

# 基于核特征距离的局部活动轮廓模型<sup>\*</sup>

朱晓舒<sup>1,2</sup>, 孙权森<sup>1</sup>, 夏德深<sup>1</sup>

(1. 南京理工大学 计算机科学与技术学院, 南京 210094; 2. 南京师范大学 分析测试中心, 南京 210046)

**摘要:** 提出了一种基于核特征距离局部活动轮廓分割模型。在模型中使用核特征距离来构造局部拟合能量, 从而可以获取精确的局部图像特征, 可以分割存在灰度不均匀的图像。并通过引入水平集规范项以避免水平集演化的重新初始化, 提高了分割的效率。实验结果表明, 本模型可以很好地克服灰度不均匀性, 同时在分割精度上有了较大的提升, 特别是分割速度比 LBF 模型快 1.3 ~ 1.5 倍。

**关键词:** 图像分割; 灰度不均匀; LBF 模型; 水平集; 核特征距离

**中图分类号:** TP391.41      **文献标志码:** A      **文章编号:** 1001-3695(2012)10-3987-03

doi:10.3969/j.issn.1001-3695.2012.10.103

## Active contour model by kernel-induced distance fitting energy

ZHU Xiao-shu<sup>1,2</sup>, SUN Quan-sen<sup>2</sup>, XIA De-shen<sup>2</sup>

(1. School of Computer Science & Technology, Nanjing University of Science & Technology, Nanjing 210094, China; 2. Center for Analysis & Testing, Nanjing Normal University, Nanjing 210046, China)

**Abstract:** This paper proposed a new active contour model based on kernel-induced distance for image segmentation. It introduced a local fitting energy with a kernel-induced distance, which enabled the extraction of accurate local image information. Therefore, this model could be used to segment images with intensity inhomogeneity. In addition, it used the level set regularizing term to avoid expensive reinitialization of the evolving level set and improved the segmentation speed. Experimental results demonstrate that the proposed algorithm can overcome intensity inhomogeneity, and get the more accurate segmentation result, especially there is about 1.3 to 1.5 times faster than the LBF model.

**Key words:** image segmentation; intensity non-homogeneous; LBF model; level set method; kernel-induced distance

图像分割在计算机视觉、目标识别和医学图像处理领域中有着十分重要的作用。近年来,活动轮廓模型<sup>[1~5]</sup>凭借其良好的分割精度得到了广泛的应用。例如,Chan 等人<sup>[5]</sup>提出的经典 Chan-Vese(CV)模型,假设图像分为均值不等的目标和背景两个部分,将目标从背景中分割出来。由于使用轮廓内部和外部的全部灰度信息,故对噪声较大的图像和弱边界图像仍能取得很好的效果。但 CV 模型假设图像的灰度分布是均匀的,当图像中出现灰度不均匀现象时, CV 模型会产生错误分割。事实上,在许多医学图像中,灰度不均匀性是广泛存在的。为了克服灰度不均匀性对分割结果造成的不良影响, Li 等人<sup>[6]</sup>提出了局部二值拟合(local binary fitting, LBF)模型。该模型在变分方程中定义了局部拟合能量,可以较好地克服灰度不均性现象,并得到较精确的分割结果。王利等人<sup>[7,8]</sup>将 LBF 模型扩展到多相位,但 LBF 模型在演化过程中迭代次数多、计算量大,因而分割速度较慢,且该模型对参数的选择和初始化曲线的位置较为敏感。Wang 等人<sup>[9]</sup>提出了一种高效的局部 CV 模型,该模型通过引入图像局部信息来克服灰度不均匀性,相比 LBF 模型,该模型的迭代次数较少且对初始化曲线的位置较不敏感。

本文提出了一种基于核特征距离的活动轮廓分割模型。

该模型使用了核特征距离,利用窗口函数定义像素的局部拟合能量,再对所有像素的局部拟合能量进一步积分得到整幅图像的局部拟合能量。该模型可以很好地克服灰度不均匀性的影响,具有较好的分割精度和较快的分割效率。

## 1 相关工作

### 1.1 核特征距离

假设数据集  $X$  处于  $d$  维实数空间  $\mathbb{R}^d$ , 考虑一种从输入空间到高维属性空间  $H$  的非线性映射:

$$\Psi: \mathbb{R}^d \rightarrow H, X_i \rightarrow \Psi(X_i)$$

其中,  $X_i = [x_{i,1}, x_{i,2}, \dots, x_{i,d}]^T$ 。由于使用了映射  $\Psi$ , 点积  $X_i \cdot X_j^T$  就变成了  $\Psi(X_i) \cdot \Psi(X_j)^T$ , 因此,  $X_i$  和  $X_j$  之间的核特征距离可以表示为

$$\begin{aligned} \|\Psi(X_i) - \Psi(X_j)\|^2 &= (\Psi(X_i) - \Psi(X_j))(\Psi(X_i) - \Psi(X_j))^T = \\ &= \Psi(X_i)\Psi(X_i)^T - 2\Psi(X_j)\Psi(X_i)^T + \Psi(X_j)\Psi(X_j)^T = \\ &= K(X_i, X_i) - 2K(X_i, X_j) + K(X_j, X_j) \end{aligned} \quad (1)$$

其中:  $K(X_i, X_j) = \Psi(X_j)\Psi(X_i)^T$  称之为核特征函数。在众多的核特征函数中,最著名的是高斯核特征函数:

$$K(X_i, X_j) = \exp\left(-\frac{\sum_{k=1}^d |x_{i,k} - x_{j,k}|^a}{\sigma^2}\right)^b \quad (2)$$

**收稿日期:** 2012-02-21; **修回日期:** 2012-03-23      **基金项目:** 国家自然科学基金资助项目(60773172); 江苏省自然科学基金资助项目(BK2008411); 教育部博士学科点基金资助项目(200802880017)

**作者简介:** 朱晓舒(1978-), 男, 湖南湘潭人, 博士研究生, 主要研究方向为图像处理、计算机视觉(xiaoshu\_zhu78@163.com); 孙权森(1963-), 男, 山东梁山人, 教授, 博导, 博士, 主要研究方向为模式识别、图像处理、医学影像分析、遥感信息系统等; 夏德深(1941-), 男, 江苏南京人, 教授, 博导, 博士, 主要研究方向为图像处理、卫星遥感、模式识别。

其中:  $a \geq 0, 1 \leq b \leq 2$  和  $\sigma > 0$  都为常数。显然, 对于高斯核特征函数式(2)来说,  $K(X_i, X_i) = 1$ , 因此, 核特征距离式(1)可化简为

$$\|\Psi(X_i) - \Psi(X_j)\|^2 = 2(1 - K(X_i, X_j)) \quad (3)$$

核特征距离的本质是对于某一非线性的输入空间, 采用某种非线性映射将该输入空间变换到更高维属性空间, 变换后的高维属性空间就可进行线性分类, 从而提高距离测量的准确性。

## 2 本文的方法

### 2.1 理论模型

考虑已知图像  $I: \Omega \rightarrow \mathbb{R}^d$ , 其中  $\Omega$  为图像域, 且  $d \geq 1$  是图像  $I(x)$  的维度, 对于灰度图像  $d=1$ , 对于彩色图像  $d=3$ 。假设  $C$  是图像域  $\Omega$  的边界。对于图像中的每一像素点  $x \in \Omega$ , 定义下列局部能量函数:

$$\begin{aligned} \mathcal{E}^K(f_1, f_2, C) = & \lambda_1 \int_{\text{in}(C)} \omega(x-y) \|\Psi(I(y)) - \Psi(f_1(x))\|^2 dy + \\ & \lambda_2 \int_{\text{out}(C)} \omega(x-y) \|\Psi(I(y)) - \Psi(f_2(x))\|^2 dy \end{aligned} \quad (4)$$

其中,  $\omega(x)$  为窗口函数, 采用如下形式:

$$\omega(x) = \frac{1}{2\pi\sigma^2} e^{-x^2/2\sigma^2} \quad (5)$$

这样, 当  $y$  在  $x$  附近时,  $\omega(x-y)$  取得较大值, 而  $y$  远离  $x$  时,  $\omega(x-y)$  值趋向于零。这就导致了  $x$  附近的像素点  $y$  对局部能量  $\mathcal{E}^K(f_1, f_2, C)$  起主导作用, 而远离  $x$  的像素点作用几乎可以忽略不计。因此,  $\omega(x-y)$  将局部能量式(4)定位在以  $x$  为中心的局部区域内。

在局部能量式(4)中,  $f_1(x)$  和  $f_2(x)$  分别为点  $x$  邻域的局部拟合中心;  $\Psi(\cdot)$  为映射函数;  $\|\Psi(I(y)) - \Psi(f_i(x))\|^2$  为像素点  $I(y)$  与局部拟合中心  $f_i(x)$  之间的核特征距离, 该核特征距离可以表示为

$$\begin{aligned} & \|\Psi(I(y)) - \Psi(f_i(x))\|^2 = \\ & K(I(y), I(y)) + K(f_i(x), f_i(x)) - 2K(I(y), f_i(x)) \end{aligned} \quad (6)$$

其中:  $K(x, y) = \Psi(x) \Psi(y)^T$  为核特征函数。本文选用高斯核特征函数, 形式为

$$K(x, y) = \exp\left(-\frac{\|x-y\|^2}{\sigma^2}\right) \quad (7)$$

由式(7)可知,  $K(I(y), I(y)) = K(f_i(x), f_i(x)) = 1$ , 则像素点  $I(y)$  和局部拟合中心  $f_i(x)$  之间的核特征距离式(7)可写成

$$\|\Psi(I(y)) - \Psi(f_i(x))\|^2 = 2(1 - K(I(y), f_i(x))) \quad (8)$$

因此, 局部能量函数式(4)可以表示为

$$\begin{aligned} \mathcal{E}^K(f_1, f_2, C) = & \lambda_1 \int_{\text{in}(C)} \omega(x-y) (1 - K(I(y), f_1(x))) dy + \\ & \lambda_2 \int_{\text{out}(C)} \omega(x-y) (1 - K(I(y), f_2(x))) dy \end{aligned} \quad (9)$$

显然, 对于每个点  $x$ , 当轮廓  $C$  准确地定位在目标边界时, 局部能量  $\mathcal{E}^K(f_1, f_2, C)$  获得最小值。但局部能量  $\mathcal{E}^K(f_1, f_2, C)$  仅定义在以点  $x$  为中心的局部区域上, 为了找到整个图像的目标边界, 必须对图像域  $\Omega$  上所有点  $x$  的局部能量  $\mathcal{E}^K(f_1, f_2, C)$  最小化。因此, 本文定义了下面的总能量函数:

$$E^K(f_1, f_2, C) = \int_{\Omega} \mathcal{E}^K(f_1(x), f_2(x), C) dx \quad (10)$$

### 2.2 能量最小化

为了最小化总能量函数式(10), 通常采用水平集方法, 为此引入水平集函数  $\varphi(x)$ , 能量函数式(10)可以表示为

$$\begin{aligned} E^K(f_1, f_2, C) = & \int_{\Omega} \mathcal{E}^K(f_1(x), f_2(x), C) dx = \\ & \lambda_1 \int [\omega(x-y) (1 - K(I(y), f_1(x))) H(\varphi)] dy dx + \\ & \lambda_2 \int [\omega(x-y) (1 - K(I(y), f_2(x))) (1 - H(\varphi))] dy dx \end{aligned} \quad (11)$$

其中:  $H(\varphi)$  为 Heaviside 函数。为了提高曲线演化速度, 加入无须重新初始化的水平集演化正则项:

$$\rho(\varphi) = \int \frac{1}{2} (|\nabla \varphi(x)| - 1)^2 dx \quad (12)$$

同时加入零水平集的长度约束项:

$$\ell(\varphi) = \int \delta(\varphi(x)) |\nabla \varphi(x)| dx \quad (13)$$

最终, 得到本文模型能量方程为

$$\Gamma(f_1, f_2, C) = E^K(f_1, f_2, C) + \mu \rho(\varphi) + \nu \ell(\varphi) \quad (14)$$

其中,  $\mu$  和  $\nu$  为非负常数。

根据变分法原理, 最小化能量方程式(14), 可以得到  $f_1$  和  $f_2$  的最优表达式:

$$f_1(x) = \frac{\omega(x) * [K(I(x), f_1(x)) I(x) H(\varphi(x))]}{\omega(x) * [K(I(x), f_1(x)) H(\varphi(x))]} \quad (15)$$

$$f_2(x) = \frac{\omega(x) * [K(I(x), f_1(x)) I(x) (1 - H(\varphi(x)))]}{\omega(x) * [K(I(x), f_1(x)) (1 - H(\varphi(x)))]} \quad (16)$$

采用梯度下降流, 可以得到  $\varphi$  的演化方程:

$$\begin{aligned} \frac{\partial \varphi}{\partial t} = & \mu (\nabla^2 \varphi - \text{div}(\frac{\nabla \varphi}{|\nabla \varphi|})) + \nu \delta_{\varepsilon}(\varphi) \text{div}(\frac{\nabla \varphi}{|\nabla \varphi|}) + \\ & \delta_{\varepsilon}(\varphi) [-\lambda_1 \int \omega(y-x) (1 - K(I(x), f_1(x))) dy + \\ & \lambda_2 \int \omega(y-x) (1 - K(I(x), f_2(x))) dy] \end{aligned} \quad (17)$$

### 2.3 本文模型的优点

本文模型使用核特征距离, 从而有效地提高了分割的精度。从式(15)(16)可以看出, 本文模型的局部拟合中心  $f_i(x)$  受到权重因子  $K(I(x), f_i(x))$  的影响。当点  $x$  的灰度值  $I(x)$  与局部拟合中心  $f_i(x)$  相似度越大, 权重因子  $K(I(x), f_i(x))$  的值就越大, 于是该点对局部拟合中心计算的影响就越大。经过这样的加权计算后, 得出的拟合中心会更加准确, 因此本文模型具有较好的分割精度。

本文模型的另外一个优点是分割效率大大提升, 如式(17)所示, 在进行水平集函数  $\varphi(x)$  的演化时, 本文模型使用的是指数函数  $1 - K(I(x), f_i(x)) = 1 - \exp(-\frac{\|I(x) - f_i(x)\|^2}{\sigma^2})$ , 相比大多数活动轮廓模型(如 LBF 模型)的线性函数  $\|I(x) - f_i(x)\|^2$ , 指数函数变化得更快, 因此, 本文模型收敛速度较快, 可以实现较高的分割速度。

## 3 实验与分析

仿真实验的硬件环境为联想 T400 笔记本电脑 (Intel Core™ 2 Duo processor, 2.53 GHz, 2 GB RAM); 软件环境为 Windows XP SP3 操作系统, MATLAB 7.0 编程平台。

图1(a)所示为一幅大小为  $127 \times 96$  的图像, 该图像存在较强的灰度不均匀现象, 图中左下部区域较亮而右半部区域较暗。图1(a)为初始化方式, (b)~(d)分别为经过20次、40次和60次迭代后的分割结果。从最终的分割结果来看, 本文方法获得了较为理想的分割效果, 如图1(d)所示。




图1 灰度不均匀图像的分割结果

为了和其他模型的分割效果进行比较,本文选用了三幅噪声水平 3%、灰度不均匀性 40% 的 MRI 脑图像。这些图像取自 McGill 大学 Montreal 神经学研究所大脑成像中心的 Brain Web 仿真脑部 MR 图像数据库<sup>[10]</sup>。该数据库同时提供真实的分割结果。图 2 的第一列分别显示了三个不同轴向的脑图像,第二列显示了 LBF 模型的分割结果,第三列显示了本文模型的分割结果。为了更准确地表示各个模型的分割结果,本文采用了 DSC 指标<sup>[11]</sup>来衡量分割精度,DSC 指标的定义如下:

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

(18)

其中: $S_1$  和  $S_2$  分别代表分割结果和真实结果, $N(\cdot)$  为像素的个数。DSC 指标值越趋近于 1,表明分割精度越高。表 1 显示了图 2 中三幅图像经过 LBF 模型和本文模型分割后的 DSC 指标值。可以看出,本文模型的分割精度要好于 LBF 模型。




图 2 本文方法和 LBF 模型的比较

表 1 LBF 模型和本文模型的分割精度

| 图像 | 组织 | LBF 模型/% | 本文模型/% |
|----|----|----------|--------|
| 1  | 白质 | 85.04    | 89.34  |
|    | 灰质 | 87.18    | 90.29  |
| 2  | 白质 | 84.96    | 88.04  |
|    | 灰质 | 87.79    | 89.25  |
| 3  | 白质 | 89.13    | 92.96  |
|    | 灰质 | 90.72    | 93.39  |

在表 2 中,对比了图 2 中三幅图像采用本文模型和 LBF 模型的分割时间。可以看出,本文方法的分割速度有了显著的提升。

表 2 LBF 模型和本文模型的处理时间

| 图像        | LBF 模型分割时间/s | 本文模型分割时间/s |
|-----------|--------------|------------|
| 图 2 第一行图像 | 68.80        | 55.57      |
| 图 2 第二行图像 | 97.37        | 71.39      |
| 图 2 第三行图像 | 62.38        | 43.79      |

4 结束语

本文提出了一种新的基于核特征距离的变分模型。该模型使用核特征距离来构造局部拟合能量,由于在模型中嵌入了图像的局部信息,所以可以克服灰度不均匀性带来的分割困难;并且在模型中加入了水平集正则项,因此在水平集的演化过程中不需要重新初始化。实验结果表明,与 LBF 模型相比,本文模型的分割精度更高、分割速度更快。

参考文献:

[1] CASELLES V, KIMMEL R, SAPIRO G. Geodesic active contours[J]. *Int'l J Comp Vis*, 1997, 22(1): 61-79.

[2] COHEN L, COHEN I. Finite-element methods for active contour models and balloons for 2-D and 3-D images[J]. *IEEE Trans on Patt Anal Mach Intell*, 1993, 15(11): 1131-1147.

[3] 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 on Imag Proc*, 2001, 10(8): 1169-1186.

[4] PARAGIOS N, DERICHE R. Geodesic active regions and level set methods for supervised texture segmentation[J]. *Int'l J Comp Vis*, 2002, 46(3): 223-247.

[5] CHAN T, VESE L. Active contours without edges[J]. *IEEE Trans on Imag Proc*, 2001, 10(2): 266-277.

[6] LI Chun-ming, KAO C-K, GORE J C, *et al*. Implicit active contours driven by local binary fitting energy [C]//*Proc of IEEE International Conference on Computer Vision and Pattern Recognition*. Minneapolis: IEEE, 2007: 339-345.

[7] 王利, 陈允杰, 韦志辉, 等. 克服灰度不均匀性的脑 MR 图像分割模型[J]. *计算机辅助设计与图形学学报*, 2009, 21(11): 1624-1631.

[8] WANG Li, LI Chun-ming, SUN Quan-sen, *et al*. Active contours driven by local and global intensity fitting energy with application to brain MR image segmentation[J]. *Computerized Medical Imaging and Graphics*, 2009, 33(7): 520-531.

[9] WANG Xiao-feng, HUANG De-shuang, XU Huan. An efficient local Chan-Vese model for image segmentation[J]. *Pattern Recognition*, 2010, 43(3): 603-618.

[10] <http://www.bic.mni.mcgill.ca/brainweb/> [EB/OL].

[11] SHATTUCK D W, SANDOR-LEAHY S R, SCHAPER K A, *et al*. Magnetic resonance image tissue classification using a partial volume model[J]. *Neuroimage*, 2001, 13(5): 856-876.