

文章编号:1001-9081(2008)09-2288-04

结合聚类和改进的 C-V 演化方程在医学图像分割中的应用

罗志宏^{1,2}, 冯国灿², 成秋生³

(1. 中山大学 计算机科学系, 广州 510275; 2. 中山大学 数学与计算科学学院, 广州 510275;

3. 广州市第一人民医院 脑内科, 广州 510180)

(luozhmail@126.com)

摘要:在传统的 C-V 模型的基础上提出一类改进的 C-V 演化方程, 利用它们与聚类技术相结合对病理状态脑部 CT 和 MR 图像进行分割, 能获得较理想的实验结果。特别是利用提出的演化方程对一个合成的几何图像进行分割, 结果显示能比一些传统的演化方程具有更好的稳健性和准确性。

关键词:活动轮廓模型; 水平集; 图像分割; *k*-means 聚类

中图分类号: TP391.41 **文献标志码:** A

Application of clustering and improved C-V evolution equation in medical image segmentation

LUO Zhi-hong^{1,2}, FENG Guo-can², CHENG Qiu-sheng³

(1. Department of Computer Science, Sun Yat-Sen University, Guangzhou Guangdong 510275, China;

2. School of Mathematics and Computational Sciences, Sun Yat-Sen University, Guangzhou Guangdong 510275, China;

3. Department of Neurology, the First Municipal People's Hospital of Guangzhou City, Guangzhou Guangdong 510180, China)

Abstract: A class of improved C-V evolution equation based on classical C-V model was proposed in this paper. It integrated with *k*-means clustering to segment pathological tissue of Brain CT and MRI, and satisfactory results were obtained. Specially, experimental result of a synthetic image shows that the proposed method is more accurate and robust than some traditional evolution equations.

Key words: active contour model; level set; image segmentation; *k*-means clustering

0 引言

近十几年来, 基于偏微分方程 (Partial Differential Equation, PDE) 的图像处理技术在图像处理与分析这个领域得到了广泛的重视。源于变分方法和活动轮廓模型的 PDE 方法已经成为图像处理与分析中的一个重要工具。活动轮廓模型的基本思想是在图像域中构建一条初始曲线 (曲面), 该曲线 (曲面) 在内力和外力作用下向着目标边界演化变形, 在达到被检测目标边界时停止变形。活动轮廓模型与水平集方法相结合, 广泛地应用于图像分割和检测、图像平滑、运动分割以及运动目标跟踪, 立体视觉和图像的修复^[1]。

医学中的 CT 和 MR 图像分割是提取图像中特殊组织和病变组织的定量信息的不可缺少的手段。由于脑内各组织之间的边缘混迭, 以及脑部 CT 图像和 MRI 的复杂性, 所以, 将脑部 CT 图像和 MRI 中的病变部位进行精确可靠的分割是现代医学处理的难点和热点之一。至今, 对医学图像分割已有多种方法, 也取得了大量的研究成果。其中, 活动轮廓模型方法在医学图像分割中取得了相当的成功, 已成为医学图像分割的主流方法之一^[2]。K 均值聚类技术也是一种图像分割的重要方法, 将活动轮廓模型方法与 K 均值聚类技术相结合可使它们的优势互补。本文使用改进的 C-V 演化方程与 K 均值聚类技术相结合对一批病理状态脑部 CT 图像和 MRI 进行分

割, 能获得较好的效果。特别是, 利用本文提出的演化方程对一个合成的图像进行分割实验, 与文献[3]中提出的模型和无需重新初始化的 C-V 模型进行分割实验的结果作比较, 说明本文提出的演化方程对图像分割是有效的且有一定的优势。

1 C-V 模型及其演化方程

2001 年, 文献[5]针对 M-S 模型^[4]的缺陷提出一种简化的 M-S 模型, 通称为 C-V 模型。设原图像 $I(x, y)$ 被活动轮廓线 C 划分为目标 ω_o 和背景 ω_b 两个区域, 各个区域的平均灰度为 C_1 和 C_2 ; $\lambda_1, \lambda_2 > 0, \mu \geq 0, \nu$ 都是常数; $u(x, y)$ 为内正外负的水平集函数, Ω 是水平集函数的定义域; $H(z)$ 是 Heaviside 函数, $\delta(z)$ 是 Dirac 函数, $\delta(z) = H'(z)$ 是 $H(z)$ 在分布意义下的导数。C-V 模型以水平集函数表达为:

$$E(u, C_1, C_2) = \mu \int_{\Omega} \delta(u) |\nabla u| dx dy + \nu \int_{\Omega} H(u) dx dy + \lambda_1 \int_{\Omega} |I - C_1|^2 H(u) dx dy + \lambda_2 \int_{\Omega} |I - C_2|^2 (1 - H(u)) dx dy \quad (1)$$

右端第一项 (活动轮廓线 C 的长度) 是正则化项, 第二项 (C 的内部区域面积) 由参数 ν 的符号选择不同可控制轮廓线

收稿日期: 2008-04-15; 修回日期: 2008-06-10。

基金项目: 国家自然科学基金资助项目 (60675007); 教育部重点基金资助项目 (104145)。

作者简介: 罗志宏 (1970-), 女, 广西桂林人, 讲师, 博士研究生, 主要研究方向: 图像处理、模式识别; 冯国灿 (1962-), 男, 湖北孝感人, 教授, 博士生导师, 主要研究方向: 图像处理、模式识别、计算机视觉; 成秋生 (1963-), 男, 湖南衡阳人, 副主任医师, 硕士, 主要研究方向: 脑血管疾病。

向内收缩或向外膨胀,最后两项是拟合能量。

在具体实验中,需要将 Heaviside 函数正则化为 $H_\varepsilon(u)$, 在本文中取:

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

$$\delta_\varepsilon(u) = H'_\varepsilon(u) = \frac{\varepsilon}{\pi(\varepsilon^2 + u^2)} \quad (3)$$

正则化后的 C-V 模型为:

$$E_\varepsilon(u, C_1, C_2) = \mu \int_{\Omega} \delta_\varepsilon(u) |\nabla u| \, dx dy + \nu \int_{\Omega} H_\varepsilon(u) \, dx dy + \lambda_1 \int_{\Omega} |I - C_1|^2 H_\varepsilon(u) \, dx dy + \lambda_2 \int_{\Omega} |I - C_2|^2 (1 - H_\varepsilon(u)) \, dx dy \quad (4)$$

于是,利用负梯度流方法,得对应的演化方程组为:

$$C_1(u) = \frac{\int_{\Omega} I(x,y) H_\varepsilon(u) \, dx dy}{\int_{\Omega} H_\varepsilon(u) \, dx dy} \quad (5)$$

$$C_2(u) = \frac{\int_{\Omega} I(x,y) [1 - H_\varepsilon(u)] \, dx dy}{\int_{\Omega} [1 - H_\varepsilon(u)] \, dx dy} \quad (6)$$

$$\frac{\partial u}{\partial t} = \delta_\varepsilon(u) \left\{ \mu \cdot \operatorname{div}\left(\frac{\nabla u}{|\nabla u|}\right) - \nu - \lambda_1 [I(x,y) - C_1]^2 + \lambda_2 [I(x,y) - C_2]^2 \right\} \text{ 在 } (0, \infty) \times \Omega \text{ 内} \quad (7)$$

$$\frac{\delta_\varepsilon(u)}{|\nabla u|} \frac{\partial u}{\partial n} = 0 \text{ 在 } \partial\Omega \text{ 上} \quad (8)$$

纵观活动轮廓模型的发展历程,归结起来主要是考虑如何建立新模型^[4-8],或对演化方程做改进^[1,9],或对数值算法作修正^[1,5-6,10]。

2 改进的 C-V 模型及其演化方程

C-V 模型的一个非常显著特点是全局优化,因此仅用一条初始闭合轮廓线就能把含有内部空洞的目标的内、外部边界全部检测出来。但是,C-V 模型也存在一些明显的不足,例如,每迭代几步需要对水平集函数重新初始化。对此,文献[3]给能量泛函添加一个惩罚能量项,用以控制演化中的水平集函数与符号距离函数的偏差。

2.1 无需重新初始化的 C-V 模型

由符号距离函数的构造可知,一个函数 $u(x,y)$ 是距离函数的充要条件是 $|\nabla u| = 1$ 。文献[3]利用符号距离函数的这个性质,定义惩罚能量为: $P(u) = \int_{\Omega} \frac{1}{2} (|\nabla u| - 1)^2 \, dx dy$, 并考虑如下的能量泛函:

$$E(u) = \alpha \int_{\Omega} \frac{1}{2} (|\nabla u| - 1)^2 \, dx dy + \mu \int_{\Omega} g(x,y) \delta(u) |\nabla u| \, dx dy + \nu \int_{\Omega} g(x,y) H(-u) \, dx dy \quad (9)$$

其中: $\alpha > 0, \mu > 0, \nu$ 都是常数; $g(x,y)$ 是边缘停止函数,定义为: $g = 1/(1 + |\nabla(G_\sigma \cdot I)|^2)$ 。

该能量泛函正则化后,利用负梯度流方法,得到对应的演化方程组为:

$$\frac{\partial u}{\partial t} = \alpha \left[\nabla^2 u - \operatorname{div}\left(\frac{\nabla u}{|\nabla u|}\right) \right] + \delta_\varepsilon(u) \left\{ \mu \cdot \operatorname{div}\left(g \frac{\nabla u}{|\nabla u|}\right) + \nu \cdot g \right\} \text{ 在 } (0, \infty) \times \Omega \text{ 内} \quad (10)$$

$$\frac{\delta_\varepsilon(u)}{|\nabla u|} \frac{\partial u}{\partial n} = 0 \text{ 在 } \partial\Omega \text{ 上} \quad (11)$$

而如果在 C-V 模型中添加惩罚能量项,可得到对应的 C-V 演化方程:

$$\frac{\partial u}{\partial t} = \alpha \left[\nabla^2 u - \operatorname{div}\left(\frac{\nabla u}{|\nabla u|}\right) \right] + \delta_\varepsilon(u) \left\{ \mu \cdot \operatorname{div}\left(\frac{\nabla u}{|\nabla u|}\right) + \nu \right\} + \delta_\varepsilon(u) \left\{ \lambda_2 [I(x,y) - C_2]^2 - \lambda_1 [I(x,y) - C_1]^2 \right\} \quad (12)$$

2.2 改进的 C-V 演化方程

在 C-V 模型中,前两项是计算活动轮廓线的长度和活动轮廓线所围内部区域面积的总和,它们的主要作用是保持轮廓线在演化过程中的光滑性,而后两项中的 C_1 和 C_2 是计算轮廓线的内部区域和外部区域总的灰度均值,是背景和目标的区域信息,它们在该能量泛函中起主导作用,是轮廓线演化的主要驱动力。据此,本文考虑加重 C_1, C_2 的影响,提出如下改进的 C-V 演化方程:

$$\frac{\partial u}{\partial t} = \alpha \left[\nabla^2 u - \operatorname{div}\left(\frac{\nabla u}{|\nabla u|}\right) \right] + \delta_\varepsilon(u) \left\{ \mu \cdot \operatorname{div}\left(g \frac{\nabla u}{|\nabla u|}\right) + \nu \cdot g + (C_2 - C_1)^2 [\lambda_2 (I - C_2)^2 - \lambda_1 (I - C_1)^2] \right\} \quad (13)$$

本文还提出下列改进的演化方程:

$$\frac{\partial u}{\partial t} = \alpha \left[\nabla^2 u - \operatorname{div}\left(\frac{\nabla u}{|\nabla u|}\right) \right] + \delta_\varepsilon(u) \left\{ \mu \cdot \operatorname{div}\left(g \frac{\nabla u}{|\nabla u|}\right) + (C_2 - C_1)^2 [\lambda_2 (I - C_2)^2 - \lambda_1 (I - C_1)^2] \right\} \quad (14)$$

以及:

$$\frac{\partial u}{\partial t} = \alpha \left[\nabla^2 u - \operatorname{div}\left(\frac{\nabla u}{|\nabla u|}\right) \right] + \delta_\varepsilon(u) \left\{ \nu \cdot g + (C_2 - C_1)^2 [\lambda_2 (I - C_2)^2 - \lambda_1 (I - C_1)^2] \right\} + \mu \cdot \operatorname{div}\left(g \frac{\nabla u}{|\nabla u|}\right) \quad (15)$$

$$\frac{\partial u}{\partial t} = \alpha \left[\nabla^2 u - \operatorname{div}\left(\frac{\nabla u}{|\nabla u|}\right) \right] + \delta_\varepsilon(u) \left\{ \nu \cdot g + (C_2 - C_1)^2 [\lambda_2 (I - C_2)^2 - \lambda_1 (I - C_1)^2] \right\} \quad (16)$$

3 结合聚类与本文提出的方程的分割方法

3.1 K 均值聚类技术简介^[11]

K 均值聚类是一种动态聚类算法,算法把 n 个对象分为 k 类,以使类内具有较高的相似度,而类间的相似度较低。设待聚类的数据集为 $X = \{x_1, x_2, \dots, x_n\}$, 要找 X 的一个划分 $P_k = \{w_1, w_2, \dots, w_k\}$, 使得目标函数 $J = \sum_{i=1}^k \sum_{x_j \in w_i} \|x_j - w_i\|$ 最小, 聚类迭代次数为 t , 算法如下。

1) 随机选取 k 个样本点(可以取前 k 个样本点)作为 k 个初始聚类中心 $m_1(1), m_2(1), \dots, m_k(1), t = 1$ 。

2) 计算每个数据到这 k 个聚类中心的距离,并将各数据划分到具有最小距离的类中。即 $d(X, m_j(t)) = \min d(X, m_i(t)), i = 1, 2, \dots, k, d(X, m_j(t))$ 表示 X 到 m_j 的距离(第 t 次迭代)。

3) 重新计算聚类中心, $m_i(t+1) = \frac{1}{N_i} \sum_{x \in w_j} X(i = 1, 2,$

..., k)。

4) 检查聚类是否应结束, 若存在任一 $i \in \{1, 2, \dots, k\}$, 有 $m_i(t+1) \neq m_i(t)$, 则 $t = t + 1$, 转 2); 否则聚类结束。

K 均值聚类用于图像分割是将图像中像素点看成数据集的样本点, 像素点的灰度看成样本点的特征属性, 对每类像素进行标定, 从而实现图像分割。

3.2 本文方法的分割步骤

为简便, 下面将 K 聚类技术与本文提出的式(14~16)相结合的方法, 简称为本文方法。由于采用 K 聚类技术进行图像分割的结果能较好地体现图像的全局特征, 但在对图像的局部细节的处理能力上稍显不足; 而采用本文提出的方程进行图像分割能使边界具有较好的连续性和平滑性, 能较好地处理图像的局部细节。因此, 采用本文方法进行图像分割会使两者的优势互补, 提高分割的效果。本文方法分两步进行: 首先用 K 均值聚类技术作初分割, 提取感兴趣的病变区域, 但所得到的分割图还包含了除病变区域的其他组织和孤立点, 然后采用本文提出的式(14~16)进行分割, 能去除一些非病变组织, 修正初分割的结果。

4 实验结果与分析

我们的实验环境是 CPU 为 P4 2.8 GHz, 内存为 512 MB, 操作系统为 Windows XP, 所用程序的初始轮廓线为完全包含目标的正方形。

4.1 本文方法与 C-V 方法的分割结果

我们采用本文方法对一批病理状态脑部 MRI 和 CT 图像做过分割实验, 限于篇幅, 下面仅代表性选取其中一部分, 并将采用本文方法与 C-V 方法(即方程(12))进行分割的结果相比较。由于 MRI 中非脑组织(头皮、颅骨、肌肉等)中的一些成分的灰度信号与脑组织灰度信号非常接近, 会影响脑分割算法的精度。因此, 本文采用的脑病变图像已先去除其外围组织, 只保留脑组织。所用的参数为: $\alpha = 0.001, \varepsilon = 5, \mu = 1.5, \nu = 1, \lambda_1 = 1, \lambda_2 = 1.65$ 。

图 1(a)和图 1(b)分别是采用本文方法与 C-V 方法对脑梗死患者的 MR-T₁ 加权图像迭代 5 次分割的结果。从图 1(a)可清晰看到, 活动轮廓线已将患者的脑左半球中的梗死后的水肿区相当好地分割出来了, 甚至继续迭代 100 次(图 1(c))也只是使初分割的结果更精确; 但用 C-V 方法继续迭代(图 1(d))轮廓线就会越入病变区域不停地向内收缩。




图 1 不同方法对脑梗死患者 MR 图像分割的结果

图 2、3 分别是采用本文方法对脑胶质瘤患者的 MR-T₁

flair 图像和脑出血患者的 CT 图像分割的结果。从图 2(a)中能看到活动轮廓线已明显地分割出患者的脑胶质瘤。而图 3(a)也清晰地显示了活动轮廓线准确地分割出患者的脑左半球中的出血块。迭代 100 次的图 2(b)和图 3(b)都只是使初分割的结果更精确而已。




图 2 用本文方法对脑胶质瘤 MRI 分割的结果




图 3 用本文方法对脑出血患者 CT 分割的结果

4.2 本文提出的方程与传统的方程的分割结果比较

为了便于更明显评价本文提出的演化方程的有效性和准确性, 在此我们以一个合成的几何图像作为实验对象, 采用本文提出的一个演化方程与传统的演化方程对其分割作比较。

图 4 是由三个边缘呈锯齿状、形状为白色的有凹陷板块和灰色的圆环形板块以及黑色的三角形板块合成的图像, 利用不同的演化方程进行分割的结果。图 4(a)和图 4(b)分别是采用演化方程(13)和(12)迭代 10 次的分割结果, 其中所用参数 $\alpha = 0.0001, \varepsilon = 1.5, \mu = 5, \nu = 1.5, \lambda_1 = 1, \lambda_2 = 0.28128$, 时间步长为 5, 空间步长为 1; 图 4(c)是采用演化方程(1)迭代 500 次的分割结果, 其中权系数 $\alpha, \varepsilon, \mu, \nu$ 都与演化方程(3)的相同。在演化的过程中, 每迭代 10 次显示分割结果, 图 4(a)耗时 1.3125 s, 图 4(b)耗时 1.375 s, 图 4(c)耗时 74.2813 s。




图 4(a) 用方程(13)迭代 10 次分割的结果 (b) 用方程(12)迭代 10 次分割的结果




图 4(b) 用方程(11)迭代 500 次分割的结果

图 4 用方程(11~13)对一个合成图像分割的结果比较

从中明显看到, 图 4(c)中的活动轮廓线有一部分刚收缩到目标的边缘, 而另一部分却已越入目标的边缘或还未收缩到目标的边缘, 且不能同时分割圆环形板块的内部和外部的边缘, 效果很差; 图 4(a)和图 4(b)在相同的条件下进行分割, 结果是采用本文提出的演化方程(13)(图 4(a))比传统

的演化方程(12)(图4(b))效果更好。另外,从表1列出的关于活动轮廓线的内、外区域的灰度均值也可看出,采用本文提出的演化方程(13)比传统的演化方程(12)驱动轮廓线能更快、更好地贴近目标的边缘。

表1 采用方程(12)和(13)演化轮廓线的内外区域的灰度均值

迭代次数	采用演化方程(12)		采用演化方程(13)	
	C_1	C_2	C_1	C_2
1	148.5514	141.8864	148.5514	141.8864
2	155.9592	140.3634	155.9718	136.1715
3	155.9894	110.8392	155.9987	101.4999
8	155.9916	103.1916	156.0002	101.2059
9	155.9916	103.1294	156.0002	101.2056
10	155.9916	103.0748	156.0002	101.2053

5 结语

医学图像中组织结构复杂,各组织之间的边缘混迭,采用一些传统的分割方法难以达到良好的分割效果。本文在传统的C-V模型的基础上提出几个改进的C-V演化方程,利用它们与K聚类技术相结合对一批脑病患者的MR图像和CT图像进行分割,获得了较理想的实验结果。为了便于评价本文提出的水平集演化方程的有效性和准确性,用本文提出的一个方程对一个合成的几何图像做实验,分割的结果明显优于一些传统的分割模型。实验表明,选择适当的权系数对减少活动轮廓线贴近目标边缘的迭代次数和提高精确度有很大的影响,但是用本文提出的改进的演化方程可以使权系数在较大的范围内选取。例如,对于本文提出的演化方程(13),选取 $\varepsilon = 3, \alpha = 0.00001, \lambda_1 = 1, \lambda_2 = 0.5504, \nu = 4, -120 < \mu < 165$ 这样的权系数组合也能获得很好的分割结果。

(上接第2287页)

辨率为 1152×256 ,操作内容与4.3节相同,采用 64×64 分块、数据按照UYVY交叉格式组织,读写和展开用时仅需要7.8 ms/帧,比较表2中相同展开条件的结果快约30%。

4.5 更高分辨率全景图像展开

原始图像分辨率为 2048×1536 ,目标图像分辨率为 2560×576 ,操作内容与4.3节相同,YUV数据按照UYVY交叉格式组织,采用 64×64 分块,块读写和全景展开共计41 ms/帧,即每秒24帧,达到实时要求。

5 结语

分块预取方法基于全景图像查表展开法,利用DSP性能特点,将查找表分块和原始图像分块通过二维DMA操作预先取入DSP片内存储器完成展开,降低存取访问开销,加快查表展开。在下一步研究中,将研究对全景展开图像进行平滑运算从而进一步提高展开后全景图像的质量,还将研究在全景展开时进一步节省查找表空间的方法。

参考文献:

[1] 曾吉勇.折反射全景立体成像[D].成都:四川大学,2003.
 [2] 张茂军,徐玮,王伟,等.二次凸曲面反射成像的实景空间构造方法及装置:中国,200510031552.XI[P],2005.
 [3] ARGYROS A A, BEKRIS C, ORPHANOUDAKIS S C, *et al.* Robot homing by exploiting panoramic vision[J]. Journal of Autonomous Robots, 2005, 19(1): 7-25.

参考文献:

[1] 杨新,李俊,杜啸晓.图像偏微分方程的原理与应用[M].上海:上海交通大学出版社,2003.
 [2] 田捷,包尚联,周成全.医学影像处理与分析[M].北京:电子工业出版社,2003.
 [3] LI C M, XU C Y, GUI C F, *et al.* Level set evolution without re-initialization: a new variational formulation[J]. Computer Vision and Pattern Recognition, 2005(1): 430-436.
 [4] MUMFORD D, SHAH J. Optimal approximations by piecewise smooth functions and associated variational problems[J]. Communications on Pure and Applied Mathematics, 1989, 42(5): 577-685.
 [5] CHAN T F, VESE L A. Active contours without edges[J]. IEEE Transactions on Image Processing, 2001, 10(2): 266-277.
 [6] KASS M, WITKIN A, TERZOPOULOS D. Snakes: Active contour models[J]. International Journal of Computer Vision, 1987, 1(4): 321-331.
 [7] COHEN L D. Note on active contour models and balloons[J]. CVGIP: Image understanding, 1991, 53(2): 211-218.
 [8] CASELLES V, KIMMEL R, SAPIRO G. A geodesic active contours[J]. International Journal of Computer Vision, 1997, 22(1): 61-79.
 [9] CASELLES V, CATTE F, COLL T, *et al.* A geometric model for active contours in image processing[J]. Numeric Mathematic, 1993, 66(1): 1-31.
 [10] COHEN L D, COHEN I. Finite-element methods for active contour models and balloons for 2-D and 3-D images[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1993, 15(11): 1131-1147.
 [11] 肖健华.智能模式识别方法[M].广州:华南理工大学出版社,2006.
 [4] SHUM H Y, HE L W. Rendering with concentric mosaics[C]// Proceedings of ACM SIGGRAPH. New York: ACM Press, 1999: 299-306.
 [5] 马建光.基于全向视觉的机器人定位和路径规划研究[D].北京:北京理工大学,2003.
 [6] GANDHI T, TRIVEDI M M. Parametric ego-motion estimation for vehicle surround analysis using an omni-directional camera[J]. Machine Vision and Applications, 2005, 16(2): 82-95.
 [7] SUN C, PELEG S. Fast panoramic stereo matching using cylindrical maximum surfaces[J]. IEEE Transactions on Systems, Part B, 2004, 34(2): 760-765.
 [8] SVOBODA T, PAJDLA T. Epipolar geometry for central catadioptric cameras[J]. Journal of Computer Vision, 2002, 49(1): 23-37.
 [9] 侯慧杰,白剑,杨国光.全景环形透镜三维空间成像展开算法的研究[J].光学仪器,2005,27(6): 43-47.
 [10] BENOSMAN R, KANG S B. Panoramic vision: Sensors, theory, and applications[M]. Berlin: Springer-Verlag Publisher Press, 2001.
 [11] 谭志刚.全景环形成像的嵌入式DSP处理研究[D].杭州:浙江大学,2005.
 [12] CHOI B-D, CHOI K-S, HWANG M-C, *et al.* Real-time DSP implementation of motion-JPEG2000 using overlapped block transferring and parallel-pass methods[J]. Real-Time Imaging, 2004, 10(5): 277-284.
 [13] 汪国有,谢励. DSP中如何利用高速缓存优化流媒体程序[J]. 计算机测量与控制, 2007, 15(3): 402-404.
 [14] TMS320C64x Technical Overview. Texas Instruments[R]. 2001.