

基于图像层的双水平集图像分割

陈 静 朱家明 吴 杰

(扬州大学信息工程学院 扬州 225127)

摘 要 传统 C-V 模型可以将待分割图像分割成目标和背景两区域,但无法实现对多目标图像的分割。多相 C-V 模型能够对多目标图像进行分割,但需要多次迭代,计算量较大。为了解决上述问题,提出一种基于图像层的双水平集分割算法,该算法通过引入背景填充技术来改变图像背景,从而形成新的图像层,双水平集不断地在新的图像层中进行分割,直到所有目标被分割。这样通过双水平集就可以实现对多目标图像的分割。实验结果表明:该算法能够实现多目标分割,且迭代次数较少,同时具有较强的抗干扰能力和较快的收敛速度。

关键词 图像分割,图像层,水平集

中图法分类号 TP391 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2015.6.065

Double Level Set Image Segmentation Based on Image Layer

CHEN Jing ZHU Jia-ming WU Jie

(School of Information Engineering, Yangzhou University, Yangzhou 225127, China)

Abstract Traditional C-V model can divide the image into object and background, but can not be achieved on the multi-objective image segmentation. Multiphase C-V model for image segmentation requires more iterations and more computing time. In order to solve these problems, this paper proposed a double level set image segmentation algorithm based on image layer. The algorithm introduces the background filling technology to change the image background, forming a new image layer, and the double level set continues division in the new image layer, until all objects are segmented. Through the new image layer, the double level set can achieve the multi-objective image segmentation. The experimental results show that the algorithm can realize multi-objective segmentation with less iteration, also has strong anti-interference ability and faster convergence speed.

Keywords Image segmentation, Image layer, Level set

图像分割是计算机视觉和模式识别领域非常重要的组成部分,也是计算机图像理解方法实现的基础。近年来,随着曲线演化理论不断完善,水平集方法也越来越受到研究者的重视和青睐。1988年, Osher 和 Sethian^[1]最早提出水平集方法来解决曲线演化问题。随后 Caselles^[2]和 Malladi^[3]等人率先将水平集方法运用到图像分割领域,创立了几何活动轮廓模型(GACM)。Zhao^[4]等人在 1996 年通过添加约束条件实现了用 n 个水平集表示 n 个不同区域,开创了多水平集对多目标图像的分割。Chan 和 Vese^[5]对 Zhao 等人提出的方法进行了改进,提出了多相 C-V 模型,用 n 个水平集表示 2^n 个区域,分割的目标数量明显增加且无须初始约束条件。多相 C-V 模型的优点显著但缺点同样明显,多水平集同时演化,使得迭代计算量较大,分割所需时间较长,同时双曲线还易对同一目标出现混分的现象。Brox^[6]等人在此基础上提出了基于区域竞争模型的随机分割区域数耦合曲线演化方法,该方法通过改变能量项实现了对分割区域数量的限制,避免混分现象的发生。Wang^[7]等人在 C-V 模型图像层概念的基础上提出了多相图像分割的多层水平集框架,实现了对图像多目标多

层次分割。本文提出基于图像层的双水平集图像分割,通过引入图像层概念,运用双水平集分割,将分割出来的目标区域用背景灰度均值进行填充,形成新的图像层,再重新初始化双水平集对新的图像层进行分割,实现了图像多层次分割。通过加入单图像层演化终止条件、背景层演化终止条件来减少在单个图像层上不必要的迭代次数,实现对目标区域快速准确的分割。

1 多相 C-V 模型

1.1 C-V 模型

1988 年, Chan 和 Vese 提出了 C-V 模型。C-V 模型是一种基于全局信息的活动模型,能够检测到具有光滑边缘的目标,且对曲线初始位置、噪声都不敏感,其能量泛函为:

$$E_{CV}(u, C) = \mu \int_{\Omega} |\nabla H(\phi)| dx dy + v \int_{\Omega} H(\phi) dx dy + \lambda_1 \int_{\Omega} |u_0 - c_1|^2 H(\phi) dx dy + \lambda_2 \int_{\Omega} |u_0 - c_2|^2 (1 - H(\phi)) dx dy \quad (1)$$

到稿日期:2014-05-08 返修日期:2014-07-21 本文受国家自然科学基金资助项目(61174046, 61175111, 60904030, 60874030, 60835001, 60874045), 中国江苏省高校自然科学基金(09KJB51001910, KJB510027), 江苏省博士后科研资助计划项目(1102167C)资助。

陈 静(1989-),男,硕士,主要研究方向为图像处理, E-mail: chenjing891225@foxmail.com; 朱家明(1972-),男,博士,副教授,主要研究方向为图像处理、智能控制, E-mail: qingzhu@yzu.edu.cn.

其中, $\mu, \nu, \lambda_1, \lambda_2$ 为正常数, Ω 为图像域, ϕ 为水平集函数, δ 为 Dirac 函数, H 为 Heaviside 函数, c_1 和 c_2 分别为目标和背景区域的灰度均值, 其表达式为:

$$c_1 = \frac{\int_{\Omega} u(x, y) H(\phi) dx dy}{\int_{\Omega} H(\phi) dx dy} \quad (2)$$

$$c_2 = \frac{\int_{\Omega} u(x, y) (1 - H(\phi)) dx dy}{\int_{\Omega} (1 - H(\phi)) dx dy}$$

水平集函数 ϕ 的曲线演化方程为:

$$\frac{\partial \phi}{\partial t} = \delta_{\epsilon}(\phi) [\mu \cdot \text{div}(\frac{\nabla \phi}{|\nabla \phi|}) - \lambda_1 |u - c_1|^2 + \lambda_2 |u - c_2|^2] \quad (3)$$

1.2 四相 C-V 模型

传统 C-V 模型对单目标图像的分割效果较好, 但对多目标图像分割效果不佳。为了解决此问题, Chan 和 Vese 等人提出了多相 C-V 模型, 该模型的原理是用 n 个水平集将待分割图像划分为 2^n 个互不重叠的区域, 这样图像中每个像素点只能对应其中一个区域, 有效地避免了区域划分时出现重叠或者真空的问题。

图 1 是一幅四相 C-V 模型原理图, 两个水平集 ϕ_1 和 ϕ_2 将图像域划分成 4 个互不重叠的区域:

$$\begin{aligned} \Omega_{11} &= \{\phi_1 > 0, \phi_2 > 0\} \\ \Omega_{12} &= \{\phi_1 > 0, \phi_2 < 0\} \\ \Omega_{21} &= \{\phi_1 < 0, \phi_2 > 0\} \\ \Omega_{22} &= \{\phi_1 < 0, \phi_2 < 0\} \end{aligned} \quad (4)$$




图 1

四相 C-V 模型的能量泛函:

$$\begin{aligned} E_{CV}^4(c, \phi) &= \mu \int_{\Omega} \delta_{\epsilon}(\phi_1) |\nabla H_{\epsilon}(\phi_1)| dx dy + \mu \int_{\Omega} \delta_{\epsilon}(\phi_2) \\ &|\nabla H_{\epsilon}(\phi_2)| dx dy + \int_{\Omega} |u_0 - c_{11}|^2 H_{\epsilon}(\phi_1) dx dy + \\ &\int_{\Omega} |u_0 - c_{12}|^2 H_{\epsilon}(\phi_1) (1 - H_{\epsilon}(\phi_2)) dx dy + \\ &\int_{\Omega} |u_0 - c_{21}|^2 (1 - H_{\epsilon}(\phi_1)) H_{\epsilon}(\phi_2) dx dy + \int_{\Omega} \\ &|u_0 - c_{22}|^2 (1 - H_{\epsilon}(\phi_1)) (1 - H_{\epsilon}(\phi_2)) dx dy \end{aligned} \quad (5)$$

其中, $c_{11}, c_{12}, c_{21}, c_{22}$ 分别是 $\Omega_{11}, \Omega_{12}, \Omega_{21}, \Omega_{22}$ 区域的灰度均值。

为了解决曲线在演化过程中需要重新初始化的问题, 本文在曲线能量泛函中加入 Li 等人提出的能量惩罚项。该能量惩罚项表达式为:

$$P(\phi) = \frac{1}{2} \int_{\Omega} (|\nabla \phi_1| - 1)^2 dx dy + \frac{1}{2} \int_{\Omega} (|\nabla \phi_2| - 1)^2 dx dy \quad (6)$$

因此定义新的能量泛函为:

$$\begin{aligned} E_{CV}^4(c, \phi) &= \mu \int_{\Omega} \delta_{\epsilon}(\phi_1) |\nabla H_{\epsilon}(\phi_1)| dx dy + \mu \int_{\Omega} \delta_{\epsilon}(\phi_2) \\ &|\nabla H_{\epsilon}(\phi_2)| dx dy + \int_{\Omega} |u_0 - c_{11}|^2 H_{\epsilon}(\phi_1) dx dy + \\ &\int_{\Omega} |u_0 - c_{12}|^2 H_{\epsilon}(\phi_1) (1 - H_{\epsilon}(\phi_2)) dx dy + \\ &\int_{\Omega} |u_0 - c_{21}|^2 (1 - H_{\epsilon}(\phi_1)) H_{\epsilon}(\phi_2) dx dy + \int_{\Omega} \\ &|u_0 - c_{22}|^2 (1 - H_{\epsilon}(\phi_1)) (1 - H_{\epsilon}(\phi_2)) dx dy + \\ &\frac{1}{2} \int_{\Omega} (|\nabla \phi_1| - 1)^2 dx dy + \frac{1}{2} \int_{\Omega} (|\nabla \phi_2| - \\ &1)^2 dx dy \end{aligned} \quad (7)$$

水平集函数 ϕ_1 和 ϕ_2 的演化方程分别为:

$$\begin{aligned} \frac{\partial \phi_1}{\partial t} &= \delta_{\epsilon}(\phi_1) [\mu \cdot \text{div}(\frac{\nabla \phi_1}{|\nabla \phi_1|}) - ((u_0 - c_{11})^2 - (u_0 - \\ &c_{21})^2) H_{\epsilon}(\phi_2) - ((u_0 - c_{12})^2 - (u_0 - c_{22})^2) (1 - \\ &H_{\epsilon}(\phi_2))] + (\Delta \phi_1 - \text{div}(\frac{\nabla \phi_1}{|\nabla \phi_1|})) \end{aligned} \quad (8)$$

$$\begin{aligned} \frac{\partial \phi_2}{\partial t} &= \delta_{\epsilon}(\phi_2) [\mu \cdot \text{div}(\frac{\nabla \phi_2}{|\nabla \phi_2|}) - ((u_0 - c_{11})^2 - (u_0 - \\ &c_{12})^2) H_{\epsilon}(\phi_1) - ((u_0 - c_{21})^2 - (u_0 - c_{22})^2) (1 - \\ &H_{\epsilon}(\phi_1))] + (\Delta \phi_2 - \text{div}(\frac{\nabla \phi_2}{|\nabla \phi_2|})) \end{aligned} \quad (9)$$

在每次的迭代过程中, 4 个相位的灰度均值 $c_{11}, c_{12}, c_{21}, c_{22}$ 会按下式不断地更新:

$$\begin{aligned} c_{11} &= \frac{\int_{\Omega} u_0(x, y) H_{\epsilon}(\phi_1) H_{\epsilon}(\phi_2) dx dy}{\int_{\Omega} H_{\epsilon}(\phi_1) H_{\epsilon}(\phi_2) dx dy} \\ c_{12} &= \frac{\int_{\Omega} u_0(x, y) H_{\epsilon}(\phi_1) (1 - H_{\epsilon}(\phi_2)) dx dy}{\int_{\Omega} H_{\epsilon}(\phi_1) (1 - H_{\epsilon}(\phi_2)) dx dy} \\ c_{21} &= \frac{\int_{\Omega} u_0(x, y) (1 - H_{\epsilon}(\phi_1)) H_{\epsilon}(\phi_2) dx dy}{\int_{\Omega} (1 - H_{\epsilon}(\phi_1)) H_{\epsilon}(\phi_2) dx dy} \\ c_{22} &= \frac{\int_{\Omega} u_0(x, y) (1 - H_{\epsilon}(\phi_1)) (1 - H_{\epsilon}(\phi_2)) dx dy}{\int_{\Omega} (1 - H_{\epsilon}(\phi_1)) (1 - H_{\epsilon}(\phi_2)) dx dy} \end{aligned} \quad (10)$$

2 图像层

多相 C-V 模型能够同时对多个目标进行分割, 有效地解决了区域重叠和真空问题。但引入多个水平集会导致计算量较大, 演化时间增长。本文引入图像层的方法, 能够有效地减少水平集在单个图像层上的迭代计算量, 整个演化过程不需要人为监督和干涉, 能够自动完成。

2.1 图像层填充

假设待分割图像由 $2N+1$ 个区域组成, 其中有 N 对同类目标区域, 1 个背景区域, 定义原始图像为图像层 L_0 , 则 L_0 的表达式为:

$$L_0 = (\bigcup_{i=1}^N \Omega_i) \cup \Omega_B \quad (11)$$

其中, Ω_i 表示的是第 i 类目标区域, Ω_B 表示背景区域。

如图 2 所示, 运用双水平集方法将两个同质目标区域 Ω_1^1 和 Ω_1^2 从图像层 L_0 中分割出来, 并且用 $(\bigcup_{i=2}^N \Omega_i) \cup \Omega_B$ 区域的灰度均值对 Ω_1^1 和 Ω_1^2 两区域进行灰度填充, 得到新的背景区域 $(\Omega_1^1 \cup \Omega_1^2) \cup \Omega_B$, 则新的图层 L_1 的表达式为:

$$L_1 = (\bigcup_{i=2}^N \Omega_i) \cup (\Omega_1^1 \cup \Omega_1^2 \cup \Omega_B) \quad (12)$$




图2

假设待分割图像中目标区域数 $2N \geq 4$, 同样运用上述方法, 在图像层 L_1 中将目标区域 Ω_1^0 和 Ω_2^0 分割出来, 并用 $(\bigcup_{i=3}^N \Omega_i) \cup (\Omega_1^1 \cup \Omega_2^1 \cup \Omega_B)$ 区域灰度均值对 Ω_1^0, Ω_2^0 两区域进行灰度填充, 新的背景区域为 $(\Omega_1^1 \cup \Omega_2^1 \cup \Omega_3^1 \cup \Omega_4^1 \cup \Omega_B)$, 则新的图层 L_2 的表达式为:

$$L_2 = (\bigcup_{i=3}^N \Omega_i) \cup (\Omega_1^1 \cup \Omega_2^1 \cup \Omega_3^1 \cup \Omega_4^1 \cup \Omega_B) \quad (13)$$

将上述方法一直执行下去, 直到图像中所有目标区域全部转化成背景区域。目标区域数为偶数时, 图像层表达式归纳如下:

$$L_N = (\bigcup_{i=N}^N \Omega_i) \cup (\Omega_1^{N-1} \cup \Omega_2^{N-1} \cup \Omega_3^{N-1} \cup \Omega_4^{N-1} \cup \dots \cup \Omega_N^{N-1} \cup \Omega_B) \quad (14)$$

当目标区域数为奇数时, 图像层表达式为:

$$L_N = (\bigcup_{i=N}^N \Omega_i) \cup (\Omega_1^{N-1} \cup \Omega_2^{N-1} \cup \Omega_3^{N-1} \cup \Omega_4^{N-1} \cup \dots \cup \Omega_N^{N-1} \cup \Omega_B) \quad (15)$$

通过双水平集曲线不断地进行演化, 可以得到图像层的一个分割序列:

$$L_0 \rightarrow L_1 \rightarrow L_2 \rightarrow \dots \rightarrow L_{n-1} \rightarrow L_n (\text{背景图层}) \quad (16)$$

2.2 迭代次数阈值 u 和网格间隔阈值 h 的修正

随着水平集在不同的图像层中演化, 图像层中的目标区域和背景区域的灰度差异会不断缩小, 这样就会导致水平集迭代次数增加, 演化速度减慢。如果还保持原先设定的迭代次数, 就可能导致在某个图像层中出现目标区域不完全分割的现象, 并且这种误差会随着图像层的增加而逐渐变大。因此, 需要不断地对迭代次数进行修正。本文提出自适应迭代次数函数:

$$U_n = U_0 + \Delta u (\Delta C_0 - \Delta C_n) \quad (17)$$

其中, U_0 表示在图层 L_0 中的迭代次数, Δu 表示迭代增量, ΔC_n 表示在图层 L_n 中的最大灰度差值。

水平集曲线是在笛卡尔网格上离散化的, 每个网格点表示一个像素点, 随着曲线演化的进行, 图像层中目标区域的数量会逐渐减少, 因此需要增大网格间隔来快速获取新的目标区域位置, 提高水平集演化速度。本文提出自适应网格间隔函数:

$$h_n = h_0 + \Delta h (\Delta C_0 - \Delta C_n) \quad (18)$$

其中, h_0 表示在图层 L_0 中的网格间隔, Δh 表示网格增量, ΔC_n 表示在图层 L_n 中的最大灰度差值。

2.3 单图像层演化终止条件

由于本文引入图像层概念, 将待分割图像分为多个层次进行分割, 双水平集演化曲线需要在每个图像层上通过迭代计算来进行演化, 计算量较大, 因此为了减少各个图像层不必要的迭代计算, 提高演化效率, 需要定义单层图像层的演化终止条件。

一条演化曲线的能量泛函的表达式为:

$$E^{NL}(c_1, c_2, C) = \mu \text{Length}(C) + \int_{\text{inside}(C)} |L_l(x, y) - c_1|^2 dx dy + \int_{\text{outside}(C)} |L_l(x, y) - c_2|^2 dx dy \quad (19)$$

其中, $L_l(x, y)$ 表示的是图像层 L_l 的灰度值, c_1 和 c_2 分别表示图像层 L_l 中目标区域和背景区域的灰度均值, $\text{Length}(C)$ 表示曲线弧长。

随着演化曲线接近目标区域的边缘, 式(19)中后两项曲线演化数据项会不断地减少, 当演化曲线到达目标边缘时, 数据项就趋近于零, 从而实现了能量泛函的最小化。此时曲线能量泛函为:

$$\inf(E^{NL}(c_1, c_2, C)) = \mu \text{Length}(C) \quad (20)$$

由此可以得出当演化曲线到达目标边缘时, 尽管迭代次数增加, 曲线的弧长并不会随着时间发生大的变化, 因此定义单图像层曲线演化终止条件为:

$$|\text{Length}(C(t+1)) - \text{Length}(C(t))| \leq \theta_{len} \quad (21)$$

其中, θ_{len} 是人为设置的曲线停止值。

2.4 背景层的检测

如果分割区域数目已知, 通过计算图像层的序列数, 就可以很容易判断曲线是否到达背景层。但在实际应用中, 由于目标区域的数量具有不确定性, 如何快速准确地判断当前层是否为背景层, 一直是一个难点。

本文从曲线演化能量和灰度均值的角度出发, 来定义背景层的条件。当曲线在背景层中演化时, 由于没有目标存在, 演化曲线的数据项依旧接近于零, 同时演化曲线内外的灰度均值与背景的灰度值相等。根据以上特点, 定义背景层条件如下:

$$\begin{cases} \inf(E^{NL}(c_1, c_2, C)) = \mu \text{Length}(C) \\ c_1 = c_2 = (\Omega_1^1 \cup \Omega_2^1 \cup \Omega_3^1 \cup \Omega_4^1 \cup \dots \cup \Omega_N^1 \cup \Omega_B) \end{cases} \quad (22)$$

其中, c_1, c_2 是曲线内外的灰度均值, $(\Omega_1^1 \cup \Omega_2^1 \cup \Omega_3^1 \cup \Omega_4^1 \cup \dots \cup \Omega_N^1 \cup \Omega_B)$ 为背景层灰度均值。

2.5 对无目标的曲线的终止条件

本文一开始定义目标区域数量是偶数, 因此在整个图层的演化过程中, 双水平集曲线都是演化的。但在实际应用中, 目标区域数量可能出现奇数的情况, 若如此, 在背景层之前的图像层就只有一个目标, 只需要单曲线演化就足够了, 双曲线演化就会增加计算量, 影响演化速度。因此, 需要定义一个曲线优先演化最小能量项, 来选择其中一条覆盖目标区域较多的曲线进行演化; 当曲线演化能量项大于这个最小能量项时, 曲线进行演化; 如果小于这个最小能量项, 曲线将不进行演化, 即

$$E^{NL}(c_1, c_2, C) = \int_{\text{inside}(C)} |L_l(x, y) - c_1|^2 dx dy + \int_{\text{outside}(C)} |L_l(x, y) - c_2|^2 dx dy \leq \theta_{eng} \quad (23)$$

其中, θ_{eng} 是曲线演化最小能量项。

3 算法步骤

1. 初始化各项参数: 时间步长 Δt , 网格间隔 h_0 , Heavide 函数正则化参数 ϵ , 长度项控制参数 μ , 单图像层曲线演化终止阈值 θ_{len} , 无目标时曲线演化终止阈值 θ_{eng} 。

2. 输入原始图像(原始图像层 L_0 , 设置图像层标号 $l=0$), 设置初始迭代次数 U_0 。

3. 根据式(22)判断演化曲线是否到达背景层, 如果到达背景层, 演化结束, 输出分割结果; 否则, 转下一步。

4. 初始化水平集函数 ϕ_1 和 ϕ_2 , 计算各个区域的灰度均值 $c_{11}, c_{12}, c_{21}, c_{22}$ 。

5. 根据本文提出的水平集演化方程式(8)和式(9)进行双

曲线演化。

6. 根据式(23)判断曲线在当前图像层是否停止演化,如果有一条曲线满足终止条件,转下一步;否则双曲线继续演化。

7. 根据式(19)判断该曲线是否演化结束,如果满足,转下一步。

8. 使用背景填充技术,对分割的目标区域进行填充,形成新的图像层。

9. 图像层标号 $l=l+1$,调整曲线演化参数 U_n, h_n ,返回第3步。

4 实验结果与分析

为了验证算法的正确性,本文的模型参数选取为: $\Delta t=0.1, h_0=1, \Delta h=0.5, U_0=10, \Delta u=2$,长度项控制参数 $\mu=0.01 \cdot 255^2$,权重系数 $\lambda_1=\lambda_2=\lambda_3=\lambda_4=1$,Heavide 函数正则化参数 $\epsilon=1$ 。单图像层曲线演化终止阈值 θ_{L_m} 、背景层曲线演化终止阈值 θ_{mg} 根据图像的特征进行参数的选取。

实验1 运用本文模型对噪声图像进行分割

图3(a)是一幅含有噪声的图像,分别运用本文模型方法、C-V模型方法以及双C-V模型方法进行分割比较。单图像层曲线演化终止阈值 $\theta_{L_m}=0.03$,背景层演化终止阈值 $\theta_{mg}=0.2$ 。图3(a)是原始图像同时也是原始图像层 L_0 。图3(b)为本文模型在原始图像层 L_0 的初始轮廓。图3(c)为本文模型分割结果图,由于该图像只包含一个同质区域,因此只有第一条曲线在图像层 L_0 上进行演化,第二条演化曲线的能量项小于之前定义的最小能量项 θ_{mg} ,所以不进行演化。图3(d)为用背景区域的灰度均值替代目标区域的灰度均值所形成的新的图像层 L_1 。判断当前图像层 L_1 为背景层,演化结束。图3(e)和图3(f)分别是C-V模型和双C-V模型的分割结果图,分割的效果都受到了噪声的影响,分割失败。比较3种模型的分割效果,可以看出本文模型的抗干扰能力更好,对噪声具有一定的鲁棒性。

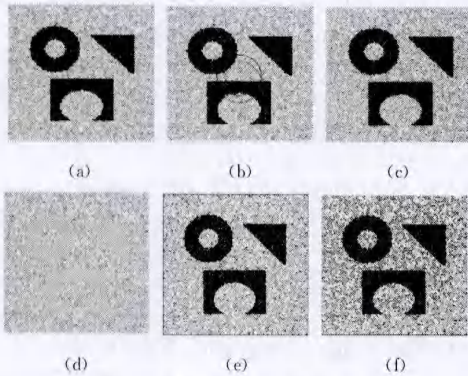


图3 本文模型对两区域噪声图像分割

实验2 运用本文模型对多区域合成图像进行分割

图4(a)是一幅三目标区域人工合成图像,分别运用本文模型方法、C-V模型方法以及双C-V模型方法进行分割比较。单图像层曲线演化终止阈值 $\theta_{L_m}=0.05$,背景层演化终止阈值 $\theta_{mg}=0.2$ 。图4(a)是原始图像同时也是原始图像层 L_0 。图4(b)为本文模型在原始图像层 L_0 的初始轮廓。图4(c)为两条演化曲线在原始图像层 L_0 上的分割结果图,两目标区域被分割出来。图4(d)是用背景区域的灰度均值来填充分割出来的目标区域所形成的新的图像层 L_1 。判断当前图像层 L_1 不为背景层,演化继续,在新的图像层 L_1 形成初始

轮廓。图4(e)为本文模型在图像层 L_1 分割结果图,由于图像只包含一个目标区域,因此通过判断 θ_{mg} ,其中一条曲线在图像层 L_0 上进行演化,另一条演化曲线不进行演化。图4(f)为新的图像层 L_2 ,判断当前图像层 L_2 为背景层,演化结束。图4(g)为C-V模型分割结果图,虽然分割效果较好,但所需迭代次数较多,时间较长。图4(h)为双C-V模型的分割结果图,分割过程中出现了混分的现象。

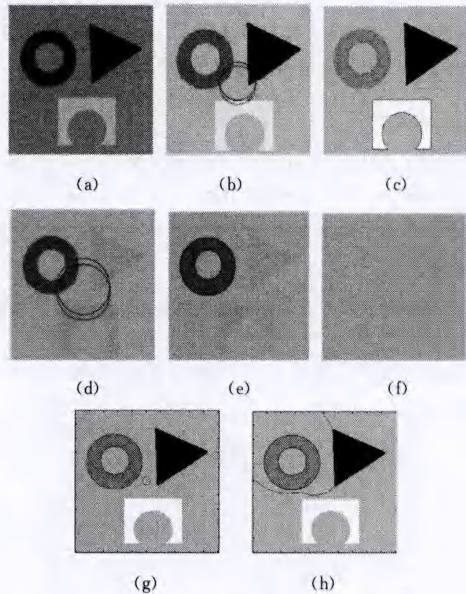


图4 本文模型对四区域合成图像分割

对图4采用本文模型、C-V模型以及双C-V模型在原始图像层 L_0 的分割比较如表1所列。

表1 对图4采用本文模型、C-V模型以及双C-V模型在原始图像层 L_0 的分割比较

	C-V模型	双C-V模型	本文模型
迭代次数	250	200	100
运行时间/s	24.37	21.48	13.83
结果	成功	失败	成功

结束语 本文提出的基于图像层的双水平集分割算法优势明显,引入图像层概念可以有效地解决曲线演化时对图像中多目标区域分割的问题,同时单图像层演化终止条件和无目标时曲线演化终止条件可以有效地减少曲线在各个图像层上不必要的迭代次数,实现了较低的迭代计算量和较快的收敛速度,分割结果相比较于C-V模型和双C-V模型更加精确。本文模型整个分割过程不需要人工监督和干预,可以自动完成。

参考文献

- [1] Osher S, Sethian J A. Fronts propagation with curvature dependent speed; Algorithms based on the Hamilton-jacobi formulation[J]. Journal of computational physics, 1988, 79: 12-49
- [2] Caselles V, Catta F, Coll T, et al. A geometric model for active contours[J]. Numerische Mathematik, 1993, 66(1): 1-31
- [3] Malladi R, et al. Shape modeling with front propagation; A level set approach[J]. IEEE trans on PAMI, 1995, 17(2): 158-175
- [4] Zhao H K, Chan T, Merriman B, et al. A variational level set approach to multiphase motion[J]. Journal of computational physics, 1996, 127: 179-195
- [5] 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

[6] Brox T, Weickert J. Level set segmentation with multiple regions[J]. IEEE trans on image processing, 2006, 17: 3213-3218

[7] 王大凯, 侯榆青, 彭进业. 图像处理的偏微分方程方法[M]. 北京: 科学出版社, 2008
Wang Da-kai, Hou Yu-qing, Peng Jin-ye. The partial differential equation in image processing[M]. Beijing: Science Press, 2008

[8] Bertelli L, Sumengen B, Manjunath B, et al. A variational framework for multi-region pairwise similarity-based image segmentation[J]. IEEE trans on pattern analysis and machine intelligence, 2008, 30: 1400-1414

[9] Ayed I B, Mitiche A. A region merging prior for variational level set image segmentation[J]. IEEE trans on image processing,

2008, 17: 2301-2311

[10] 王小峰. 水平集方法及在图像分割中的应用研究[D]. 合肥: 中国科学技术大学, 2009
Wang Xiao-feng. Level set method and its application in image segmentation[D]. Hefei: University of Science and Technology of China, 2009

[11] 方江雄. 基于变分水平集的图像分割算法研究[D]. 上海: 上海交通大学, 2012
Fang Jiang-xiong. Research on image segmentation based on variational level set[D]. Shanghai: Shanghai Jiaotong University, 2012

[12] 盛朗. 基于水平集的医学图像处理[D]. 扬州: 扬州大学, 2014
Sheng Lang. Medical image segmentation based on level set[D]. Yangzhou: Yangzhou University, 2014

(上接第 295 页)

表 2 在 PSB 测试集和 SCUdb 上进行检索比较的 DCG 性能

序号	特征融合	数据集	
		PSB 测试集 DCG(%)	SCUdb DCG(%)
1	$\hat{R}_x, \hat{R}_y, \hat{R}_z$	54.9	71.3
2	$\hat{D}, \hat{N}_x, \hat{N}_y, \hat{N}_z$	57.8	72.0
3	CAH	43.4	68.1
4	EGI	43.8	53.5
5	3DHT	57.7	72.7
6	R, C_x, C_y, C_z	54.8	73.4
7	$\hat{D}, \hat{N}_x, \hat{N}_y, \hat{R}, \hat{R}_x, \hat{R}_z$	62.4	74.4

结束语 本文提出一个基于局部特征概率密度的三维模型特征提取框架。与仅粗略考虑网格模型表面三角形的重心或对模型表面进行大量随机采样的直方图特征提取方法相比, 该框架针对三维表面局部几何特征集, 利用核密度估计方法估计每一个选定目标点的特定局部特征密度, 所有目标点的局部特征密度值构成一个特征向量, 用以描述一个三维模型。实验结果表明: 使用该模型抽取三维网格模型的单元特征及多个单元特征组合而成的多元特征实现三维模型检索, 其检索性能优于基于统计的直方图特征提取方法。

参考文献

[1] 徐正光, 陈宸. 鲁棒且快速的特征点匹配算法[J]. 计算机科学, 2013, 40(2): 294-296
Xu Zheng-guang, Chen Chen. Robust and Fast Feature Points Matching[J]. Computer Science, 2013, 40(2): 294-296

[2] 胡事民, 杨永亮, 来煜坤. 数字几何处理研究进展[J]. 计算机学报, 2009, 32(8): 1451-1469
Hu Shi-min, Yang Yong-liang, Lai Yu-kun. Research Progress of Digital Geometry Processing[J]. Chinese Journal of Computers, 2009, 32(8): 1451-1469

[3] Castellani U, Cristani M, Murino V. Statistical 3D Shape Analysis by Local Generative Descriptors[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2011, 33(12): 2555-2560

[4] Horn B K P. Extended Gaussian images[J]. Proceedings of the IEEE, 1984, 72(12): 1671-1686

[5] Kang S, Ikeuchi K. The complex EGI: a new representation for 3-D pose determination[C]// Proceedings of 5th International Central and Eastern European Conference on Multi-Agent Sys-

tems (CEEMAS 2007) Leipzig, Germany, 2007, 9: 25-27

[6] Zaharia T, Preteux F. 3D shape-based retrieval within the MPEG-7 framework [C]// Proceedings of SPIE Conference on Nonlinear Image Processing and Pattern Analysis XII. San Jose, 2001: 133-145

[7] Liu Zhen-bao, Bu Shu-hui, Kun Zhou, et al. A Survey on Partial Retrieval of 3D Shapes[J]. Journal of Computer Science and Technology, 2013, 28(5): 836-851

[8] 王刚, 靳彦青, 刘立柱, 等. 基于多特征融合的东亚文种识别[J]. 计算机科学, 2013, 40(1): 260-263
Wang Gang, Jin Yan-qing, Liu Li-zhu, et al. East Asian Script Identification Based on Multi-feature [J]. Computer Science, 2013, 40(1): 260-263

[9] Akgül C B, Sankur B, Yemez Y, et al. Density based 3D shape descriptors[J]. EURASIP Journal on Advances in Signal Processing, 2007, 2007: 1-16

[10] Hardle W, Muller M, Sperlich S, et al. Nonparametric and Semiparametric Models[M]. Springer Series in Statistics, Springer, Heidelberg, Germany, 2004

[11] Scott D W. Multivariate Density Estimation: Theory, Practice and Visualization[M]. John Wiley & Sons, 2008

[12] Comaniciu D, Ramesh V, Meer P. The variable bandwidth mean shift and data-driven scale selection[J]. Proceedings of the 8th International Conference on Computer Vision (ICCV'01), Vancouver, BC, Canada, 2001, 7(1): 438-445

[13] 黄云清. 数值计算方法[M]. 北京: 科学出版社, 2010
Huang Yun-qing. Numerical Method [M]. Beijing: Science Press, 2010

[14] Sinha A, Gupta S. A Fast Nonparametric Noncausal MRF-Based Texture Synthesis Scheme Using a Novel FKDE Algorithm[J]. IEEE Transactions on Image Processing, 2010, 19(3): 561-572

[15] Shilane P, Min P, Kazhdan M, et al. The Princeton shape Benchmark[C]// Proceedings of International Conference on Shape Modeling and Applications (SMI'04). Genova, Italy, 2004: 167-178

[16] Goodall S, Lewis P H, Martinez K, et al. SCULPTEUR: multimedia retrieval formuseums[C]// Image and Video Retrieval: Image and Video Retrieval (CIVR'04). Dublin, Ireland, 2004: 638-646

[17] 郭连朋, 陈向宁, 徐万朋, 等. 基于 Kinect 传感器的物体三维重建[J]. 四川兵工学报, 2014, 35(11): 119-123
Guo Lian-peng, Chen Xiang-ning, Xu Wan-peng, et al. 3D-object Reconstruction Based on kinect Sensor[J]. Journal of Sichuan Ordnance, 2014, 35(11): 119-123