

# 基于快速FCM算法的多目标分割CV模型

葛琦, 张建伟, 陈允杰, 吴玲玲, 王克松

(南京信息工程大学数理学院, 南京 210044)

**摘要:** Chan-Vese(CV)模型是基于水平集方法演化不依赖图像梯度的算法, 能很好地处理拓扑变化和弱边界, 但对于目标和背景对比度低的边界以及多目标区域分割效果较差。针对上述问题提出一种基于快速模糊 F 均值(FCM)算法和邻域模板改进的 CV 模型。利用快速 FCM 算法提取图像特征信息, 采用邻域模板阈值法对不同的目标区域分别处理, 准确控制了轮廓线的分裂, 能够分割出更多的目标区域。  
**关键词:** Chan-Vese 模型; 快速模糊 F 均值算法; 邻域模板; 多目标

## Chan-Vese Model Based on Fast FCM Algorithm in Multiple-objects Segmentation

GE Qi, ZHANG Jian-wei, CHEN Yun-jie, WU Ling-ling, WANG Ke-song

(College of Math & physics, Nanjing University of Information Science & Technology, Nanjing 210044)

**【Abstract】** Chan-Vese(CV) model is able to handle the blurry boundary and complex topological structures in images segmentation. The effect on extracting multiple-objects contours and contours in low contrast of the objects and background is not success. This paper proposes an improved CV model based on fast FCM algorithm and local template. It gets the image property by fast FCM algorithm, and makes use of local template to handle the different objects differently so as to control the split-up of the contour accurately and segment more objects.

**【Key words】** Chan-Vese(CV) model; fast FCM algorithm; local template; multiple-objects

### 1 概述

近年来, 基于变分方法和偏微分方程演化的图像分割方法得到了广泛应用。文献[1]提出的 snake 模型和文献[2]提出的水平集方法<sup>[2]</sup>能够隐含表示曲线, 具有自动处理角点、拐点和拓扑结构变化的优点。文献[3]提出的 Chan-Vese(CV)模型是一种不根据图像梯度而根据强度均匀的同质区域并依靠水平集演化的模型。但由于水平集函数的定义及 CV 模型对多目标区域不能完全分割, 因此文献[4]引入多相位水平集方法, 极大增加了计算复杂度, 分割出的区域数目随着水平集个数增加而增加。影响 CV 模型分割多目标区域的原因是在演化中不能根据轮廓线的即时拓扑变化信息进行具体处理。

本文针对 CV 模型对目标背景对比度较低的边界不能很好分割的问题, 利用快速模糊 F 均值(FCM)算法<sup>[5]</sup>得到图像的特征信息, 提高了分割精度, 并根据邻域模板阈值规则演化, 对不同目标分别处理, 控制轮廓线的分裂。该算法能准确地指导轮廓线的分裂, 准确分割出更多的目标区域。

### 2 快速FCM算法改进的CV模型

#### 2.1 CV模型

设定义域为  $\Omega$  的图像  $I(x)$  被闭合边界曲线  $C$  划分为目标和背景 2 个区域  $in(C)$  和  $out(C)$  分别在  $C$  的内外部分, 2 个区域的灰度均值为  $c_0$  和  $c_1$ 。CV 模型的能量如下:

$$E(C, c_0, c_1) = \mu L(C) + \lambda_1 \int_{in(C)} (I(x) - c_1)^2 dx + \lambda_2 \int_{out(C)} (I(x) - c_2)^2 dx \quad (1)$$

其中,  $L(C)$  为曲线  $C$  的弧长;  $\mu, \lambda_1, \lambda_2 > 0$  是权重系数;  $c_0$  和  $c_1$  分别是在区域  $in(C)$  和  $out(C)$  部分的平均图像强度。轮廓线  $C$  以水平集函数  $\phi$  表示, 以  $\phi$  为变量的 Heaviside 函数表示区域  $\Omega_c$  和  $\Omega \setminus \Omega_c$ , 能量泛函为

$$E_1(\phi, c_1, c_2, \lambda) = \mu \int_C ds + \lambda_1 \int_{\Omega_c} H_\epsilon(\phi) (I(x) - c_1)^2 dx + \lambda_2 \int_{\Omega \setminus \Omega_c} (1 - H_\epsilon(\phi)) (I(x) - c_2)^2 dx \quad (2)$$

CV 模型引入了水平集方法, 能较好地处理轮廓线拓扑变化。仅将初始零水平集内外区域像素灰度均值作为基准逼近, 没有准确考虑图像特征。文献[6]结合 FCM 算法和 CV 模型, 在轮廓线包围区域内外部分别聚类, 轮廓线根据聚类得到的特征信息演化, 既保持了 CV 模型处理几何拓扑变化的特点, 又考虑了图像的特征信息, 提高了模型的分割精度。

#### 2.2 基于快速FCM算法的CV模型

##### 2.2.1 FCMSL 模型

FCMSL 模型<sup>[6]</sup>分别在区域  $\Omega_c$  和  $\Omega \setminus \Omega_c$  中利用 FCM 算法得到目标和背景的特征信息, 这一过程相当于将 CV 模型能量泛函的适应能量项以聚类算法实现, 能量泛函为

$$E(U, V, C) = \int_{x \in \Omega_c} \left( \sum_{i=1}^m u_{ik}^h + \sum_{j=m+1}^{m+n} u_{jk}^h \right) d_{jk}^2 dx + \int_{x \in \Omega \setminus \Omega_c} \left( \sum_{i=m+1}^{m+n} u_{jk}^h + \sum_{j=1}^m u_{ik}^h \right) d_{jk}^2 dx + \lambda \int_{x \in \Omega} \left( \sum_{i=1}^m u_{ik}^h d_{ik}^2 + \sum_{j=m+1}^{m+n} u_{jk}^h d_{jk}^2 \right) dx + \mu \int_C ds \quad (3)$$

**基金项目:** 国家自然科学基金资助项目(60805003); 江苏省教育厅“青蓝工程”基金资助项目(20070047); 香港特区政府研究资助局基金资助项目(CUHK/4185/00E)

**作者简介:** 葛琦(1984—), 女, 硕士研究生, 主研方向: 图像处理, 模式识别; 张建伟, 教授、博士、博士生导师; 陈允杰, 讲师、博士; 吴玲玲、王克松, 硕士研究生

**收稿日期:** 2009-05-11 **E-mail:** geqi1984@163.com

其中,

- $u_{ik}, u_{jk}$  分别为区域  $\Omega_c, \Omega \setminus \Omega_c$  中聚类时的模糊隶属度;
- $m, n$  分别为 2 个区域中参与聚类的数据个数;
- $d_{ik}$  和  $d_{jk}$  分别为 2 个区域中数据点到聚类中心的距离;
- $h$  为模糊加权指数;
- $\lambda$  是控制参数。

由于演化中须对图像数据进行聚类计算再进行微分方程的迭代, 计算量太大, 因此采用快速 FCM 算法改进 CV 模型, 大大减少了计算时间。

### 2.2.2 基于快速 FCM 算法的改进 CV 模型

FCM 算法是一种通过对目标函数进行迭代优化, 进而对数据样本集进行模糊聚类的方法。数据样本集是图像的  $N$  个像素, 通过 FCM 算法把  $N$  个像素分成  $C$  个类, FCM 的目标函数定义为

$$J_m(U, V) = \sum_{k=1}^n \sum_{i=1}^c (u_{ik})^m d^2(x_k, v_i) \quad (4)$$

其中,

$\sum_{i=1}^c u_{ik} = 1, u_{ik} \in [0, 1]$ , 表示第  $k$  个像素划分为第  $C$  个类的程度;

$V = \{v_1, v_2, \dots, v_c\}$  表示样本的  $C$  个聚类中心;

$d^2(x_k, v_i) = \|x_k - v_i\|^2$  表示第  $k$  个样本到第  $i$  类中心的距离。计算隶属度矩阵:

$$u_{ik}^{(t)} = 1 / \sum_{j=1}^c (d_{ik}^{(t)} / d_{jk}^{(t)})^{2/(m-1)} \quad (5)$$

计算新的聚类中心:

$$v_i^{(k+1)} = (\sum_{k=1}^n (u_{ik}^{(k)})^m x_k) / (\sum_{k=1}^n (u_{ik}^{(k)})^m) \quad (6)$$

若初始聚类中心和最终迭代结果相近, 能减少算法的迭代次数, 且不易收敛到局部最优值。硬  $C$  类均值聚类算法比模糊聚类算法收敛快且最终得到的聚类中心很接近。因此, 先用聚类算法得到硬  $C$  类均值聚类中心作为 FCM 算法的初始聚类中心。

FCM 算法的每步迭代要对整个图中各像素点的灰度值集合  $X = \{x_1, x_2, \dots, x_n\}$  进行计算。由于不同像素点的灰度值可能相同, 而相同灰度值的像素点更有可能属于一类, 因此设  $X$  中有  $p$  种灰度值, 数据集合为  $X' = \{x'_1, x'_2, \dots, x'_p\}$ , 每种灰度值对应的像素个数为:  $W = \{w_1, w_2, \dots, w_p\}$ , 聚类中心更新为

$$v_i^{(k+1)} = (\sum_{k=1}^n w_k (u_{ik}^{(k)})^m x_k) / (\sum_{k=1}^n w_k (u_{ik}^{(k)})^m) \quad (7)$$

通过以上优化, 对于一幅  $256 \times 256$  像素、灰度级为  $0 \sim 255$  的图像, 收敛速度可提高  $(256 \times 256) / 255 \square 256$  倍。用快速 FCM 算法改进 CV 模型, 演化速度比 FCMSL 模型更快。

利用快速 FCM 算法对区域  $\Omega_c$  和  $\Omega \setminus \Omega_c$  进行聚类, 设 2 个区域的灰度值种类分别为  $p_1$  和  $p_2$  ( $p_1 + p_2 = p$ ), 更新聚类中心:

$$v_i = \frac{\int_{x \in \Omega} \left( (\lambda + H(\phi)) u_{ik}^h + H(\phi) \sum_{l=p_1+1}^p w_k u_{lk}^h \right) I(x) dx}{\int_{x \in \Omega} \left( (\lambda + H(\phi)) u_{ik}^h + H(\phi) \sum_{l=p_1+1}^p w_k u_{lk}^h \right) dx} \quad (8)$$

$$v_j = \frac{\int_{x \in \Omega} \left( (\lambda + 1 - H(\phi)) u_{jk}^h + (1 - H(\phi)) \sum_{l=1}^{p_1} w_k u_{lk}^h \right) I(x) dx}{\int_{x \in \Omega} \left( (\lambda + 1 - H(\phi)) u_{jk}^h + (1 - H(\phi)) \sum_{l=1}^{p_1} w_k u_{lk}^h \right) dx}$$

隶属度更新:

$$u_{ik} = \left( \frac{(\lambda + H(\phi)) d_{ik}^2 + (1 - H(\phi)) \sum_{l=p_1+1}^p d_{lk}^2}{(\lambda + H(\phi)) d_{pk}^2 + (1 - H(\phi)) \sum_{l=p_1+1}^p d_{lk}^2} \right)^{\frac{1}{h-1}} + \sum_{q=p_2+1}^p \left( \frac{(\lambda + H(\phi)) d_{ik}^2 + (1 - H(\phi)) \sum_{l=p_1+1}^p d_{lk}^2}{(\lambda + 1 - H(\phi)) d_{pk}^2 + H(\phi) \sum_{l=p_1+1}^p d_{lk}^2} \right)^{\frac{1}{h-1}} \quad (9)$$

$$u_{jk} = \left( \frac{(\lambda + 1 - H(\phi)) d_{jk}^2 + H(\phi) \sum_{l=1}^{p_1} d_{lk}^2}{(\lambda + H(\phi)) d_{ik}^2 + (1 - H(\phi)) \sum_{l=p_1+1}^p d_{lk}^2} \right)^{\frac{1}{h-1}} + \sum_{q=p_2+1}^p \left( \frac{(\lambda + 1 - H(\phi)) d_{jk}^2 + H(\phi) \sum_{l=1}^{p_1} d_{lk}^2}{(\lambda + H(\phi)) d_{ik}^2 + H(\phi) \sum_{l=1}^{p_1} d_{lk}^2} \right)^{\frac{1}{h-1}}$$

演化方程为

$$\phi_{t+1} = \phi_t + \Delta t \square \delta_\epsilon(\phi) \left[ \sum_{i=1}^{p_1} ((\lambda + 1) w_k u_{ik}^h + \sum_{j=1}^p w_k u_{jk}^h) d_{ik}^2 - \sum_{j=p_2+1}^p ((\lambda + 1) w_k u_{jk}^h + \sum_{i=1}^{p_1} w_k u_{ik}^h) d_{jk}^2 + \nabla \left( \frac{\nabla \phi}{|\nabla \phi|} \right) \right] \quad (10)$$

虽然结合了聚类算法的 CV 模型提高了分割精度, 但对于多目标区域的分割仍不完善。CV 模型利用水平集方法实现轮廓线的演化, 演化中轮廓线分裂形成若干个准目标区域, 通过继续分裂和迭代最终提取多个目标边界。但不同准目标区域的图像特征可能不同, 所以, 将所有准目标区域的图像特征统一处理并不能正确分割图像。本文采用邻域模板阈值法指导轮廓线正确演化。

### 3 基于快速聚类算法的多目标图像分割

为保证轮廓线分裂正确, 引入一个存储像素邻域的灰度均值矩阵  $Mod(x)$ 。设邻域半径  $r=3$ ,  $Mod(x)$  是存储以  $x$  为中心、 $r$  为邻域的灰度均值矩阵。设上一步得到的目标和背景区域内初始聚类中心的灰度均值分别为  $\bar{v}_i, \bar{v}_j$ 。给定阈值  $T$ , 轮廓线根据以下规则演化:

- (1) 当  $\phi(x) < 0$ , 若  $\bar{v}_i > \bar{v}_j > Mod(x) + T$  或  $\bar{v}_i < \bar{v}_j < Mod(x) - T$ , 则:

$$\phi_{t+1} = \phi_t + \Delta t \square \delta_\epsilon(\phi) \left[ \lambda_1 (I(x) - Mod(x))^2 - \sum_{j=p_2+1}^p \left( (\lambda + 1) w_k u_{jk}^h + \sum_{i=1}^{p_1} w_k u_{ik}^h \right) d_{jk}^2 + \nabla \left( \frac{\nabla \phi}{|\nabla \phi|} \right) \right] \quad (11)$$

- (2) 当  $\phi(x) > 0$ , 若  $\bar{v}_j > \bar{v}_i > Mod(x) + T$  或  $\bar{v}_j < \bar{v}_i < Mod(x) - T$

$$\phi_{t+1} = \phi_t + \Delta t \square \delta_\epsilon(\phi) \left[ \sum_{i=1}^{p_1} \left( (\lambda + 1) w_k u_{ik}^h + \sum_{j=1}^p w_k u_{jk}^h \right) d_{ik}^2 - \lambda_2 (I(x) - Mod(x))^2 + \nabla \left( \frac{\nabla \phi}{|\nabla \phi|} \right) \right] \quad (12)$$

利用以上演化规则, 可对轮廓线在不同的目标区域区别处理, 从而准确控制轮廓线的分裂。在充分利用图像局部特征基础上, 能对多个目标区域进行准确分割。

算法步骤如下:

**步骤 1** 初始化轮廓线, 生成符号距离函数  $\phi_0(x)$ , 轮廓线外部标记为  $\phi_0(x) = -1$ , 轮廓线内部标记为  $\phi_0(x) = 1$ , 轮廓线上为  $\phi_0(x) = 0$ 。生成矩阵  $Mod(x)$ , 给定阈值  $T$ 。

**步骤2** 使用硬聚类算法得到初始的聚类中心。目标部分为： $v_i^0, 1 \cdots p_1$ ；背景部分为： $v_j^0, j = p_2 \cdots p$ ，从而得到2个部分的初始聚类中心灰度均值  $\bar{v}_i^0, \bar{v}_j^0$ ，以及对应的隶属度  $u_i^0, u_j^0$ 。


**步骤3** 利用演化控制条件判断式(11)或式(12)演化。

**步骤4** 根据式(9)更新聚类中心  $v_i$  和  $v_j$ ，若符合收敛条件，则停止演化，若不符合收敛条件，则利用式(9)计算新的隶属度函数  $u_i$  和  $u_j$ ，转步骤3。


#### 4 实验结果及分析

本文实验在 Dell Core 2.0 GHz 和 1 GB RAM 的计算机上完成。


图1是含多个目标和复杂拓扑结构的大脑MR图像，大小为435×346。从图中可看出，传统的CV模型对于目标和背景对比度较低的边界不能分割，由于不能正确分裂轮廓线，因此多个目标区域不能完全分割。结合FCM算法的CV模型能准确分割出主要目标边界，提高了传统CV模型分割精度，但计算量较大，耗时31.86 s，且小部分和背景区域灰度相近的目标区域没能分割出。本文算法比FCMSL算法分割出更多的目标区域，对于狭小细长的边界能有效分割，分割精度进一步提高。并且计算时间大大减少，只耗时1.42 s，比FCMSL算法效率提高了约22倍。




(a)初始曲线



(b)CV 模型分割结果



(c)FCMSL 模型分割结果




(d)本文算法结果

图1 大脑 MR 图像

图2是含几何目标的组合图像，图2(b)为CV模型迭代400次的分割结果，图2(c)是本文算法迭代25次的结果。可


以看出，CV模型不能分割出与背景灰度接近的目标，本文算法能分割出CV模型不能分割的目标区域，而且迭代次数大大减少，这是因为改进的方法以图像特征为依据，正确控制了轮廓线的分裂，避免了演化时重复迭代计算。



(a)初始曲线



(b)CV 模型迭代 400 次



(c)本文算法迭代 25 次

图2 组合图像

#### 5 结束语

针对 CV 模型分割精度不高以及缺乏对多目标提取的能力，本文提出一种基于快速 FCM 算法和邻域模板演化规则改进的 CV 模型。该模型利用快速 FCM 算法得到图像特征信息，能很好地分割出目标和背景对比度低的边界，采用均值模板控制轮廓线的分裂，能准确提取更多目标区域。由于采用了快速 FCM 方法，因此本文算法的计算效率比 FCMSL 算法提高了很多，并且保持了较高的分割精度。针对 FCM 算法抗噪性较差的问题，今后将做进一步改进，使之能较好地处理含较高噪声的图像。

#### 参考文献

- [1] Kass M, Witkin A, Terzopoulos D. Snakes: Active Contour Models[J]. International Journal of Computer Vision, 1998, 1(4): 321-331.
- [2] Osher S, Sethian J A. Fronts Propagating with Curvature-dependent Speed: Algorithms Based on Hamilton-Jacobi Formulation[J]. Journal of Comput. Phys., 1988, 79(1): 12-49.
- [3] Chan T, Vese L. Active Contours Without Edges[J]. IEEE Trans. on Image Processing, 2001, 10(2): 266-277.
- [4] Vese L, Chan T F. A Multiphase Level Set Framework for Image Segmentation Using the Mumford and Shah Model[J]. International Journal of Computer Vision, 2002, 5(3): 271-293.
- [5] 吴林, 郭大勇. 改进的 FCM 在人脑 MR 图像分割中的应用[J]. 清华大学学报: 自然科学版, 2004, 44(2): 157-159.
- [6] Zhen Ping. A New Level Set Method for Image Segmentation Integrated with FCM[C]//Proc. of the 4th International Conference on Fuzzy Systems and Knowledge Discovery. Hainan, China: [s. n.], 2007: 699-703.

编辑 张正兴