

doi: 10.11918/j.issn.0367-6234.2016.05.003

结合 KL 散度和 RSF 模型的主动轮廓图像分割方法

刘琳^{1,2}, 程丹松¹, 何仕文¹, 石大明¹, 吴锐¹, 王君¹

(1.哈尔滨工业大学 计算机科学与技术学院, 150001 哈尔滨; 2.哈尔滨学院 工学院, 150086 哈尔滨)

摘要: 针对主动轮廓模型在进行图像分割时计算复杂度较高的问题, 提出一种基于区域的变分水平集主动轮廓模型图像分割方法. 新模型将 Kullback-Leibler (KL) 散度信息加入到 RSF (region-scalable fitting) 模型中, 在新模型的能量项中通过 RSF 能量项计算区域内某点和该区域“中心”之间的拟合距离来表示目标区域的相似性, 同时通过最大化 KL 能量项使模型能更容易分离图像中的不同灰度区域, 进而使图像分割的计算时间显著降低. 该模型可以很好地处理图像的模糊边界和图像噪声等问题, 并适用于合成图像和实际图像的分割. 通过实验结果的对比可以看出, 本模型在保证分割精度的前提下, 加快了边缘的收敛速度, 提高了图像分割的效率.

关键词: RSF 模型; 能量函数; 图像分割; KL 散度; 水平集

中图分类号: TP391 **文献标志码:** A **文章编号:** 0367-6234(2016)05-0023-09

Active contour driven by region-scalable fitting and Kullback-Leibler divergence for image segmentation

LIU Lin^{1,2}, CHENG Dansong¹, HE Shiwen¹, SHI Daming¹, WU Rui¹, WANG Jun¹

(1.School of Computer Science and Technology, Harbin Institute of Technology, 150001 Harbin, China;
2.Engineering Institute, Harbin University, 150086 Harbin, China)

Abstract: To overcome the problem of high computational cost of active contour model, a new local region-based active contour model in a variational level set formulation for image segmentation is proposed. An energy function based on the region-scalable fitting (RSF) term and the Kullback-Leibler divergence term is formulated. The existing methods construct the energy function for segmentation through computing the distances among the intraregion points and the "center" fitting this region, representing similarity of object region. An energy term including the disparity measured by Kullback-Leibler divergence between regions to be segmented is added to the energy function of the RSF model in the proposed model. The model can handle blurry boundaries and noise problems. The proposed method is applied to segment synthetic and real images, and the experimental results show that KL-RSF can improve the effectiveness of segmentation while ensuring the accuracy through accelerating the minimization of the energy function.

Keywords: region-scalable fitting model; energy function; image segmentation; Kullback-Leibler divergence; level set

图像分割是把图像分成多个具有显著界限(轮廓/边界)区域的处理过程. 所有的图像分割方法可以分为两大类: 分析算法和统计算法. 主动轮廓^[1]和水平集方法^[2]属于前者, 它们基于给定图像的信息来获得区域的轮廓. 基于统计的方法, 如主动形状模型^[3]和空间分割模型^[4], 则根据分析训练样本

间相似性的变化来进行图像分割. 但是统计方法因需要一定量的训练样本, 且分析方法受到噪声或显著特征的干扰而使轮廓发散, 所以在某些应用上是不适合的. 本文将主要研究水平集方法的图像分割.

基于水平集方法的主动轮廓模型是近年来快速发展的一种图像分割方法, 在图像处理和计算机视觉等领域得到了广泛的应用^[2]. 基于水平集方法的主动轮廓模型与文献[1]提出的主动轮廓模型(也叫 snake 模型)的不同之处在于: 基于水平集方法的主动轮廓模型将图像不同区域之间的边界作为零水平集嵌入定义在图像区域上的高一维的水平集函数中, 并利用对整个水平集函数的演化代替传统的主动轮廓模型对图像不同区域间边界曲线的演化, 最

收稿日期: 2015-05-04.

基金项目: 国家自然科学基金(61440025, 61402133); 国家博士后科学基金(20100480998); 国防科工局重大专项(公开)(50-Y20A08-0508-15/16); 哈尔滨市科技创新人才专项资金(2013RFQXJ110).

作者简介: 刘琳(1984—), 女, 讲师, 博士研究生;
石大明(1971—), 男, 博士生导师.

通信作者: 程丹松, cdsinhit@hit.edu.cn.

终通过演化得到一个定义在图像区域上的水平集函数,该水平集函数中的零水平集代表了图像不同区域间边界的位置.根据建立能量泛函的不同思想,基于水平集方法的主动轮廓模型可以分为两类:基于边缘的模型和基于区域的模型.基于边缘的模型对图像上的边缘信息(如图像的梯度)有较好的响应,而基于区域的模型通常可以更好地考虑图像不同区域中的整体信息(如区域中的平均灰度、整体纹理特征等).对于具有高噪声和低对比度,不同区域间边缘模糊不清的图像,基于边缘的模型通常不能取得很好的分割效果.而基于区域的模型可以对区域上整体信息进行建模,更有利于处理高噪声、低对比度、边缘不清等问题.CV模型^[5]作为经典的主动轮廓模型,它的能量泛函是基于区域信息的,该方法在被分割图像存在弱边界的情况下也能检测到对象的内部轮廓.但是该方法只适用于均匀图像的分割处理,对亮度不均匀图像的处理效果不是很好,特别是文献[6-7]中提到的分段图像(PS),它们都具有较高的计算复杂度且对初始轮廓比较敏感.针对这个问题,先后出现了RSF模型^[8]、LCV模型^[9]、LIF模型^[10]和其他的方法^[11-16],它们都针对分割能量函数进行了修正,与CV法相比,这些模型在分割效率和有效性方面都得到了增强.RSF模型中因能量函数中所用能量为局部拟合能量,使得其能量函数存在许多局部最优解.文献[17]对RSF模型进行改进,引入局部有序能量,提出了一个Order-LBF的图像分割模型,通过添加局部灰度约束即局部有序能量减少局部最优解的数目,从而能够得到比RSF模型更稳定和理想的分割效果.

本文在RSF模型的基础上进行能量泛函的改进,将Kullback-Leibler散度加入到RSF模型中,形成一个新的能量泛函模型(KL-RSF模型).实验结果表明,加入类间距离信息的KL-RSF模型与RSF模型、LCV模型、LIF模型、LBF+Order相比,具有较低的计算量和很好的分割性能和效率.

1 RSF模型

在RSF模型的能量函数中, x 是灰度图像 Ω 中的一个点, $x \in \Omega, I: \Omega \subset \mathbb{R}^2 \rightarrow \mathbb{R}, C$ 是图像 Ω 中的一个闭合曲线,它将图像 Ω 分为两个适应子区域 Ω_1 和 $\Omega_2, f_1(x)$ 和 $f_2(x)$ 分别为这两个区域中以 x 为中心点的小区域内亮度的近似值.RSF模型中拟合能量的定义为

$$E^{\text{Fit}} = \sum_{i=1}^2 \lambda_i \int_{\Omega} \int_{\Omega} K_{\sigma}(x-y) |I(y) - f_i(x)|^2 dy dx. \quad (1)$$

其中 λ_1 和 λ_2 是两个正常数,代表权重参数, $K_{\sigma}(x -$

$y)$ 是一个尺度参数 $\sigma > 0$ 的核函数.RSF模型的拟合能量模型的物理意义如图1所示.在子区域 Ω_i 中, y 是以点 x 为中心,半径为 σ 的圆形邻域内的一点. E^{Fit} 的最小值能够引导曲线 C 去发现目标边缘,拟合函数 $f_i(x)$ 是曲线 C 两边区域的局部图像亮度的最佳逼近值.

在演变过程中为了平滑曲线 C ,把正规项(曲线的长度 $|C|$)引入到函数中,修改后的能量函数可改写为

$$E^{\text{RSF}} = E^{\text{Fit}} + v |C|. \quad (2)$$

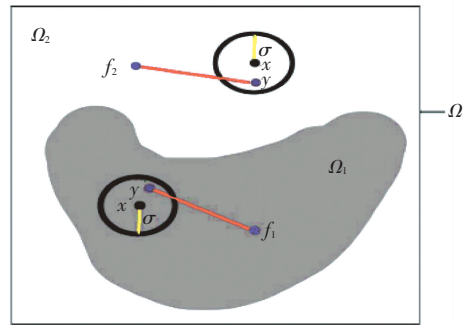


图1 RSF模型拟合能量模型的示意

为了处理拓扑变化,一般要把能量函数 E^{RSF} 代入到一个变分水平集,并通过梯度下降法来计算.水平集函数 φ 从轮廓 C 的内部区域 Ω_1 到外部区域 Ω_2 的定义为

$$\varphi(x) \begin{cases} -c_0, & x \in \Omega_1; \\ 0, & x \in C; \\ c_0, & x \in \Omega_2. \end{cases}$$

其中 $C \in \Omega$ 是一个用零水平集函数表示的轮廓.

文献[8]中RSF模型能量泛函的水平集格式为

$$F^{\text{RSF}}(\varphi, f_1, f_2) = \varepsilon^{\text{RSF}}(\varphi, f_1, f_2) + vL(\varphi) + \mu p(\varphi), \quad (3)$$

其中前两项 $\varepsilon^{\text{RSF}}(\varphi, f_1, f_2)$ 和 $L(\varphi)$ 分别是数据拟合项和长度项,对应式(2)中右端的两项.最后一项是新加入的水平集正则项,该项可以保证分割结果的准确性,水平集演化的稳定性,以及避免重新初始化水平集函数.它们的表达式为

$$\varepsilon^{\text{RSF}}(\varphi, f_1, f_2) = \sum_{i=1}^2 \lambda_i \int_{\Omega} \int_{\Omega} K_{\sigma}(x-y) | \mu_0(y) - f_i(x) |^2 M_i^{\varepsilon}(\varphi(y)) dy dx,$$

$$L(\varphi) = \int_{\Omega} | \nabla H(\varphi(x)) | dx,$$

$$p(\varphi) = \int \frac{1}{2} (| \nabla \varphi(x) | - 1)^2 dx.$$

其中 $M_1(\varphi) = H(\varphi)$, $M_2(\varphi) = 1 - H(\varphi)$.为了极小化能量函数式(3),本文同样使用光滑的Heaviside

函数 $H_\varepsilon(x)$ 来近似 $H(x)$, $H_\varepsilon(x)$ 和 $\delta_\varepsilon(x)$ 分别是 Heaviside 函数和 Dirac 函数的正规化函数^[9], 而且 $\delta_\varepsilon(x)$ 是 $H_\varepsilon(x)$ 的导数. 它们的表达式如式(4)所示, 拟合能量 $f_i(x)$ 的表达式如式(5)所示:

$$H_\varepsilon(x) = \frac{1}{2} \left[1 + \frac{2}{\pi} \arctan\left(\frac{x}{\varepsilon}\right) \right],$$

$$\delta_\varepsilon(x) = H'_\varepsilon(x) = \frac{1}{\pi} \frac{\varepsilon}{\varepsilon^2 + x^2}, \quad (4)$$

$$f_i(x) = \frac{k_\sigma(x - y) * [M'_i(\varphi(x))I(x)]}{k_\sigma(x - y) * M'_i(\varphi(x))}. \quad (5)$$

2 结合 KL 散度的改进 RSF 模型

从文献[8]可知, RSF 模型可以很好地对不均匀图像进行分割, 然而在等式(5)中, 卷积运算是非常耗时的, 所以本文对 RSF 模型进行了改进, 提出了加入 KL 散度的改进 RSF 模型来有效地解决这一问题.

2.1 模型的能量函数


基于几何主动轮廓模型的图像分割可以被看作是一个聚类问题, 现存的方法通过最小化图像中每个点的灰度与其所在区域灰度的“拟合中心点”的距离来寻找目标的轮廓^[18-19]. 图像中各区域可以看作不同类别, 而区域的“拟合中心点”代表该类别, 与区域“拟合中心点”距离小的就认为其归属于该类. 为了使主动轮廓能准确地发现亮度不均匀图像中的目标边界, RSF 模型使用局部能量拟合项来确保同质区域内的像素具有相似特征, 即像素是否属于该区域是由最小化该项来决定的, 即使聚类中的类内距离最小.

在保证分割结果准确的前提下, 为了使轮廓演化速度更快, 把类间信息, 即区域间(轮廓内部和外部)的统计差异, 加入到 RSF 的能量函数中. 通过最大化类间距离来使分割变得更快和更容易. 任意两个区域的 KL 散度指出了它们之间的相似性, 数值越高意味着两个区域越不相似, 从而使分割的速度越快. 通过引入区域间的 KL 散度能量, 可以令区域间的 KL 散度能量最大化, 即最大化两个区域之间的差异, 使距离区域“拟合中心点”较远的边缘点不因为式(1)中拟合能量的最小化, 而被划分到错误的区域中, 从而使分割的结果更准确. 另外, 随着区域间差异的增加, 也使得各点划分到其所属区域中的过程加快, 能量函数最小化的求解收敛速度增加, 即加快了图像分割的速度. 改进后能量函数的定义为

$$\varepsilon = \gamma_1 E^{\text{Fit}} + \gamma_2 E^{\text{KL}}. \quad (6)$$

其中 γ_1 和 γ_2 是用于平衡两个能量项性能的系数.

图 2(a) 显示了 RSF 方法的能量函数, 图 2(b) 显示了本文方法的能量函数. 图 2 中的黑线表示了式(6)中的第一项 E^{Fit} , 两个点 C_1 和 C_2 分别表示区域 Ω_1 和 Ω_2 的亮度“中心”. 拟合函数是两类距离的和: 一类距离是区域 Ω_1 内的点到亮度“中心” C_1 的距离, 另一类距离是区域 Ω_2 内的点到亮度“中心” C_2 的距离. 可通过最小化相同区域内黑色线的长度来得到目标边界. 图 2(b) 中显示的虚线距离和表示了式(6)中的第二项 E^{KL} . 每一条虚线表示区域 Ω_1 (或 Ω_2) 内的点到另外一个区域亮度“中心” C_2 (或 C_1) 的距离. 因为 E^{KL} 值越大意味着两个区域相似性越小, 所以最大化 E^{KL} 将使某区域内的点与其它区域的点产生更大的差异, 进而加速分割的处理过程. 图 2(b) 给出了包含类内距离的能量项 E^{Fit} (图中黑线) 和包含类间距离的能量项 E^{KL} (图中虚线) 的示意图, 本文将这两种距离结合到一起来进行图像分割, 称为 KL-RSF 模型.



(a) RSF 模型能量的应用 (b) 本文提出的 KL-RSF 模型能量的应用

图 2 现有 RSF 模型与本文提出的 KL-RSF 模型能量的比较用于构建的能量项 E^{KL} 的 KL 散度表达式为

$$\text{KL}(p, q) = \sum p \log \frac{p}{q}, \quad (7)$$

其中 p 和 q 表示两个概率分布. 根据文献[20]对 KL 散度的描述, 能量 E^{KL} 的定义为

$$E^{\text{KL}} = \int_{\Omega_1} I(x)_{\Omega_1} \log \frac{I(x)_{\Omega_1}}{\text{mean}(I(x)_{\Omega_2})} dx + \int_{\Omega_2} I(x)_{\Omega_2} \log \frac{I(x)_{\Omega_2}}{\text{mean}(I(x)_{\Omega_1})} dx.$$

其中 $I(x)_{\Omega_1}$ 和 $I(x)_{\Omega_2}$ 分别表示区域 Ω_1 和 Ω_2 内像素点的亮度. 从式(7)可以看出, 如果 $I(x)_{\Omega_1}$ (或 $I(x)_{\Omega_2}$) 逼近 $I(x)_{\Omega_2}$ (或 $I(x)_{\Omega_1}$) 的均值, 意味着区域 Ω_1 (或 Ω_2) 中点的亮度接近区域 Ω_2 (或 Ω_1)

点的平均亮度, $\log \frac{I(x)_{\Omega_1}}{\text{mean}(I(x)_{\Omega_2})}$ (或 $\log \frac{I(x)_{\Omega_2}}{\text{mean}(I(x)_{\Omega_1})}$) 将趋近 0. 所以说如果两个区域非常接近, 则该能量函数将接近于 0, 反之如果两个区域存在很大差异时, 该值将比较大.

由于本文方法的分割是由最小化全局能量 E^{Fi} 和最大化第二项 E^{KL} 来完成的,所以 E^{KL} 前的系数 γ_2 是负的,进而使整个能量函数最小.

2.2 水平集函数表达式

为了清晰阐述模型的表达式,使用两段水平集来解决能量函数最小化问题. 由于系数 γ_1 的作用可以用系数 λ_1 和 λ_2 来表示,所以把正规项代入到水平集函数后,分割的整个能量函数可以表示为

$$\begin{aligned} \varepsilon(\varphi) = & \sum_{i=1}^2 \lambda_i \iint K_{\sigma}(x-y) |I(y) - \\ & f_i(x)|^2 M_i(\varphi(x)) dy dx + \\ & \gamma_2 \int I(x) \log \frac{I(x)}{\text{mean}(I(x)_{\Omega_2})} M_1(\varphi(x)) dx + \\ & \gamma_2 \int I(x) \log \frac{I(x)}{\text{mean}(I(x)_{\Omega_1})} M_2(\varphi(x)) dx + \\ & v \int |\nabla H(\varphi(x))| dx + \\ & \mu \int \frac{1}{2} (|\nabla \varphi(x)| - 1)^2 dx. \end{aligned}$$

其中 $\int |\nabla H(\varphi(x))| dx$ 是 φ 的零水平轮廓长度的正规项, $\int \frac{1}{2} (|\nabla \varphi(x)| - 1)^2 dx$ 是为了提高计算精度和保证水平集曲线稳定演化而引进的正规项.

梯度下降法经常被用于水平集函数 φ 的能量函数最小化. 即 f_1 和 f_2 被固定,通过标准梯度下降法来求解梯度流方程,进而使能量函数最小化.

$$\begin{aligned} \frac{\partial \varphi}{\partial t} = & -\delta_{\varepsilon}(\varphi) (-\lambda_1 e_1 + \lambda_2 e_2) - \gamma_2 \delta_{\varepsilon}(\varphi) (e_4 - \\ & e_3) + v \delta_{\varepsilon}(\varphi) \text{div} \left(\frac{\nabla \varphi}{|\nabla \varphi|} \right) + \mu (\nabla^2 \varphi - \\ & \text{div} \left(\frac{\nabla \varphi}{|\nabla \varphi|} \right)) \end{aligned}$$

其中:

$$e_1 = \iint K_{\sigma}(x-y) |I(x) - f_1(y)|^2 dy dx,$$

$$e_2 = \iint K_{\sigma}(x-y) |I(x) - f_2(y)|^2 dy dx,$$

$$e_3 = \int I(x) \log \frac{I(x)}{\text{mean}(I(x)_{\Omega_2})} dx,$$

$$e_4 = \int I(x) \log \frac{I(x)}{\text{mean}(I(x)_{\Omega_1})} dx.$$

3 实验结果和性能分析

为了验证 KL-RSF 模型的准确性、鲁棒性等处理效果,针对不同类型的图像进行处理,并把处理结果和其他方法进行比较. 全部实验是在 3.20 GHz CPU, 4GB RAM 的惠普台式机上使用 Matlab2011b

完成的. 实验中的参数如下:迭代的时间步长 $\Delta t = 0.1$, 参数 λ_1 、 λ_2 和 ν 的值取 1, 长度约束项的系数 μ 的大小随分割图像的变化而改变. 其中引入的能量 E^{Fi} 前的系数 γ_2 的值,在用于合成图像和医学图像分割时,取值都为 1,而在自然图像分割时其取值根据图像的不同进行调整.

3.1 轮廓定位的准确性

在本实验中,通过把 KL-RSF 模型分别应用到合成图像和真实医学图像来验证本文模型的效果,具体处理结果如图 3 所示. 在图 3 中,第一列显示的是图像的初始轮廓,接下来的 5 列从左到右依次显示的是 RSF 模型、LIF 模型、LCV 模型、Order-LBF 模型和本文模型的处理结果. 从实验结果可以看到,LCV 模型和 LIF 模型对图#2 和图#5 的分割效果较好,而 RSF 模型的分割效果与其相比有所提高,因其能量函数就是针对非均匀图像进行构造,只有对图#7 和#8 的分割结果不是很理想. Order-LBF 模型虽然通过引入局部有序能量以减少局部最优解的数目,但仍陷入局部最优解,导致分割结果不理想. 而本文的模型通过引入 KL 能量即全局信息,使求得的解为全局最优,实验结果也证明本文模型与其他模型相比具有更好的准确性,因其具备 RSF 模型分割非均匀图像的能力,同时又因为 KL 能量的引入,使最终求得的解全局最优.

为了进一步证实本文方法的效果,把它应用到自然图像分割,在 Berkeley 分割数据集 BSDS300 上进行测试,并把处理结果同人工分割结果进行对比,比较结果如图 4 所示. 在图 4 中从左到右分别表示原始图像、手工分割的结果、RSF 模型的分割结果、LIF 模型的分割结果、LCV 模型的分割结果、Order-LBF 模型的分割结果和本文模型的分割结果. 通过对比,可以看出本文方法比其他 4 种方法更接近手工分割结果. 其分割效果不理想的原因也是因为其他模型得到的解为局部解.

为了对 KL-RSF 模型进行客观评价,使用两个著名的评价准则: PRA 距离^[20] 和 Hausdorff 距离^[21] 来进行评价. 其中 Hausdorff 距离检测两幅图像的相似性,较低的值意味着较好的分割结果. 计算图像间 Hausdorff 距离的公式为

$$\text{HAU}(I_c, I_{\text{ref}}) = \max(h(I_c, I_{\text{ref}}), h(I_{\text{ref}}, I_c)).$$


其中: $h(I_c, I_{\text{ref}}) = \max_{a \in I_c} (\min_{b \in I_{\text{ref}}} \|a - b\|)$; I_c 定义了一个通过分割结果得到的分割轮廓; I_{ref} 定义了真实数据对应的参考轮廓.

PRA 经验测度是一个最常用的对两个像素组进行比较的措施, PRA 的计算公式为

$$PRA(I_c, I_{ref}) = \frac{\sum_{k=1}^{card(I_c)} \frac{1}{1 + d^2(k)}}{\max\{card(I_{ref}), card(I_c)\}}$$

其中的 $d(k)$ 是一个分割轮廓上 I_c 的第 k 个点 to 参考轮廓 I_{ref} 最近点的距离. 表 1 列出了 RSF 模型、LIF 模型、LCV 模型、Order-LBF 模型和本文模型使用 Hausdorff 距离和 PRA 距离的定量对比结果. 使用手工分割图像作为 I_{ref} , 使用相应模型的分割结果作为 I_c . Hausdorff 距离越小, 说明该模型的分割结果与手工分割结果越接近; 相反, PRA 距离越大, 说明两

种结果越接近. 表 1 的实验结果显示, 与其他模型相比较, 本文的模型对除图#100080 外的两个评价指标结果更优, 而 RSF 模型对图#100080 的评价指标为最优. 观察图 4 中 RSF 模型的分割结果, 可以看到其分割结果集中熊身体, 而没有找到熊身体两侧草的轮廓, 同时两侧草的轮廓存在于人工分割结果中, 因此导致两个评价指标的计算结果较好. 综合来看评价指标结果, 本文模型的分割效果好于其他 4 种方法.



(a) 初始轮廓 (b) RSF 方法 (c) LIF 方法 (d) LCV 方法 (e) Order-LBF 方法 (f) KL-RSF 方法

图 3 本文模型和现存算法分割结果的比较

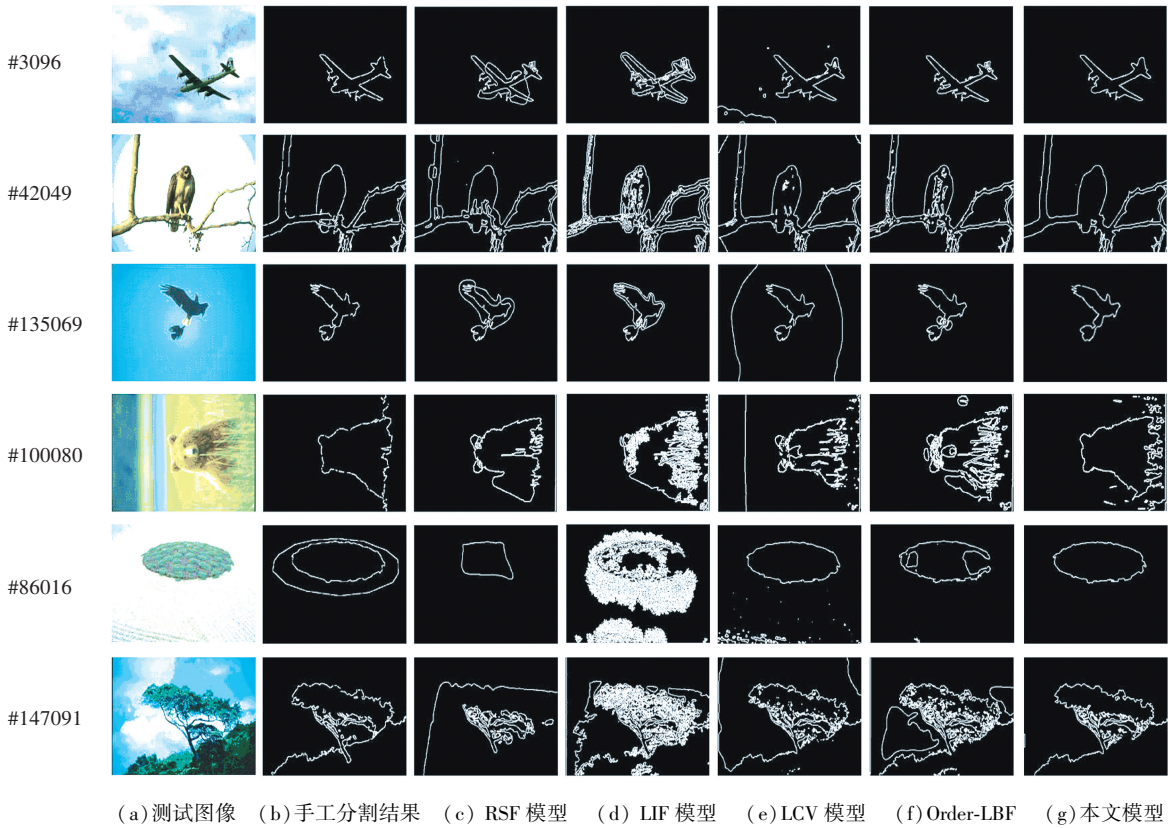


图 4 本文模型和现存算法在公共测试集上分割结果的比较

表 1 定量评价的结果

测试图像 (481 * 321)	Hausdorfs 准则					Pratt 准则				
	RSF	LIF	LCV	Order-LBF	KL-RSF	RSF	LIF	LCV	Order-LBF	KL-RSF
#3096	21.023 8	17.029 4	204.963 4	17.117 2	9.219 5	1.191 6E-11	5.561 6E-13	2.132 1E-13	5.807 1E-11	1.155 8E-9
#42049	53.000 0	39.458 8	110.887 3	39.051 2	23.430 7	2.225 2E-12	5.199 3E-14	6.827 3E-13	3.333 5E-13	3.691 8E-11
#135069	26.926 8	26.925 8	178.101 1	13.416 4	10.198 0	1.595 2E-11	2.477 1E-11	1.390 3E-13	2.646 8E-10	4.233 9E-9
#100080	48.093 7	48.093 7	106.775 5	55.362 4	58.523 5	8.222E-13	1.188 2E-14	6.260 3E-14	3.604 7E-14	4.12E-13
#86016	116.726 2	149.187 8	157.419 8	125.016 0	62.641 8	2.682 6E-11	3.307 7E-17	3.841 6E-14	3.553 9E-12	6.953E-10
#147091	96.213 3	124.807 9	114.201 6	124.807 9	31.906 1	7.380 4E-13	1.955 9E-15	8.348 3E-14	1.860 9E-14	2.48E-12

3.2 对噪声的鲁棒性

为了验证 KL-RSF 对噪声的鲁棒性,选择图 3 中的#2 图像作为测试图像,这是因为#2 图像中包含较多的目标.在图 5 的第一行,可以看出图像从左到右分别被加入了不同程度的高斯噪声($\mu = 0, \sigma^2 = 10, 15, 20, 25$).在图 5 的第二行到第六行分别显示了 RSF 模型、LIF 模型、LCV 模型、Order-LBF 模型和本文模型的分割结果.从图 5 中可以看出,本文模型引入的 KL 能量增强区域间的差异,从而能够准确处理噪声点,得到较好的分割结果.其他模型都是根据局部信息构造能量函数,导致噪声的出现严重影响其分割的准确性,从而得到的结果随着噪声的增强而变差.与其他模型相比,KL-RSF 模型

可以得到较好的分割结果,并且对噪声具有很好的鲁棒性.

3.3 轮廓演变的收敛速度

一个模型的效率可通过比较最终轮廓所需要的迭代次数和完成分割过程所用的 CPU 时间来进行验证.完成图 3 和图 4 分割过程所需要的迭代次数和 CPU 时间如表 2 和表 3 所示.由表 2 可知, KL-RSF 模型与其他 4 种方法相比只需要较少的迭代次数, LCV 模型分割图#6 和#7 的 CPU 时间比 KL-RSF 模型少,其原因之一是其陷入局部最优解.此外,由于 KL 能量的引入,增加了单次迭代的计算时间. LCV 模型虽然在分割图#6 和#7 时所用的分割时间减少,但分割结果较差.




图 5 对噪声图像分割结果的比较

表 2 图 3 分割过程所需迭代次数和 CPU 时间的比较

测试图像 (图像尺寸)	RSF 模型		LIF 模型		LCV 模型		Order-LBF		KL-RSF 模型	
	CPU 时间	迭代次数	CPU 时间	迭代次数	CPU 时间	迭代次数	CPU 时间	迭代次数	CPU 时间	迭代次数
#1(79 * 75)	4.593 4	250	9.158 9	300	3.637 4	200	5.665 4	300	2.124 6	110
#2(95 * 72)	0.804 96	40	3.287 6	100	2.818 3	150	2.086 3	100	0.660 16	30
#3(111 * 110)	1.924	95	5.782 9	147	2.963	150	10.060 8	500	1.325 3	60
#4(103 * 131)	6.274	300	5.128 6	147	3.840 7	200	26.383 1	1 300	2.178 2	100
#5(252 * 185)	2.920 8	90	7.374 3	100	3.510 2	130	3.133 9	100	2.365 2	70
#6(119 * 78)	3.465 4	185	6.731 7	190	3.310 2	190	6.325 7	300	3.501 7	180
#7(180 * 170)	4.025 8	180	9.779 2	190	3.773	190	8.592 5	350	4.047 4	180
#8(549 * 357)	69.782 6	350	87.760 8	350	78.631 2	350	62.882 7	350	67.382 4	350

表 3 图 4 分割过程所需迭代次数和 CPU 时间的比较

测试图像 (图像尺寸)	RSF 模型		LIF 模型		LCV 模型		Order-LBF		KL-RSF 模型	
	CPU 时间	迭代次数	CPU 时间	迭代次数	CPU 时间	迭代次数	CPU 时间	迭代次数	CPU 时间	迭代次数
#3096	28.036 7	230	7.429 4	200	21.882 2	200	11.109 8	100	18.401 9	150
#42049	28.230 9	220	10.045 6	220	21.78 2	190	56.912 4	480	25.333 6	200
#135069	37.716 6	300	5.812 6	150	40.754 7	350	40.264 7	350	14.990 2	120
#100080	61.595 6	500	13.688 4	300	21.8537	180	45.607 5	380	18.940 7	150
#86016	25.454 8	210	8.232 2	100	11.558 9	100	51.604 5	450	7.954 6	60
#147091	32.662	260	13.976 9	220	22.455 9	190	59.806 2	450	12.87	100

从表 3 中可知,对图像#42049 进行处理时,LCV 模型的迭代次数比 KL-RSF 模型要少,但是从图 4 的处理结果可知,LCV 模型在对该图像进行分割时的结果要比本文模型差,这是因为 LCV 模型很容易陷入到局部解,所以它只需要较少的迭代次数,但分割效果并不理想.此外,Order-LBF 模型对图#3096 分割的迭代次数也存在上述问题,从图 4 可以看出,其只分割出飞机内部阴影区域,而没有找到飞机的整体轮廓,因此分割时的迭代次数相对较少.在 CPU 处理时间上,LIF 模型分割 4 幅图像的时间少于其他模型,但从图 4 的分割结果可以看到,LIF 模型的分割结果较差,原因与对表 2 的分析相同.

为了验证能量函数 E^{KL} 的影响,对包含该项的

KL-RSF 模型和不包含该项的 RSF 模型的收敛演化过程进行了对比实验,对图 3 中图像处理后的性能比较结果如图 6 所示,横坐标是模型得到最终轮廓所需要的迭代次数,纵坐标是在不同迭代次数时的能量函数值,其中图中的小图是 KL-RSF 变化曲线的局部放大图.从图 6 可以看到,RSF 模型的演变不稳定,很容易陷入到局部最优解,而 KL-RSF 模型的演变稳定,可以快速得到最优解,这是由这两个模型能量函数的结构决定的.在 RSF 模型中只考虑了类内距离,而 KL-RSF 模型同时考虑了类内距离和类间距离,因此 RSF 模型的能量函数只利用图像的局部区域信息,而 KL-RSF 模型则能得到图像的全局信息,进而使曲线的演变变快.

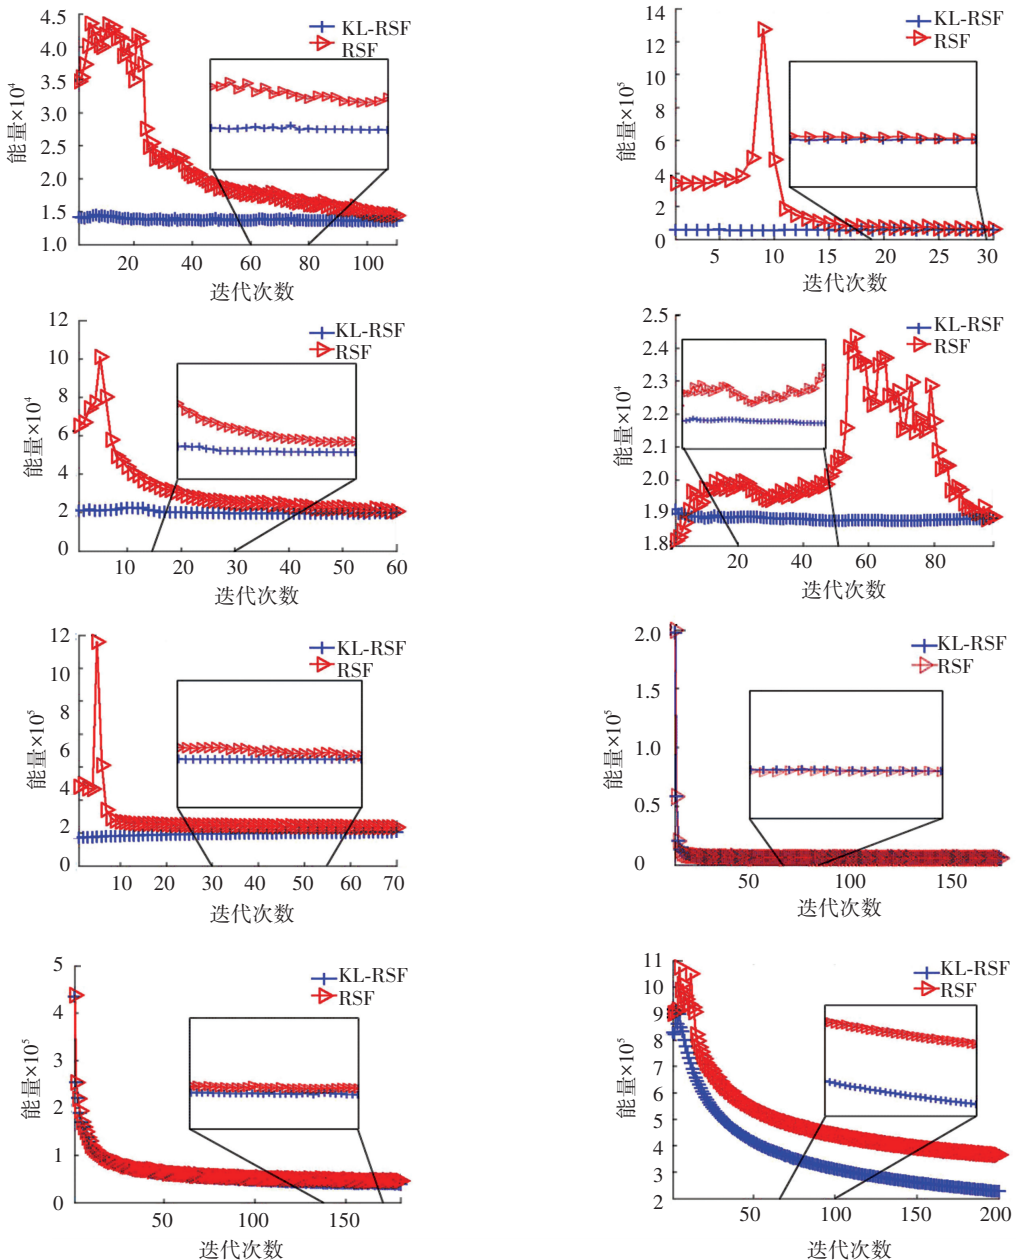


图 6 RSF 模型和 KL-RSF 模型的收敛演变的比较

4 结 论

KL-RSF模型在RSF模型中加入由KL散度信息表示的类间距离能量项,提高了模型的运算速度,降低了模型的计算复杂度.通过对合成图像和实际图像的处理结果可知,KL-RSF模型与现有的RSF模型、LIF模型、LCV模型相比,具有更好的处理效果和计算效率,在保证分割结果的前提下使分割的收敛速度变得更快.

参考文献

- [1] KASS K, WITKIN A, TERZOPOULOS D. Snakes: active contour models [J]. *Int J Comput Vis*, 1988, 1(4): 321-331.
- [2] OSHER S, SETHIAN J A. Fronts propagating with curvature-dependent speed: algorithms based on Hamilton-Jacobi formulations [J]. *J Comput Phys*, 1988, 79(1): 12-49.
- [3] SHI D, GUNN S R, DAMPER R I. Handwritten Chinese radical recognition using nonlinear active shape models [J]. *IEEE Trans. Pattern Analysis and Machine Intelligence*, 2003, 25(2): 277-280.
- [4] LIU G, LIN Z, YAN S, et al. Robust recovery of subspace structures by low-rank representation [J]. *IEEE Trans. Pattern Analysis and Machine Intelligence*, 2013, 35(1): 171-184.
- [5] ZHOU Min. Mather theory for piecewise smooth lagrangian systems [J]. *Science China (Mathematics)*, 2014, 57(5): 1033-1044.
- [6] VESE L, CHAN T. A multiphase level set framework for image segmentation using Mumford and Shah model [J]. *Int. J. Computer Vision*, 2002, 50(3): 271-293.
- [7] TSAI A, YEZZI A, WILLSKY A S. Curve evolution implementation of the Mumford-Shah functional for image segmentation, denoising, interpolation, and magnification [J]. *IEEE Trans Image Process*, 2001, 10(8): 1169-1186.
- [8] LI C, KAO C, GORE J, et al. Minimization of region-scalable fitting energy for image segmentation [J]. *IEEE Trans. Image Process*, 2008, 17(10): 1940-1949.
- [9] WANG X, HUANG D, XU H. An efficient local Chan-Vese model for image segmentation [J]. *Pattern Recognition*, 2010, 43(3): 603-618.
- [10] ZHANG K, SONG H, ZHANG L. Active contours driven by local image fitting energy [J]. *Pattern Recognition*, 2010, 43(4): 1199-1206.
- [11] CHEN Jinhui, YANG Jian. Robust subspace segmentation via low-rank representation [J]. *IEEE Trans on Cybernetics*, 2014, 44(8): 1432-1445.
- [12] WANG Y, XIANG S, PAN C, et al. Level set evolution with locally linear classification for image segmentation [J]. *Pattern Recognition*, 2013, 46(6): 1734-1746.
- [13] WANG L, SHI F, LI G, et al. Segmentation of neonatal brain MR images using patch-driven level sets [J]. *NeuroImage*, 2014, 84(1): 141-158.
- [14] Song T, Yu L, Yi S. Ratio- and distribution-metric-based active contours for SAR image segmentation [C]//Fifth International Conference on Intelligent Control and Information Processing. Dalian: IEEE, 2014: 227-232.
- [15] LI C, HUANG R, DING Z, et al. A level set method for image segmentation in the presence of intensity inhomogeneities with application to MRI [J]. *IEEE Trans. Image Process*, 2011, 20(7): 2007-2016.
- [16] ZHANG K H, SONG H, ZHANG L. Active contours driven by local image fitting energy [J]. *Pattern Recognition*, 2010, 43(4): 1199-1206.
- [17] WANG L, YU Z, PAN C. Medical image segmentation based on novel local order energy [C]//Asian Conference on Computer Vision. Queenstown: Springer, 2010: 148-159.
- [18] BALLA-ARABE S, GAO X, WANG B. A fast and robust level set method for image segmentation using fuzzy clustering and Lattice Boltzmann method [J]. *IEEE Trans. System, Man, and Cybernetics-part B: Cybernetics*, 2013, 43(3): 910-920.
- [19] WANG L, PAN C. Robust level set image segmentation via a local correntropy-based K-means clustering [J]. *Pattern Recognition*, 2014, 47(5): 1917-1925.
- [20] PRATT W K, FAUGERAS O D, GAGALOWICZ A. Visual discrimination of stochastic texture fields [J]. *IEEE Trans. Systems, Man, and Cybernetics*, 1978, 8(11): 796-804.
- [21] BEAUCHEMIN M, THOMSON K, EDWARDS G. On the Hausdorff distance used for the evaluation of segmentation results [J]. *Can. J. Remote Sens.*, 1998, 24(1): 3-8.

(编辑 王小唯 苗秀芝)