



(12)发明专利

(10)授权公告号 CN 104504720 B

(45)授权公告日 2017.04.19

(21)申请号 201510006415.4

US 2010081931 A1, 2010.04.01,

(22)申请日 2015.01.07

CN 102737382 A, 2012.10.17,

(65)同一申请的已公布的文献号

审查员 刘海艳

申请公布号 CN 104504720 A

(43)申请公布日 2015.04.08

(73)专利权人 四川大学

地址 610065 四川省成都市武侯区一环路
南一段24号

(72)发明人 刘怡光 吴鹏飞 曹丽萍 罗以宁
詹洋

(51)Int.Cl.

G06T 7/11(2017.01)

A61B 8/00(2006.01)

(56)对比文件

CN 103295224 A, 2013.09.11,

权利要求书3页 说明书10页

(54)发明名称

一种新的前列腺超声图像分割方法

(57)摘要

本发明提供一种新的前列腺超声图像分割技术，在直肠超声检测(transrectal ultrasound, TRUS)图像中对前列腺进行准确分割。传统观点认为，TRUS图像的斑点会对目标分割造成强烈的副作用。与此不同，我们利用斑点的内在属性来简化分割问题。首先，斑点的大小和方向并非完全随机分布，而是服从一定的规律特性。为了利用斑点的方向特性，我们使用了旋转不变的Gabor特性来提取问题特征；为了利用斑点的大小尺度特性，我们把TRUS图像分成了许多条状窄带，在不同窄带内对图像像素进行不同的处理。最后，我们还考虑了不同像素间的相关性，并进一步通过这一特性使用图割(graph cut)方法提高了像素分类精度。以此为基础，我们通过水平集分割模型，最终得到了TRUS图像中前列腺的分割结果。

1. 一种新的前列腺超声图像分割方法,包括以下步骤:

第一步为特征提取和特征分类:

1) 利用旋转不变的Gabor特征提取纹理特征,设以超声探针为中心的圆弧,在 (x_c, y_c) 处的法向方向为 ϕ ,则可以由下式计算

$$\phi = \text{atan}2(x - x_c, y - y_c)$$

其中 (x_c, y_c) 为超声探针的中心,函数 $\text{atan}2: \mathbb{R}^2 \mapsto [0, 2\pi]$ 为带符号反正切函数,其符号根据其点所在的四个不同象限决定;通过圆弧法方向 ϕ ,在位置 (x_c, y_c) 处的旋转不变 Gabor 特征 $F_{g, i_s}(x, y)$ 可以由下式计算

$$F_{g, i_s}(x, y) = (1 - \beta)\hat{F}_{g, \psi-i_s}(x, y) + \beta\hat{F}_{g, \psi+i_s}(x, y)$$

其中 $i_s = \lfloor \phi / \psi \rfloor$, $\beta = \phi / \psi - i_s$; 注意到 $\lfloor x \rfloor$ 为下取整函数, $\psi = \pi/n$, 其中 n 为总共使用的旋转参数个数; 最后, 旋转不变特征向量 $F(x, y)$ 即由 $\{F_{g, i_s}(x, y)\}$ 为其元素构成;

2) 根据压缩感知(Compressive Sensing)理论, 针对每一个特征向量 F 和一组我们预先获得的字典 D , 只要使用字典 D 对向量 F 的表示系数 α 足够的稀疏, 则找到对 F 的稀疏表达的过程可以通过在原函数上附加 ℓ^1 范数约束来替代问题本身所提出的 ℓ^0 范数下的最小化问题, 此时, 该稀疏表达问题可以表示为

$$\min_{\alpha} \|F - D\alpha\|_2^2 + \tau \|\alpha\|_1$$

其中 τ 为拉格朗日乘数 (Lagrange multiplier); 我们使用上述稀疏表达的表示残差作为分类依据;

3) 基于超声图像的特征获得残差; 该特征认为, 超声斑点的大小随着其与超声探测中心的距离变化而变化; 我们在超声图像中建立了许多弧形带状窄条, 在这些窄带内, 各自都训练有各自的表示字典; 严格的, 对于图像上感兴趣的区域 (Region Of Interest, ROI) 内的每一个像素点 p , 它所属的窄条可以通过下式计算

$$i = \left\lfloor \frac{\|p - c\|_2}{w} \right\rfloor$$

其中 i 为窄带的索引, c 为探测棒的中心, w 为窄带的带宽; 每一个窄带内, 并非训练集内所有的像素都拿来训练字典集, 而是只有那些在图像中前列腺轮廓附近的像素才用来训练字典; 对于第 i 个窄带条内的像素 p , 设它的特征向量 F_p , 我们可以使用字典矩阵 $D_i = [D_i^1, D_i^2, D_i^3]$ 对其进行稀疏表示, 其中 D_i^1 , D_i^2 和 D_i^3 分别代表在第 i 个窄带中针对前列腺边界类, 前列腺边界内部类和前列腺边界外部类三个类训练的字典; 依据这三个字典, 像素 p 的表示残差可以由下式计算

$$r_k = \|F_p - D_i \delta_k(\alpha)\|_2^2, \quad k \in \{1, 2, 3\}$$

其中

$$\alpha = \arg \min_{\alpha} \|F_p - D_i \alpha\|_2^2 + \tau \|\alpha\|_1$$

$\delta_k(\alpha)$ 是这样一个函数, 它把 α 中所有跟 k 不是一类元素都设为零;

第二步为像素分类：

1) 在获得表示残差之后,取表示残差的负值,并把所有残差归一化到[0,1]区间作为该像素属于某一类的可能性的度量;使用如下能量函数通过图割(graph cut)来最终实现像素的分类

$$E = \sum_{p \in \Omega} R_p(k_p) + \mu \sum_{(p,q) \in \mathcal{N}} B(k_p, k_q)$$

μ 代表权重参数, Ω 为图像域, \mathcal{N} 为相邻像素的集合, $R_p(k_p)$ 为像素 p 属于 k 类处罚值, B 用来维持相邻像素间分类的平滑性,其公式为:

$$B(l, k) = \begin{cases} 0, & l = k \\ 1, & \text{其它} \end{cases}$$

$R_p(k_p)$ 将残差 E_p 规范到[0,1]区间;

第三步为基于水平集的分割:

1) 水平集分割模型基于能量最小化模型,其能量定义为

$$E = E_c + \alpha_t E_r$$

其中 α_t 为权重参数, E_c 即为定义的窄带对比度能量,而 E_r 为纹理能量;这两部分能量可以被严格地定义为

$$\begin{aligned} E_c &= -\iint_{\Omega} \tilde{H}(\Phi) I - \tilde{H}(-\Phi) I dA \\ E_r &= -\iint_{\Omega} \dot{H}(\Phi) l_e + \dot{H}(\Phi)(l_o - l_i) + \dot{H}(-\Phi)(l_i - l_o) dA \end{aligned}$$

其中 Ω 为图像域, I 为图像灰度, Φ 为符号距离函数(SDF);符号 l_e , l_i 和 l_o 表示像素分类结果,分别为前列腺边界类,前列腺边界内部类和前列腺边界外部类;一个像素如果被分类某一类,则该类对应的设为1,其它均被设为0;下面三个公式定义了模型边缘的窄带,用于提取信息,帮助分割:

$$\tilde{H}(\Phi) = \begin{cases} 1, & \text{if } 0 < \Phi \leq h; \\ 0, & \text{if } \Phi > h \text{ or } \Phi \leq 0; \end{cases}$$

$$\dot{H}(\Phi) = \begin{cases} 1, & \text{if } c < \Phi \leq h; \\ 0, & \text{if } \Phi > h \text{ or } \Phi \leq c; \end{cases}$$

$$\ddot{H}(\Phi) = \begin{cases} 1, & -c \leq \Phi \leq c; \\ 0, & \Phi > c \text{ or } \Phi < -c; \end{cases}$$

其中 h 和 c 为两个不同的带宽,且 $h > c$;

2) 直接使用梯度下降法对能量公式进行最小化求解;能量 E 的梯度为

$$\begin{aligned} \nabla E(w, p) &= -\iint_{\Omega} \nabla \tilde{H}(\Phi) I - \nabla \tilde{H}(-\Phi) I dA \\ &\quad - \alpha \iint_{\Omega} \nabla \dot{H}(\Phi) l_e + \nabla \dot{H}(\Phi)(l_o - l_i) + \nabla \dot{H}(-\Phi)(l_i - l_o) dA \end{aligned} \tag{1}$$

其中三个不同的H的梯度可以通过链式法则获得:

$$\nabla H(\Phi) = [\delta(\Phi - h_1) - \delta(\Phi - h_2)]\nabla\Phi \quad (2)$$

其中 $\delta(\cdot)$ 为狄拉克雷函数(Dirac Delta function);符号 $h_1, h_2 \in \{h, 0, c\}$ 代表模型边缘的窄带上下界,且 $h_1 < h_2$;综合上述(1)(2)式,可得:

$$\begin{aligned} \nabla E = & -2 \oint_{\Phi=h} \nabla\Phi I ds + \oint_{\Phi=c} \nabla\Phi [I + \alpha(l_e - l_i)] ds \\ & + \oint_{\Phi=0} \nabla\Phi [I - \alpha(l_i - l_o)] ds \\ & + \oint_{\Phi=c-e} \alpha \nabla\Phi (l_i - l_o - l_e) ds + \oint_{\Phi=c+e} \alpha \nabla\Phi (l_e - l_o + l_i) ds \end{aligned}$$

通过迭代求解 \mathbf{W} 和 \mathbf{P} ,可以实现对超声图像的分割;迭代过程为

$$\mathbf{w}^{t+1} = \mathbf{w}^t - \alpha_w \nabla_{\mathbf{w}} E$$

$$\mathbf{p}^{t+1} = \mathbf{p}^t - \alpha_p \nabla_{\mathbf{p}} E$$

其中 α_w 和 α_p 为步长参数, t 代表迭代次数。

一种新的前列腺超声图像分割方法

技术领域

[0001] 本发明涉及一种图像分割技术,特别是涉及前列腺超声图像分割技术,属于计算机图像处理领域。

背景技术

[0002] 在国内,已经有一些研究组对TRUS图像的分割进行了研究。早在2003年,东南大学罗立民教授就提出了一种超声波多尺度非线性的自适应边界检测方法。该方法首先对超声图像进行多尺度分解,然后用非线性软阈值法抑制斑点噪声之后用小波变换重建图像最后使用基于“窄条”的线性边界检测方法对已经降噪的图像进行处理。但由于区域增长过程的时间开销,其计算量较大。北京交通大学阮秋琦教授提出了一种提出了一种超声图像去噪与边缘增强算法:可以在去除噪声的同时,保持重要的边缘、局部细节和超声回声亮条。虽然对抑制噪声增强边界有较好的效果,但没有将其应用到对图像的分割和边缘检测中。由于超声图像信噪比低、斑点噪声强烈,上述单纯的图像增强与边缘检测方法难以取得较好的效果。

[0003] 研究人员致力于结合图像特点和领域知识,以期达到较为理想的分割效果。超声图像的纹理特性是人们在研究中使用的先验知识之一。人们也尝试了多种方法来利用该特征以帮助前列腺自动分割。此外,活动表现模型(Active Appearance Model)具有把纹理信息嵌入到形状模型中的特点,也展现出了在TRUS图像分割中的潜力。此外,局部二值模式(Local Binary Pattern)提取纹理特征也广泛应用到了超声图像分割中。2010年,哈尔滨工业大学唐降龙教授提出了一种结合全局概率密度差异与局部灰度拟合的主动轮廓模型对超声图像进行分割的方法。该方法分别在原始超声图像与预处理图像上利用了图像的全局和局部信息。在原始图像上,利用各区域的灰度分布,并结合超声图像的背景知识对图像的全局信息建模。上述方法都取得一定效果,然而它们均没有很好的利用超声图像有别于自然图像的一些固有特点,因此在实际应用中,其性能都受到一定限制。首先,前列腺超声图像中,斑点噪声的大小并非一成不变,而是随着其与超声探棒间的距离变化而变化。这一特性并没有在目前主流的特征提取算法中得到体现并加以利用。其次,超声图像中的斑点还拥有自身的角度,且角度并非随机分布,而呈现出一定规律性,因此,直接使用Gabor 滤波对于进行提取是不合适的。Shen等人的方法考虑到了Gabor滤波的旋转变化特性,但并没有进一步与斑点的旋转结合起来,因此其性能也受到一定限制。在2006年,Zhan等人也使用了Gabor 滤波,并将其扩展到了3D超声图像的分割中。

[0004] 另一个重要的先验知识是前列腺的形状特性。最初,前列腺的形状被视为超椭圆,通过对齐进行各种变换,来与目标轮廓拟合。英属哥伦比亚大学Badiel等人于2006年提出了一种需要人工初始化,使用超椭圆拟合来寻找前列腺边缘的方法。该种方法简单高效,对一般形状的前列腺有较好的效果,而对于形变比较严重,形状不规则的目标,则难以达到理想的效果。因此,一种更灵活的统计形状模型获得了研究人员较大的关注,并给出了较好的分割结果。然而,大多数方法假设前列腺形状模型服从高斯分布。2007 年,南京理工大学夏

德深教授提出了一种先验形状参数活动轮廓模型。该模型通过引入一种非距离性的先验形状力场，构建一种新的能反映先验形状的参数活动轮廓模型，新的先验形状活动轮廓模型避免了。曲线之间距离的计算，减少了模型的复杂性，同时可以很好的利用分割目标的先验形状信息。但是该模型在处理图像之前依然需要人工定义活动轮廓模型的初始曲线。飞利浦北美研究院Yang 等人于2010年提出了一种新的思路，使用部分活动轮廓模型(Partial Active Shape Models)来处理边界丢失的问题，使用在结合离散可形变模型(Discrete Deformable Model)进一步对分割结果求精。该方法使用未经预处理的图像，没有进一步挖掘图像中蕴含的信息(如纹理特性)。此外，该方法对目标形状的建模基于主成分分析(Principal Component Analysis)，只能去除训练集中不同维度的线性相关性，对于现实数据存在的普遍相关相关性难以彻底去除，故对于并不符合高斯分布的前列腺形状难以取得很好的效果。在水平集分割框架下结合形状模型的方法也面临类似的问题。如Tsai等人在中直接将主成分分析应用到向量化的曲面演化隐函数上，虽然取得了较好的效果，但是由于向量化的符号距离范数维度过高，模型的局限性更大。能够逼近任何分布的非参数核密度估计模型也被引入到医学图像分割领域，但目前这类方法由于没有很好地结合超声图像和临床应用本身的领域知识，因此大都需要人工干预初始化才能达到要求的精度，大大限制了其进一步应用和扩展。

[0005] 虽然非高斯分布的形状模型在许多医学图像分割领域取得了更优越的成果；同时，人们已经进行了许多研究，来把非高斯形状先验嵌入到已经被广泛采用的显示分割模型(如活动轮廓模型)和隐式分割模型(如水平集)中去。然而，很少有人专门针对超声图像使用这些非高斯形状先验。

发明内容

[0006] 本发明所要解决的技术问题是提供一种新的前列腺超声图像分割技术，在TRUS图像具有信噪比(signal-to-noise ratio, SNR)低，对比度低，斑点噪声强烈，伪影干扰和同一组织器官灰度分布异构性强和不同组织器官灰度分布具有同构性等特点的情况下，来解决TRUS图像自动分割问题。

[0007] 本发明的解决方案是：我们提出一个较为全面的分割框架，整合了(1)前列腺形状先验，(2)边界附近的灰度渐变特性和(3)前列腺斑点纹理特性。传统观点认为，TRUS图像的斑点会对目标分割造成强烈的副作用。与此不同，我们利用斑点的内在属性来简化分割问题。首先，根据我们的观测结果，斑点的大小和方向并非完全随机分布，而是服从一定的规律特性，这些斑点不一定有害，甚至可能可以给前列腺分割提供帮助。为了利用斑点的方向特性，我们使用了旋转不变的Gabor特性来提取问题特征；为了利用斑点的大小尺度特性，我们把TRUS图像分成了许多条状窄带，在不同窄带内对图像像素进行不同的处理。最后，我们还考虑了不同像素间的相关性，并进一步通过这一特性使用图割(graph cut)方法提高了像素分类精度。以此为基础，我们通过水平集分割模型，最终得到了TRUS 图像中前列腺的分割结果。

[0008] 本发明为实现上述解决方案，其方法步骤如下所示：

[0009] 1. 特征提取 Gabor 滤波是对超声图像进行纹理特征提取的常用方法。Gabor滤波可以被看作是角度和尺度可调整的边缘和线段检测器，并且可以通过设置不同的旋转和

缩放参数来提取不同频段的局部特征信息。二维的Gabor滤波器方程

$$[0010] \quad G(x, y) = \exp\left(-\frac{x'^2 + y'^2}{2\sigma^2}\right) \exp\left(i\left(2\pi\frac{x'}{\lambda} + \psi\right)\right) \quad (1)$$

[0011] 其中

$$[0012] \quad x' = x \cos \theta + y \sin \theta, \quad y' = -x \sin \theta + y \cos \theta, \quad (2)$$

[0013] λ 代表正弦函数的波长因子, θ 代表Gabor 函数的旋转方向, ψ 是相差, σ 表示高斯卷积的标准差, γ 是空间长宽比。传统Gabor滤波提取的特征向量可以用列向量 $\tilde{F}(x, y)$ 表示, 该向量中的每一个元素为 $\{\tilde{F}_{\theta_i, \lambda_j}(x, y)\}$, 它是通过使用旋转参数为 θ_i 和尺度参数的 λ_j 。Gabor函数与原图像在位置 (x, y) 处的卷积获得的。一般的, Gabor滤波簇的参数选择遵循在频域内各相邻滤波函数的频率响应的一半两两相邻原则。

[0014] 尽管Gabor滤波具有较强的提取纹理特征的能力, 但我们也看到, Gabor特征提取应该与斑点的旋转方向相适应。注意到Shen等人于2003年提出了旋转不变的Gabor特征提取方法, 虽然其出发点与我们不同, 但其旋转中心选择为超声探针, 与我们的需求一致, 故可以采用该方法并稍加改进, 以达到解决上述第一个斑点特性的目的。严格的, 设以超声探针为中心的圆弧, 在 (x, y) 处的法向方向为 ϕ , ϕ 则可以由下式计算

$$[0015] \quad \phi = \text{atan2}(x - x_c, y - y_c) \quad (3)$$

[0016] 其中 (x_c, y_c) 为超声探针的中心, 函数 $\text{atan2}: \mathcal{R}^2 \mapsto [0, 2\pi)$ 为带符号反正切函数, 其符号根据其点所在的四个不同象限决定。通过当当定义的圆弧法向量, 在位置 (x_c, y_c) 处的旋转不变Gabor特征 $F_{\theta_i, \lambda_j}(x, y)$ 可以由下式计算

$$[0017] \quad F_{\theta_i, \lambda_j}(x, y) = (1 - \beta)\tilde{F}_{\theta_i, \lambda_j}(x, y) + \beta\tilde{F}_{\theta_{n+i}, \lambda_j}(x, y) \quad (4)$$

[0018] 其中 $i_0 = \lfloor \phi / \psi \rfloor$, $\beta = \phi / \psi - i_0$ 。注意到 $\lfloor x \rfloor$ 为下取整函数, $\psi = \pi/n$, 其中 n 为总共使用的旋转参数个数。最后, 旋转不变特征向量 $\tilde{F}(x, y)$ 即由 $\{\tilde{F}_{\theta_i, \lambda_j}(x, y)\}$ 为其元素构成。

[0019] 2. 特征分类 依据像素特征提取, 图像中所有的像素将会被分成三类。首先我们会在超声图像中建立许多弧形带状窄带, 并在不同窄带中训练不同的特征字典对像素进行线性表示, 获得表示残差。然后, 基于这个残差, 我们使用图割(graph cut)方法, 把各个像素间的相关性一并考虑, 得到最终的像素分类结果。

[0020] 根据压缩感知(Compressive Sensing)中的理论, 针对每一个特征向量 \tilde{F} 和一组我们预先获得的字典 D , 只要使用字典 D 对向量 \tilde{F} 的表示系数 α 足够的稀疏, 则找到对 \tilde{F} 的稀疏表达的过程可以通过在原函数上附加 ℓ^1 范数约束来替代问题本身所提出的 ℓ^0 范数下的最小化问题, 此时, 该稀疏表达问题可以表示为

$$[0021] \quad \min_{\alpha} \|F - D\alpha\|_2^2 + \tau \|\alpha\|_1 \quad (5)$$

[0022] 其中 τ 拉格朗日乘数 (Lagrange multiplier)。我们使用上述稀疏表达的表示残差作为分类依据。

[0023] 基于超声图像的特征获得残差。该特征认为,超声斑点的大小随着其与超声探测中心的距离变化而变化。基于这个特性,我们认为只使用一个全局字典作为表示依据,并不足以充分涵盖超声斑点的丰富纹理特性。为了解决这一问题,我们在超声图像中建立了许多弧形带状窄条,在这些窄带内,各自都训练有各自的表示字典。严格的,对于图像上感兴趣的区域(Region Of Interest, ROI)内的每一个像素点 \mathbf{p} ,它所属的窄条可以通过下式计算

$$[0024] \quad i = \left\lfloor \frac{\|\mathbf{p} - \mathbf{c}\|_2}{h} \right\rfloor \quad (6)$$

[0025] 其中 i 为窄带的索引, \mathbf{c} 为探测棒的中心, h 为窄带的带宽。每一个窄带内,并非训练集中所有的像素都拿来训练字典集,而是只有那些在图像中前列腺轮廓附近的像素才用来训练字典。针对三个像素类,前列腺边界类,前列腺内部类和前列腺外部类,我们在每个窄带都分别为其训练了各自的字典。这里我们先简要解释一下为什么我们要把像素分为三类而不是直观上的两类(边界内和边界外)。首先,在我们的实验中,我们发现,尽管把像素分成三类的困难要大一些,但是我们的方法得到了和分类两类一致的实验结果。其次,在分成三类的情况下,分割模型可以更为直接的定位前列腺轮廓(而不需要通过两类情况下两类的边界来定位),从而帮助整个分割模型获得更好的整体分割效果。

[0026] 对于第 i 个窄带条内的像素 \mathbf{p} ,设它的特征向量 F_p ,我们可以使用字典矩阵 $D_i = [D_i^1, D_i^2, D_i^3]$ 对其进行稀疏表示,其中 D_i^1, D_i^2 和 D_i^3 分别代表在第 i 个窄带中针对前列腺边界类,前列腺内部类和前列腺外部类三个类训练的字典。依据这三个字典,像素 \mathbf{p} 的表示残差可以由下式计算

$$[0027] \quad r_k = \|F_p - D_i \delta_k(\alpha)\|_2^2, \quad k \in \{1, 2, 3\} \quad (7)$$

[0028] 其中

$$[0029] \quad \alpha = \arg \min_{\alpha} \|F_p - D_i \alpha\|_2^2 + \tau \|\alpha\|_1 \quad (8)$$

[0030] $\delta_k(\alpha)$ 是这样一个函数,它把 α 中所有跟 k 不是一类元素都设为零。至于字典训练的方法,学术界已经提出了许多解决方案,具有许多成熟的算法。

[0031] 在获得表示残差之后,我们并没有直接使用具有最小表示残差的类作为该像素的类,而是取表示残差的负值,并把所有残差归一化到 $[0, 1]$ 区间作为该像素属于某一类的可能性的度量。考虑到相邻像素具有更高的可能性会属于同一类,我们使用如下能量函数通过图割(graph cut)来最终实现像素的分类

$$[0032] \quad E = \sum_{p \in \Omega} R_p(k_p) + \mu \sum_{(p, q) \in \mathcal{N}} B(k_p, k_q) \quad (9)$$

[0033] μ 代表权重参数, Ω 为图像域, \mathcal{N} 为相邻像素的集合, $R_p(k_p)$ 为像素 p 属于 k 类

处罚值, B 用来维持相邻像素间分类的平滑性, 其公式为:

$$[0034] \quad B(l, k) = \begin{cases} 0, & l = k \\ 1, & \text{其它} \end{cases}$$

[0035] $R_p(k_s)$ 将残差 r_k 规范到 $[0, 1]$ 区间。

[0036] 3. 水平集分割模型 该模型为特征提取方法和窄带分割方法的总和。我们的水平集分割模型基于能量最小化模型, 其能量定义为

$$[0037] \quad E = E_C + \alpha_i E_T \quad (10)$$

[0038] 其中 α_i 为权重参数, E_C 即为定义的窄带对比度能量, 而 E_T 为纹理能量。这两部分能量可以被严格地定义为

$$[0039] \quad E_C = - \iint_{\Omega} \tilde{H}(\Phi) I - \tilde{H}(-\Phi) I dA \quad (11)$$

$$[0040] \quad E_T = - \iint_{\Omega} \tilde{H}(\Phi) l_e + \dot{H}(\Phi)(l_o - l_e) + \dot{H}(-\Phi)(l_i - l_o) dA \quad (12)$$

[0041] 其中 Ω 为图像域, I 为图像灰度, Φ 为符号距离函数 (SDF)。符号 l_e , l_i 和 l_o 表示像素分类结果, 分别为前列腺边界类, 前列腺边界内部类和前列腺边界外部类。一个像素如果被分类某一类, 则该类对应的 l 设为 1, 其它 l 均被设为 0。下面三个公式定义了模型边缘的窄带, 用于提取信息, 帮助分割:

$$[0042] \quad \tilde{H}(\Phi) = \begin{cases} 1, & \text{if } 0 < \Phi \leq h; \\ 0, & \text{if } \Phi > h \text{ or } \Phi \leq 0; \end{cases} \quad (13)$$

$$[0043] \quad \dot{H}(\Phi) = \begin{cases} 1, & \text{if } c < \Phi \leq h; \\ 0, & \text{if } \Phi > h \text{ or } \Phi \leq c; \end{cases} \quad (14)$$

$$[0044] \quad \ddot{H}(\Phi) = \begin{cases} 1, & -c \leq \Phi \leq c; \\ 0, & \Phi > c \text{ or } \Phi < -c; \end{cases} \quad (15)$$

[0045] 其中 h 和 c 为两个不同的带宽, 且 $h > c$ 。这两个不同的窄带模式分别在公式 11 和公式 12 中使用, 我们可以看到对比度能量, 即公式 11。它是 normal vector profile (NVP) 在水平集模型上的一个扩展, 同时, 它也融合了 Chan-Vese 模型的区域竞争特点, 并结合超声图像本身的特性, 只考虑了前列腺轮廓附近的信息。另一方面, 我们看到纹理特性能量, 即公式 12, 则是用来度量最终分割结果和之前像素分类结果的吻合度。

[0046] 能量最小化 我们实现对于水平集模型的参数化表示方法。因此, 我们可以直接使用梯度下降法对公式 10 进行最小化求解。能量 E 的梯度为

$$[0047] \quad \nabla E(w, p) = - \iint_{\Omega} \nabla \tilde{H}(\Phi) I - \nabla \tilde{H}(-\Phi) I dA \\ - \alpha \iint_{\Omega} \nabla \dot{H}(\Phi) l_e + \nabla \dot{H}(\Phi)(l_o - l_e) + \nabla \dot{H}(-\Phi)(l_i - l_o) dA \quad (16)$$

[0048] 其中三个不同的 H 的梯度可以通过链式法则获得:

[0049] $\nabla H(\Phi) = [\delta(\Phi - h_1) - \delta(\Phi - h_2)]\nabla\Phi \quad (17)$

[0050] 其中 $\delta(\cdot)$ 为狄拉克雷函数(Dirac Delta function);符号 $h_1, h_2 \in \{h, 0, c\}$ 代表模型边缘的窄带上下界,且 $h_1 < h_2$;把公式17代入公式16中,我们可以得到

[0051]
$$\begin{aligned} \nabla E = & -2 \oint_{\Phi=0} \nabla\Phi I ds + \oint_{\Phi=h} \nabla\Phi [I + \alpha(l_o - l_i)] ds \\ & + \oint_{\Phi=c} \nabla\Phi [I - \alpha(l_i - l_o)] ds \\ & + \oint_{\Phi=0} \alpha \nabla\Phi (l_i - l_o - l_e) ds + \oint_{\Phi=c} \alpha \nabla\Phi (l_e - l_o + l_i) ds \end{aligned} \quad (18)$$

[0052] 通过迭代求解 \mathbf{w} 和 \mathbf{p} ,可以实现对超声图像的分割;迭代过程为

[0053] $\mathbf{w}^{t+1} = \mathbf{w}^t - \alpha_w \nabla_{\mathbf{w}} E \quad (19)$

[0054] $\mathbf{p}^{t+1} = \mathbf{p}^t - \alpha_p \nabla_{\mathbf{p}} E \quad (20)$

[0055] 其中 α_w 和 α_p 为步长参数, t 代表迭代次数。

[0056] 由于我们的能量方程是基于局部信息的,因此我们需要一个模型初始化的过程来避免模型陷入局部最小。这里,我们对上一章中的模型初始化方法进行了改进,以期取得更好的效果。初始化方法是在图像域上的穷举搜索。我们的初始化方法是在图像 Ω 内的一个穷举搜索过程,我们会反复测试 \mathbf{p} 的不同值,同时固定 $\mathbf{w}=0$ 不变,来大致寻找前列腺在图像中位置。对每一个测试的 \mathbf{p} 的值,我们通过三步来考察它。首先,由于形状参数被设为固定值,模型无法准确的与图像中的前列腺拟合。因此,我们通过对原模型进行几步小的能量最小化步骤来尝试对前列腺的拟合,并在这一步中,把 α_w 和 α_p 这两个步长参数设置的比通常情况下要大一些。然后,在每一步中,我们都计算了对比度能量 E_C 。最后,我们保存了 E_C 对应的 \mathbf{E}_r ,参数 \mathbf{w} 和 \mathbf{p} 。在所有情况都测试结束后,我们取n个(在我们的实现中n=5)具有最小 E_r 的情况。这几种情况中,具有最小 E_r 的那个被视为初始化模型。我们不直接使用公式10来初始化是因为我们的能量函数具有局部特性,在初始搜索过程中直接使用公式10容易被其它像素误分类结果所影响。

具体实施方式

[0057] 本发明具体实施方式如下所示:

[0058] 1. 特征提取 Gabor 滤波是对超声图像进行纹理特征提取的常用方法。Gabor滤波可以被看作是角度和尺度可调整的边缘和线段检测器,并且可以通过设置不同的旋转和缩放参数来提取不同频段的局部特征信息。二维的Gabor滤波器方程

[0059]
$$G(x, y) = \exp\left(-\frac{x'^2 + y'^2}{2\sigma^2}\right) \exp\left(i\left(2\pi\frac{x'}{\lambda} + \psi\right)\right) \quad (21)$$

[0060] 其中

[0061] $x' = x \cos \theta + y \sin \theta, \quad y' = -x \sin \theta + y \cos \theta, \quad (22)$

[0062] λ 代表正弦函数的波长因子, θ 代表Gabor 函数的旋转方向, ψ 是相差, σ 表示高

斯卷积的标准差, γ 是空间长宽比。传统Gabor滤波提取的特征向量可以用列向量 $\tilde{F}(x, y)$ 表示, 该向量中的每一个元素为 $\{\tilde{F}_{\theta_i, \lambda_j}(x, y)\}$, 它是通过使用旋转参数为 θ_i 和尺度参数为 λ_j 的 Gabor 函数与原图像在位置 (x, y) 处的卷积获得的。一般的, Gabor 滤波簇的参数选择遵循在频域内各相邻滤波函数的频率响应的一半两两相邻原则。

[0063] 尽管Gabor滤波具有较强的提取纹理特征的能力, 但我们也看到, Gabor特征提取应该与斑点的旋转方向相适应。注意到Shen等人于2003年提出了旋转不变的Gabor特征提取方法, 虽然其出发点与我们不同, 但其旋转中心选择为超声探针, 与我们的需求一致, 故可以采用该方法并稍加改进, 以达到解决上述第一个斑点特性的目的。严格的, 设以超声探针为中心的圆弧, 在 (x, y) 处的法向方向为 ϕ , ϕ 则可以由下式计算

$$[0064] \quad \phi = \text{atan2}(x - x_c, y - y_c) \quad (23)$$

[0065] 其中 (x_c, y_c) 为超声探针的中心, 函数 $\text{atan2} : \mathcal{R}^2 \mapsto [0, 2\pi)$ 为带符号反正切函数, 其符号根据其点所在的四个不同象限决定。通过当当定义的圆弧法向量, 在位置 (x_c, y_c) 处的旋转不变Gabor特征 $F_{\theta_i, \lambda_j}(x, y)$ 可以由下式计算

$$[0066] \quad F_{\theta_i, \lambda_j}(x, y) = (1 - \beta)\tilde{F}_{\theta_i, \lambda_j}(x, y) + \beta\tilde{F}_{\theta_{i+\lfloor \frac{n}{2} \rfloor}, \lambda_j}(x, y) \quad (24)$$

[0067] 其中 $i_0 = \lfloor \phi / \psi \rfloor$, $\beta = \phi / \psi - i_0$ 。注意到 $\lfloor x \rfloor$ 为下取整函数, $\psi = \pi / n$, 其中 n 为总共使用的旋转参数个数。最后, 旋转不变特征向量 $F(x, y)$ 即由 $\{F_{\theta_i, \lambda_j}(x, y)\}$ 为其元素构成。

[0068] 2. 特征分类 依据像素特征提取, 图像中所有的像素将会被分成三类。首先我们会在超声图像中建立许多弧形带状窄带, 并在不同窄带中训练不同的特征字典对像素进行线性表示, 获得表示残差。然后, 基于这个残差, 我们使用图割(graph cut)方法, 把各个像素间的相关性一并考虑, 得到最终的像素分类结果。

[0069] 根据压缩感知(Compressive Sensing)中的理论, 针对每一个特征向量 F 和一组我们预先获得的字典 D , 只要使用字典 D 对向量 F 的表示系数 α 足够的稀疏, 则找到对 F 的稀疏表达的过程可以通过在原函数上附加 ℓ^1 范数约束来替代问题本身所提出的 ℓ^0 范数下的最小化问题, 此时, 该稀疏表达问题可以表示为

$$[0070] \quad \min_{\alpha} \|F - D\alpha\|_1^2 + \tau \|\alpha\|_1 \quad (25)$$

[0071] 其中 τ 拉格朗日乘数(Lagrange multiplier)。我们使用上述稀疏表达的表示残差作为分类依据。

[0072] 基于超声图像的特征获得残差。该特征认为, 超声斑点的大小随着其与超声探测中心的距离变化而变化。基于这个特性, 我们认为只使用一个全局字典作为表示依据, 并不足以充分涵盖超声斑点的丰富纹理特性。为了解决这一问题, 我们在超声图像中建立了许多弧形带状窄条, 在这些窄带内, 各自都训练有各自的表示字典。严格的, 对于图像上感兴趣的区域(Region Of Interest, ROI)内的每一个像素点 p , 它所属的窄条可以通过下式计算

$$[0073] i = \left\lfloor \frac{\|\mathbf{p} - \mathbf{c}\|_2}{h} \right\rfloor \quad (26)$$

[0074] 其中 i 为窄带的索引, \mathbf{c} 为探测棒的中心, h 为窄带的带宽。每一个窄带内, 并非训练集中所有的像素都拿来训练字典集, 而是只有那些在图像中前列腺轮廓附近的像素才用来训练字典。针对三个像素类, 前列腺边界类, 前列腺边界内部类和前列腺边界外部类, 我们在每个窄带都分别为其训练了各自的字典。这里我们先简要解释一下为什么我们要把像素分为三类而不是直观上的两类(边界内和边界外)。首先, 在我们的实验中, 我们发现, 尽管把像素分成三类的困难要大一些, 但是我们的方法得到了和分类两类一致的实验结果。其次, 在分成三类的情况下, 分割模型可以更为直接的定位前列腺轮廓(而不需要通过两类情况下两类的边界来定位), 从而帮助整个分割模型获得更好的整体分割效果。

[0075] 对于第 i 个窄带条内的像素 \mathbf{p} , 设它的特征向量 F_p , 我们可以使用字典矩阵 $D_i = [D_i^1, D_i^2, D_i^3]$ 对其进行稀疏表示, 其中 D_i^1, D_i^2 和 D_i^3 分别代表在第 i 个窄带中针对前列腺边界类, 前列腺边界内部类和前列腺边界外部类三个类训练的字典。依据这三个字典, 像素 \mathbf{p} 的表示残差可以由下式计算

$$[0076] r_k = \|F_p - D_i \delta_k(\alpha)\|_2^2, \quad k \in \{1, 2, 3\} \quad (27)$$

[0077] 其中

$$[0078] \alpha = \arg \min_{\alpha} \|F_p - D_i \alpha\|_2^2 + \tau \|\alpha\|_1 \quad (28)$$

[0079] $\delta_k(\alpha)$ 是这样一个函数, 它把 α 中所有跟 k 不是一类元素都设为零。至于字典训练的方法, 学术界已经提出了许多解决方案, 具有许多成熟的算法。

[0080] 在获得表示残差之后, 我们并没有直接使用具有最小表示残差的类作为该像素的类, 而是取表示残差的负值, 并把所有残差归一化到 $[0, 1]$ 区间作为该像素属于某一类的可能性的度量。考虑到相邻像素具有更高的可能性会属于同一类, 我们使用如下能量函数通过图割(graph cut)来最终实现像素的分类

$$[0081] E = \sum_{p \in \Omega} R_p(k_p) + \mu \sum_{(p, q) \in \mathcal{N}} B(k_p, k_q) \quad (29)$$

[0082] μ 代表权重参数, Ω 为图像域, \mathcal{N} 为相邻像素的集合, $R_p(k_p)$ 为像素 p 属于 k 类处罚值, B 用来维持相邻像素间分类的平滑性, 其公式为:

$$[0083] B(l, k) = \begin{cases} 0, & l = k \\ 1, & \text{其它} \end{cases}$$

[0084] $R_p(k_p)$ 将残差 r_k 规范到 $[0, 1]$ 区间。

[0085] 3. 水平集分割模型 该模型为特征提取方法和窄带分割方法的总和。我们的水平集分割模型基于能量最小化模型, 其能量定义为

$$[0086] E = E_C + \alpha_1 E_T \quad (30)$$

[0087] 其中 α_1 为权重参数, E_C 即为定义的窄带对比度能量, 而 E_T 为纹理能量。这两部分能量可以被严格地定义为

[0088] $E_C = - \iint_{\Omega} \tilde{H}(\Phi) I - \tilde{H}(-\Phi) I dA \quad (31)$

[0089] $E_T = - \iint_{\Omega} \dot{H}(\Phi) l_e + \dot{H}(\Phi)(l_o - l_i) + \dot{H}(-\Phi)(l_i - l_o) dA \quad (32)$

[0090] 其中 Ω 为图像域, I 为图像灰度, Φ 为符号距离函数 (SDF)。符号 l_e , l_i 和 l_o 表示像素分类结果, 分别为前列腺边界类, 前腺边界内部类和前列腺边界外部类。一个像素如果被分类某一类, 则该类对应的 l 设为 1, 其它 l 均被设为 0。下面三个公式定义了模型边缘的窄带, 用于提取信息, 帮助分割:

[0091] $\tilde{H}(\Phi) = \begin{cases} 1, & \text{if } 0 < \Phi \leq h; \\ 0, & \text{if } \Phi > h \text{ or } \Phi \leq 0; \end{cases} \quad (33)$

[0092] $\dot{H}(\Phi) = \begin{cases} 1, & \text{if } c < \Phi \leq h, \\ 0, & \text{if } \Phi > h \text{ or } \Phi \leq c, \end{cases} \quad (34)$

[0093] $\ddot{H}(\Phi) = \begin{cases} 1, & -c \leq \Phi \leq c, \\ 0, & \Phi > c \text{ or } \Phi < -c, \end{cases} \quad (35)$

[0094] 其中 h 和 c 为两个不同的带宽, 且 $h > c$ 。这两个不同的窄带模式分别在公式 31 和公式 32 中使用, 我们可以看到对比度能量, 即公式 31。它是 normal vector profile (NVP) 在水平集模型上的一个扩展, 同时, 它也融合了 Chan-Vese 模型的区域竞争特点, 并结合超声图像本身的特性, 只考虑了前列腺轮廓附近的信息。另一方面, 我们看到纹理特性能量, 即公式 32, 则是用来度量最终分割结果和之前像素分类结果的吻合度。

[0095] 能量最小化 我们实现对于水平集模型的参数化表示方法。因此, 我们可以直接使用梯度下降法对公式 30 进行最小化求解。能量 E 的梯度为

[0096]
$$\nabla E(\mathbf{w}, \mathbf{p}) = - \iint_{\Omega} \nabla \tilde{H}(\Phi) I - \nabla \tilde{H}(-\Phi) I dA - \alpha \iint_{\Omega} \nabla \dot{H}(\Phi) l_e + \nabla \dot{H}(\Phi)(l_o - l_i) + \nabla \dot{H}(-\Phi)(l_i - l_o) dA \quad (36)$$

[0097] 其中三个不同的 H 的梯度可以通过链式法则获得:

[0098] $\nabla H(\Phi) = [\delta(\Phi - h_1) - \delta(\Phi - h_2)] \nabla \Phi \quad (37)$

[0099] 其中 $\delta(\cdot)$ 为狄拉克雷函数 (Dirac Delta function); 符号 $h_1, h_2 \in \{h, 0, c\}$ 代表模型边缘的窄带上下界, 且 $h_1 < h_2$; 把公式 37 代入公式 36 中, 我们可以得到

[0100]
$$\begin{aligned} \nabla E = & -2 \oint_{\Phi=0} \nabla \Phi I ds + \oint_{\Phi=h} \nabla \Phi [I + \alpha(l_o - l_i)] ds \\ & + \oint_{\Phi=-h} \nabla \Phi [I - \alpha(l_i - l_o)] ds \\ & + \oint_{\Phi=-c} \alpha \nabla \Phi (l_i - l_o - l_e) ds + \oint_{\Phi=c} \alpha \nabla \Phi (l_e - l_o + l_i) ds \end{aligned} \quad (38)$$

[0101] 通过迭代求解 \mathbf{W} 和 \mathbf{P} ,可以实现对超声图像的分割;迭代过程为

$$\mathbf{w}^{t+1} = \mathbf{w}^t - \alpha_w \nabla_{\mathbf{w}} E \quad (39)$$

$$\mathbf{p}^{t+1} = \mathbf{p}^t - \alpha_p \nabla_{\mathbf{p}} E \quad (40)$$

[0104] 其中 α_w 和 α_p 为步长参数, t 代表迭代次数。

[0105] 由于我们的能量方程是基于局部信息的,因此我们需要一个模型初始化的过程来避免模型陷入局部最小。这里,我们对上一章中的模型初始化方法进行了改进,以期取得更好的效果。初始化方法是在图像域上的穷举搜索。我们的初始化方法是在图像 Ω 内的一个穷举搜索过程,我们会反复测试 \mathbf{P} 的不同值,同时固定 $\mathbf{w}=0$ 不变,来大致寻找前列腺在图像中位置。对每一个测试的 \mathbf{P} 的值,我们通过三步来考察它。首先,由于形状参数被设为固定值,模型无法准确的与图像中的前列腺拟合。因此,我们通过对原模型进行几步小的能量最小化步骤来尝试对前列腺的拟合,并在这一步中,把 α_w 和 α_p 这两个步长参数设置的比通常情况下要大一些。然后,在每一步中,我们都计算了对比度能量 E_C 。最后,我们保存了 E_C 对应的 \mathbf{E}_r ,参数 \mathbf{W} 和 \mathbf{P} 。在所有情况都测试结束后,我们取n个(在我们的实现中n=5)具有最小 E_C 的情况。这几种情况中,具有最小 E_r 的那一个被视为初始化模型。我们不直接使用公式30来初始化是因为我们的能量函数具有局部特性,在初始搜索过程中直接使用公式30容易被其它像素误分类结果所影响。

专利名称(译)	一种新的前列腺超声图像分割方法		
公开(公告)号	CN104504720B	公开(公告)日	2017-04-19
申请号	CN201510006415.4	申请日	2015-01-07
[标]申请(专利权)人(译)	四川大学		
申请(专利权)人(译)	四川大学		
当前申请(专利权)人(译)	四川大学		
[标]发明人	刘怡光 吴鹏飞 曹丽萍 罗以宁 詹洋		
发明人	刘怡光 吴鹏飞 曹丽萍 罗以宁 詹洋		
IPC分类号	G06T7/11 A61B8/00		
CPC分类号	A61B8/5223 G06T7/10 G06T2207/30081		
审查员(译)	刘海艳		
其他公开文献	CN104504720A		
外部链接	Espacenet Sipo		

摘要(译)

本发明提供一种新的前列腺超声图像分割技术，在直肠超声检测(transrectal ultrasound, TRUS)图像中对前列腺进行准确分割。传统观点认为，TRUS图像的斑点会对目标分割造成强烈的副作用。与此不同，我们利用斑点的内在属性来简化分割问题。首先，斑点的大小和方向并非完全随机分布，而是服从一定的规律特性。为了利用斑点的方向特性，我们使用了旋转不变的Gabor特性来提取问题特征；为了利用斑点的大小尺度特性，我们把TRUS图像分成了许多条状窄带，在不同窄带内对图像像素进行不同的处理。最后，我们还考虑了不同像素间的相关性，并进一步通过这一特性使用图割(graph cut)方法提高了像素分类精度。以此为基础，我们通过水平集分割模型，最终得到了TRUS图像中前列腺的分割结果。

