀图像, α 需设置为较小的值, β 设置为较大的值,否则容易造成分割失败,依据理论基础和相关实验可得 α 取 $[0, 0.3]$ 时,保证分割结果速度的同时又取得了较好的分割结果。

表 1 图 7 中的迭代参数以及耗时情况

Tab. 1 Number of iterations and processing time with different parameters of figure 7

	第 2 列		第 3 列		第 4 列	
	迭代次数	耗时/s	迭代次数	耗时/s	迭代次数	耗时/s
第 1 行	92	2.92	2	0.06	1	0.03
第 2 行	464	14.97	134	4.35	79	2.56

3.5 与典型算法对比分析

采用实际的图像验证本文所提分割方法的可靠性,同时与 LCV 模型、文献[14]模型以及 LBG 模型进行实验对比,实验结果如图 8 所示。图 8(a)为不同的曲线初始化位置,图 8(b)为 LCV 模型的分割结果,图 8(c)为文

献[14]模型分割结果,图 8(d)为 LBG 模型分割结果,图 8(e)为本文模型的分割结果。分割前四幅图像时本文模型选取参数 $\alpha = 0.2$, $\beta = 0.8$,后两幅图像则选取参数 $\alpha = 0.9$, $\beta = 0.1$ 进行分割。表 2 为对应图 8 各方法的迭代次数以及处理时间。LCV 模型耗时较短,但其分割前四列图像时并没有取得较好的分割结果,这是由于 LCV 模型可以看作由原始图像以及变换的原始图像相结合的 CV 模型,在一定程度上,LCV 模型保留了全局项的特点。同时这也较好地解释了该方法完成后两列灰度同质图像的分割效果。文献[14]的模型能够较好地完成第一列图像的分割,但初始轮廓发生变化后,未能分割出第二列图像。第三幅第四幅图像较好地完成分割,但第五列和第六列图

像未能得到较好的分割结果,该模型分割时间较长,存在难以分割出感兴趣区域的现象。LBG 模型的分割结果与文献[14]相似,这是由于两者均受梯度信息的影响,对初始轮廓敏感,耗时较长且不能取得理想的分割结果。本文提出的模型可以得到满意的分割结果,可以有效地分割同质图像和灰度不均匀图像,耗时较短且对初始轮廓不敏感。

从以上实验结果可以看出,本文所提方法同时考虑了全局信息与局部信息,保留全局项分割灰度同质图像的优势,将局部熵引入到局部项中,充分考虑了图像灰度特点,保证了分割灰度不均匀图像的可靠性。本文模型对轮廓初始位置不敏感,且分割灰度同质以及不均匀的图像可以获得可靠的结果。




图 8 不同方法对实际图像分割结果

Fig. 8 Comparisons of different models on segmenting different real images

表 2 图 8 中的迭代参数以及耗时情况
Tab.2 Number of iterations and processing time of figure 8

	第 1 列		第 2 列		第 3 列		第 4 列		第 5 列		第 6 列	
	迭代 次数	耗时/ s	迭代 次数	耗时/ s	迭代 次数	耗时/ s	迭代 次数	耗时/ s	迭代 次数	耗时/ s	迭代 次数	耗时/ s
LCV 模型	89	0.35	108	0.41	66	0.27	122	0.47	15	0.16	8	0.11
文献[14]模型	50	0.69	219	2.64	42	0.54	67	0.81	98	3.41	84	2.86
LBG 模型	70	1.66	217	5.10	49	1.16	66	1.56	124	8.53	108	7.28
本文模型	64	0.47	81	0.59	92	0.68	76	0.61	22	0.43	12	0.24

4 结论

传统的基于区域的主动轮廓模型存在不能兼顾噪声图像、同质图像和灰度不均匀图像的分割问题,本文构建了由全局项、局部项和正则项三部分构成的主动轮廓模型,并在建立局部项时考虑图像的局部熵信息。所构建的模型兼顾全局信息和局部信息,不同的图像依据其灰度分布特点选择合适的参数,对于灰度同质区域全局能量项发挥主导作用,当图像的灰度分布不均匀时局部能量项占据主导作用控制曲线的演化,考虑全局项和局部项不仅保证了分割模型的抗噪性,而且提高了对灰度不均匀图像分割的可靠性。对于不同的图像,选择合理的全局项和局部项的参数可取得理想的分割结果。通过实验验证,本文所提方法在分割噪声图像以及灰度不均匀图像时,可以得到理想可靠的结果。

参考文献 (References)

[1] Zhou S P, Wang J J, Zhang S, et al. Active contour model based on local and global intensity information for medical image segmentation[J]. Neurocomputing, 2016, 186: 107 – 118.

[2] 侯旺, 钟立军, 张小虎, 等. 红外目标分割方法研究[J]. 国防科技大学学报, 2013, 35(2): 173 – 178.

HOU Wang, ZHONG Lijun, ZHANG Xiaohu, et al. Research on infrared target segmentation [J]. Journal of National University of Defense Technology, 2013, 35 (2): 173 – 178. (in Chinese)

[3] 黄长专, 王彪, 杨忠. 图像分割方法研究[J]. 计算机技术与发展, 2009, 19(6): 76 – 79, 83.

HUANG Changzhuan, WANG Biao, YANG Zhong. A study on image segmentation techniques[J]. Computer Technology and Development, 2009, 19(6): 76 – 79, 83. (in Chinese)

[4] Ji B, Wang J, Liu W Q. Color-based automatic quality control for roasting chicken[J]. Computers and Electronics in Agriculture, 2016, 123: 49 – 56.

[5] 罗红根, 朱利民, 丁汉. 基于主动轮廓模型和水平集方法的图像分割技术[J]. 中国图象图形学报, 2006, 11(3): 301 – 309.

LUO Honggen, ZHU Limin, DING Han. A survey on image segmentation using active contour and level set method[J]. Journal of Image and Graphics, 2006, 11(3): 301 – 309. (in Chinese)

[6] 岑峰, 戚飞虎, 曾文珺. 基于边缘吸引力场正则化的短程

线主动轮廓模型[J]. 电子学报, 2003, 31(1): 17 – 20.

CEN Feng, QI Feihu, ZENG Wenjun. A new geodesic active contour based on attraction field regularization [J]. Acta Electronica Sinica, 2003, 31(1): 17 – 20. (in Chinese)

[7] Slama A B, Mouelhi A, Sahli H, et al. A new preprocessing parameter estimation based on geodesic active contour model for automatic vestibular neuritis diagnosis [J]. Artificial Intelligence in Medicine, 2017, 80: 48 – 62.

[8] Chan T F, Vese L A. Active contours without edges[J]. IEEE Transactions on Image Processing, 2001, 10 (2): 266 – 277.

[9] Wang X F, Huang D S, Xu H. An efficient local Chan-Vese model for image segmentation [J]. Pattern Recognition, 2010, 43(3): 603 – 618.

[10] 孙阳光, 蔡超, 周成平, 等. R-Snake: 一种基于边缘与区域信息的图像主动轮廓提取模型[J]. 电子学报, 2009, 37(8): 1810 – 1815.

SUN Yangguang, CAI Chao, ZHOU Chengping, et al. R-Snake: a snake model using both boundary and region information [J]. Acta Electronica Sinica, 2009, 37 (8): 1810 – 1815. (in Chinese)

[11] Vese L A, Chan T F. A multiphase level set framework for image segmentation using the Mumford and Shah model[J]. International Journal of Computer Vision, 2002, 50 (3): 271 – 293.

[12] Li C M, Kao C Y, Gore J C, et al. Implicit active contours driven by local binary fitting energy [C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition, 2007: 1 – 7.

[13] Yuan J J, Wang J J, Liu L P. Active contours driven by local intensity and local gradient fitting energies[J]. International Journal of Pattern Recognition and Artificial Intelligence, 2014, 28(3): 1455006.

[14] Zhao Y Q, Wang X F, Shih F Y, et al. A level-set method based on global and local regions for image segmentation[J]. International Journal of Pattern Recognition and Artificial Intelligence, 2012, 26(1): 1255004.

[15] Fox V L, Milanova M, Al-Ali S. A hybrid morphological active contour for natural images[J]. International Journal of Computer Science, Engineering and Applications, 2013, 3(4): 1 – 13.

[16] Shannon C E. A mathematical theory of communication[J]. Bell System Technical Journal, 1948(27): 379 – 423.

[17] Mitiche A, Ayed I B. Variational and level set methods in image segmentation [M]. Berlin: Springer, 2010.

[18] 陈宇飞, 吴启迪, 赵卫东, 等. 基于图像熵的快速 Chan-Vese 模型分割算法[J]. 同济大学学报(自然科学版), 2011, 39(5): 738 – 744.

CHEN Yufei, WU Qidi, ZHAO Weidong, et al. Fast Chan-Vese segmentation algorithm based on image entropy [J]. Journal of Tongji University (Natural Science), 2011, 39(5): 738 – 744. (in Chinese)