

基于知识的多层 Mumford-Shah 向量值图像分割模型

刘国才^{1,2} 王耀南¹ 段宣初³

摘要 针对多层 Mumford-Shah 模型不能正确分割对比度小且部分被遮挡的复杂医学图像问题, 将目标形状先验知识窄带水平集统计形状模型集成到多层 Mumford-Shah 模型, 提出了基于目标形状先验知识的多层 Mumford-Shah 向量值图像分割模型和求解该图像分割模型泛函最小值的水平集逐层迭代算法. 实验结果表明, 该方法能够有效分割对比度小且部分被血管遮挡的早期青光眼病人视乳头图像.

关键词 统计形状模型, 多层 Mumford-Shah 模型, 水平集方法, 最小分割问题, 医学图像处理
中图分类号 TP391

Knowledge Based Hierarchical Mumford-Shah Model for Vector-valued Image Segmentation

LIU Guo-Cai^{1,2} WANG Yao-Nan¹ DUAN Xuan-Chu³

Abstract To segment a given vector-valued image such as color images, and to handle important image features such as very low contrast and obscured part, a novel knowledge based hierarchical Mumford-Shah functional model is addressed by integrating a statistical shape prior model based on narrow band level set with hierarchical Mumford-Shah model. At the same time, an iterative tier-by-tier algorithm based on techniques of level set is proposed to minimize the new functional. This novel model could recognise an object whose shape is similar to the prior one. The experimental results show that the technique is effective and practicable by applying it to the segmentation of the optic disk obscured by blood vessels in color optic nerve head images of early stage glaucoma patients.

Key words Statistical shape model, hierarchical Mumford-Shah model, level set methods, minimal partition problem, medical image process

为了解决复杂图像如对比度很小且部分被遮挡的医学图像的分割难题, 许多研究人员已将目标形状先验知识引入到基于水平集的图像分割方法中. Zeng 等采用一对相互关联的演化曲面分割大脑皮层 3D MR 图像, 他们直接使用大脑中各类不同组织边界之间的厚度作为先验知识约束演化的曲面^[1]. Leventon 等则将 Cootes 等提出的点分布模型 (Point distribution model, PDM)^[2] 扩展到目标形状的水平集曲面, 提出了目标形状的水平集分布先验统计模型 (Level set distribution model,

LSDM)^[3], 并在此基础上将目标形状先验知识在最大后验概率准则 (Maximum a posteriori, MAP) 下引入测地活动轮廓模型处理过程, 使图像分割曲线的演化交替地依赖于图像的梯度和目标边界 (形状) 的先验知识. Tsai 等将 Leventon 等提出的 LSDM 引入基于区域的图像分割能量泛函^[4], 特别包括基于 Mumford-Shah 泛函^[5] 的 Chan-Vese 模型^[6]. 他们采用梯度下降法直接在目标姿态及其统计形状参数空间内寻找最优的目标形状 LSDM 模型参数和姿态参数以实现图像分割而非通过演化形状活动轮廓水平集曲面. Chen 等直接使用“平均形状”或某已知形状作为形状先验知识, 将其到当前活动轮廓零水平集上对应点之间的距离作为约束项直接添加到几何活动轮廓模型^[7] 或作为 Chan-Vese 模型中轮廓曲线长度的权重, 直接通过该形状先验知识约束水平集曲面的演化实现图像分割和最优目标姿态 (配准) 参数的寻找. Bresson 等采用 Leventon 提出的目标形状 LSDM 替代上述 Chen 的“平均形状”作为形状先验知识, 通过该统计形状先验知识约束水平集曲面的演化和目标形状姿态及其统计形状参数的优化, 实现图像分割^[8]. Yang 等在 MAP 准则下将形状和图像灰度级的联合先验知识引入到 Chan-Vese 水平集模型, 并直接通过该水平集曲面的演化实现图像分割^[9].

收稿日期 2008-02-27 收修改稿日期 2008-08-23
Received February 27, 2008; in revised form August 23, 2008
国家自然科学基金 (60872130, 60835004, 60775047), 国家高技术研究发展计划 (863 计划) (2007AA04Z244), 和教育部高等学校科技创新工程重大项目培育资金 (706043) 资助

Supported by National Natural Science Foundation of China (60872130, 60835004, 60775047), National High Technology Research and Development Program of China (863 Program) (2007AA04Z244), and National Science and Technology Innovation Program of Ministry of Education of China (706043)

1. 湖南大学电气与信息工程学院 长沙 410082 2. 加州大学戴维斯分校生物医学工程系 戴维斯 CA95616 美国 3. 中南大学湘雅二医院眼科 长沙 410011

1. College of Electrical and Information Engineering, Hunan University, Changsha 410082, P. R. China 2. Department of Biomedical Engineering, University of California, Davis CA95616, USA 3. Department of Ophthalmology of the 2nd Xiangya Hospital, Central South University, Changsha 410011, P. R. China
DOI: 10.3724/SP.J.1004.2009.00356

受 Yang 等的启发, 我们将目标形状先验知识引入多层 Mumford-Shah 模型^[10-11], 提出了基于目标形状先验知识的多层 Mumford-Shah 向量值图像分割新模型和求解该图像分割模型泛函最小值的水平集逐层迭代算法. 该模型在最大目标形状后验概率准则下将目标形状窄带水平集分布模型表达的先验知识集成到多层 Mumford-Shah 向量值图像分割模型中, 其具有以下特点: 1) 直接在目标形状水平集空间内通过目标形状水平集的演化实现分割图像, 且使该水平集演化过程既依赖于当前图像特征向量(如 R、G、B 值), 也依赖于目标形状的局部形变先验知识, 从而使该模型能够有效解决对比度很小且部分被遮挡的医学图像分割难题. 2) 在通过训练图像集建立目标形状先验知识窄带水平集分布模型时无需显式确定点的对应关系, 并可有效降低算法的计算复杂度. 青光眼病人彩色视乳头图像视盘的分割实验结果表明了该模型的有效性.

本文第 1 节论述目标形状先验知识的建模方法, 包括形状窄带水平集表达、配准和统计建模方法; 第 2 节论述基于知识的多层 Mumford-Shah 向量模型; 第 3 节论述相应的水平集逐层迭代算法; 第 4 节论述该模型在早期青光眼病人视乳头图像分割中的应用研究实验结果.

1 形状先验知识的建模方法

Cootes 等提出的点分布模型 PDM^[2] 不仅能够创建类似的新形状或外观实例, 而且能对同类的新图像进行分析处理, 但是, 该方法在创建 PDM 时需要知道目标形状标志点的对应关系, 这是非常困难的一项工作, 而且当目标对象的拓扑结构可变或变化很大或者目标对象无明显的标志点时, 不能采用 PDM 来描述其形变模式. 为了克服这些困难, Leventon 等提出了目标形状水平集分布模型 LSDM^[3]. 该模型采用 Osher 等提出的著名水平集方法^[12] 隐式表达目标的形状, 因此创建目标形状 LSDM 时不需要形状标志点, 更不需要保证训练样本标志点的显式对应关系, 但是, 因为该方法需要将目标形状曲线嵌入到高一维的水平集曲面进行处理, 因此其计算费用较高.

另一方面, 我们注意到目标形状的自然变化通常仅发生在其边界(轮廓)的邻近, 所以本文提出在创建目标形状模型时采用 Adalsteinsson 等提出的窄带水平集方法^[13], 该方法继承了 LSDM 的全部优点, 而且可降低目标形状水平集表达、训练形状配准和水平集曲面分布统计分析的计算复杂度.

1.1 形状窄带水平集表达方法

首先, 将每个目标形状训练边界曲线嵌入一个高一维的符号距离水平集曲面(1), 式中, R 为整个

图像区域, Ω 为目标形状内部图像区域, $\bar{\Omega}$ 为 Ω 的闭包集.

$$\phi_i^0(x, y) = \begin{cases} -D(x, y), & (x, y) \in \Omega \\ 0, & (x, y) \in \partial\Omega \\ D(x, y), & (x, y) \in R \setminus \bar{\Omega} \end{cases} \quad (1)$$

其次, 计算确定目标形状训练集的公共窄带区域 $\tilde{\Omega}_i^0$ 和 $\tilde{\Omega}^0$ (见式(2)), 即全体训练样本形状窄带区域的交集, 式中 d^0 为目标形状窄带宽度, 这可以获得最小的计算复杂度, 但是, 在实际应用中, 带宽应根据具体情况确定.

$$\begin{aligned} \tilde{\Omega}_i^0 &= \{(x, y) : |\phi_i^0(x, y)| \leq d^0\} \\ \tilde{\Omega}^0 &= \bigcap_{i=1}^N \tilde{\Omega}_i^0 \end{aligned} \quad (2)$$

1.2 形状窄带配准泛函模型

为了建立目标形状的窄带水平集统计形状模型, 需要先配准目标形状训练图像集. 将目标形状训练集二值化, 可以大大简化训练形状集的配准^[4]. 假定二值训练形状图像 I^i 配准后的图像为 \tilde{I}^i , 相应的姿态配准参数向量为

$$\mathbf{P}^i = [P_{\text{scale}}^i, P_{\text{sin}}^i, P_x^i, P_y^i]^T \quad (3a)$$

其中, 各分量依次为全局的缩放比例值、旋转正弦函数值和 x 、 y 方向的坐标平移(像素点数). 则有

$$\begin{aligned} \tilde{I}^i(\tilde{x}, \tilde{y}) &= I^i(x, y) \\ \tilde{x}^i &= P_{\text{scale}}^i \cdot (x \cdot P_{\text{cos}}^i - y \cdot P_{\text{sin}}^i) + P_x^i \\ \tilde{y}^i &= P_{\text{scale}}^i \cdot (x \cdot P_{\text{sin}}^i + y \cdot P_{\text{cos}}^i) + P_y^i \\ P_{\text{cos}}^i &= \sqrt{1 - (P_{\text{sin}}^i)^2} \end{aligned} \quad (3b)$$

配准这些二值图像的一个有效方法是最小化下列目标形状窄带配准泛函

$$E_{\text{align}}(\mathbf{P}^i) = \sum_{i=1}^N \sum_{j=1, j \neq i}^N \frac{\int \int_{\tilde{\Omega}^0} (\tilde{I}^i(\tilde{x}, \tilde{y}) - \tilde{I}^j(\tilde{x}, \tilde{y}))^2 d\tilde{x}d\tilde{y}}{\int \int_{\tilde{\Omega}^0} (\tilde{I}^i(\tilde{x}, \tilde{y}) + \tilde{I}^j(\tilde{x}, \tilde{y}))^2 d\tilde{x}d\tilde{y}} \quad (4)$$

式中, $\tilde{\Omega}^0$ 为训练形状集的公共窄带, 由式(2)确定.

1.3 形状窄带水平集分布统计模型

首先, 易证明, 符号距离水平集函数关于姿态平移、旋转配准变换是不变的, 所以, 配准后的训练形状水平集可直接根据式(5)确定.

$$\phi_i = P_{\text{scale}}^i \cdot \phi_i^0 \quad (5)$$

其次, 计算确定配准后目标形状的公共窄带区域 $\tilde{\Omega}_i$ 和 $\tilde{\Omega}$ (见式 (6)), 式中 d 为相应的窄带宽度. 注意, 在实际应用中, 带宽应根据具体情况确定.

$$\begin{aligned}\tilde{\Omega}_i &= \{(\tilde{x}, \tilde{y}) : |\phi_i(\tilde{x}, \tilde{y})| \leq d\} \\ \tilde{\Omega} &= \bigcap_{i=1}^N \tilde{\Omega}_i\end{aligned}\quad (6)$$

最后, 采用主成分分析 (Principle component analysis, PCA) 方法从配准后的二值训练形状窄带水平集曲面中抽取目标形变模式, 创建形状窄带水平集统计模型 (7a) ~ (7e)

$$\hat{\phi} = U_k \cdot \alpha + \bar{\phi} \quad (7a)$$

$$\bar{\phi} = \frac{1}{N} \cdot \sum_{i=1}^N \phi_i \quad (7b)$$

$$\tilde{\phi}_i = \phi_i - \bar{\phi} \quad (7c)$$

$$M = [\tilde{\phi}_1, \tilde{\phi}_2, \dots, \tilde{\phi}_N] \quad (7d)$$

$$\frac{1}{N} M \cdot M^T = U \cdot \Sigma \cdot U^T \quad (7e)$$

其中, $\bar{\phi}$ 为训练图像集公共窄带子图像区域内的目标形状水平集平均值, 即平均形状, 矩阵 U 的列向量实际上代表相互正交的目标形变模式, 即所谓的特征形状, 它是等式 (7e) 左边协方差矩阵的特征向量, 对角阵 Σ 的对角元为相应的特征值 λ_i . 不失一般性, 与最大的 k 个特征值对应, 假定其前 k 列代表最主要 k 个目标形状形变模式, 记为矩阵 U_k . 对给定的新形状 ϕ , 可采用式 (8a) 估计 k 维的统计形状模型参数向量 α

$$\alpha = U_k^T \cdot (\phi - \bar{\phi}) \quad (8a)$$

其统计特性是该类目标形状形变统计特征的表现, 其分量的方差为

$$\sigma_i^2 = \lambda_i \quad (8b)$$

2 基于知识的多层 Mumford-Shah 向量模型

最大后验概率准则是一种集成目标形状随机形变先验统计知识到图像分割变分模型的有效方法. 本文提出在最大目标形状窄带水平集统计模型参数 (8) 后验概率准则下将目标形状先验知识集成到多层 Mumford-Shah 向量值图像分割变分模型^[11].

假定目标形状包含在图像 \mathbf{u}_0 的第 h 层第 n 个子连通图像区域 Ω^{hn} 内, 该形状的边缘构成图像 \mathbf{u}_0 在 Ω^{hn} 内的边缘, 且该边缘的连续封闭曲线近似即 C^{hn} . 假设该类目标形状 C^{hn} 的窄带水平集统计模

型参数 (8) 服从均值为零、协方差为 Σ_k 的高斯型分布 (9)

$$p(C^{hn}) = \exp \frac{-0.5 \cdot \alpha^T \cdot \Sigma_k^{-1} \cdot \alpha}{\sqrt{(2\pi)^k \cdot |\Sigma_k|}} \quad (9)$$

同时假设该类目标及其“背景”图像各向同性且服从高斯型分布 (10)

$$p(\mathbf{u}_0 | C^{hn}) = \left[\prod_{x \in \Omega_1^{hn}} \prod_{i=1}^N \exp \frac{-(u_{i,0} - c_{i,1}^{hn})^2}{2\sigma_{i,1}^2} \right] \times \left[\prod_{x \in \Omega_2^{hn}} \prod_{i=1}^N \exp \frac{-(u_{i,0} - c_{i,2}^{hn})^2}{2\sigma_{i,2}^2} \right] \quad (10)$$

式 (10) 中, $c_{i,1}^{hn}$ 和 $\sigma_{i,1}^2$ 分别为各向同性高斯型分布图像 $u_{i,0}$ 在前景 (目标) 区域 Ω_1^{hn} 内的均值和方差, 而 $c_{i,2}^{hn}$ 和 $\sigma_{i,2}^2$ 分别为 $u_{i,0}$ 在“背景”区域 Ω_2^{hn} 内的均值和方差.

则最大后验概率问题 (11) 等价于基于目标形状先验知识的多层 Mumford-Shah 向量值图像分割变分问题 (12), 简称统计多层 Mumford-Shah 模型 (SHMSMv).

$$\max_{C^{hn}} \{p(C^{hn} | \mathbf{u}_0) = p(\mathbf{u}_0 | C^{hn}) \cdot p(C^{hn})\} \quad (11)$$

$$\begin{aligned}\inf_{c_{i,1}^{hn}, c_{i,2}^{hn}, C^{hn}} \{F^{\text{SHMS}}(c_{i,1}^{hn}, c_{i,2}^{hn}, C^{hn}) = & \\ & - \ln p(\mathbf{u}_0, C^{hn} | \mathbf{u}_0) \propto \\ & - \ln p(\mathbf{u}_0 | C^{hn}) \cdot p(C^{hn}) \cdot p_B(C^{hn}) \propto \\ & \int \int_{\Omega_1^{hn}} \frac{1}{N} \sum_{i=1}^N \lambda_i^{hn} \cdot |u_{i,0} - c_{i,1}^{hn}|^2 dx dy + \\ & \int \int_{\Omega_2^{hn}} \frac{1}{N} \sum_{i=1}^N \lambda_i^{hn} \cdot |u_{i,0} - c_{i,2}^{hn}|^2 dx dy + \\ & \eta^{hn} \cdot \alpha^T \cdot \Sigma_k^{-1} \cdot \alpha + \mu^{hn} \cdot L^{hn}\} \quad (12a)\end{aligned}$$

式 (12a) 中,

$$p_B(C^{hn}) = \exp \left(-\mu^{hn} \cdot \int_{C^{hn}} dH^{n-1} \right) \quad (12b)$$

为目标形状边界正则性 (光滑性) 先验概率分布.

$$\alpha^T \cdot \Sigma_k^{-1} \cdot \alpha \quad (12c)$$

为当前目标形状窄带水平集和先验统计形状窄带水平集之间的偏差度量, 即窄带内各点水平集函数值差的平方加权和. 因此, 如果该加权函数为 $w(x)$, 则式 (12a) 可改写成水平集表达的连续模型 (12d).

$$\inf_{c_{i,1}^{hn}, c_{i,2}^{hn}, C^{hn}} \left\{ F^{\text{SHMS}}(c_{i,1}^{hn}, c_{i,2}^{hn}, C^{hn}) = \int \int_{\Omega^{hn}} \frac{1}{N} \sum_{i=1}^N \lambda_i^{hn} \cdot |u_{i,0} - c_{i,1}^{hn}|^2 \cdot H(\phi^{hn}) dx dy + \right. \\ \int \int_{\Omega^{hn}} \frac{1}{N} \sum_{i=1}^N \lambda_i^{hn} \cdot |u_{i,0} - c_{i,2}^{hn}|^2 \cdot (1 - H(\phi^{hn})) dx dy + \\ \left. \eta^{hn} \cdot \int \int_{\Omega^{hn} \cap \bar{\Omega}} w(x) (\phi^{hn} - \bar{\phi}^{hn})^2 dx dy + \mu^{hn} \cdot \int_{C^{hn}} dH^{n-1} \right\} \quad (12d)$$

式 (12d) 中, $\bar{\phi}^{hn}$ 为样本形状水平集函数统计平均值. 函数 $H(\cdot)$ 为

$$H(z) = \begin{cases} 1, & \text{当 } z \geq 0 \text{ 时} \\ 0, & \text{当 } z < 0 \text{ 时} \end{cases}$$

3 水平集逐层迭代算法

水平集方法最初被用来研究依赖于曲率的曲线的演化过程^[12], 后来被广泛应用于各种和曲线演化相关的科学研究和工程领域, 包括图像科学领域. 为了求解最小值问题 (12), 本文在多层 Mumford-Shah 向量模型水平集逐层迭代算法^[11] 的基础上提出了统计多层 Mumford-Shah 向量值图像处理的水平集逐层迭代算法, 其流程与多层 Mumford-Shah 模型迭代算法流程^[10] 相同. 为简化论述, 本节只论述与多层 Mumford-Shah 向量模型水平集逐层迭代算法不同的部分, 3.1 节阐述该算法的基本部分, 3.2 节阐述该算法的逐层迭代部分.

3.1 基本算法

易知, 使式 (12a) 成立的 $c_{i,1}^{hn}$ 和 $c_{i,2}^{hn}$ 分别为 $u_{i,0}$ 在 Ω_1^{hn} 和 Ω_2^{hn} 内的平均值, 而相应的符号距离水平集函数 ϕ^{hn} 则满足如下水平集方程.

当 $(t, x, y) \in (0, \infty) \times \Omega^{hn}$ 时,

$$\frac{\partial \phi^{hn}(t, x, y)}{\partial t} = \left\{ \frac{1}{N} \sum_{i=1}^N \lambda_i^{hn} \times [-(u_{i,0} - c_{i,1}^{hn})^2 + (u_{i,0} - c_{i,2}^{hn})^2] \right\} \times \\ |\nabla \phi^{hn}| + \mu^{hn} \cdot \text{div} \left(\frac{\nabla \phi^{hn}}{|\nabla \phi^{hn}|} \right) \times |\nabla \phi^{hn}| - \\ \eta^{hn} \times \bar{\phi}_k^{hn}(t, x, y) \quad (13)$$

当 $t = 0, (x, y) \in \Omega^{hn}$ 时,

$$\phi^{hn}(0, x, y) = \phi_0^{hn}(x, y)$$

式中

$$\bar{\phi}_k^{hn}(t, x, y) = U_k \cdot \Sigma_k^{-1} \cdot U_k^T \cdot (\phi^{hn} - \bar{\phi}^{hn}) \quad (14)$$

为当前活动轮廓 (目标形状) 窄带水平集和先验统计形状水平集之间的偏差度量.

3.2 迭代算法

与多层 Mumford-Shah 向量模型水平集逐层迭代算法相比, 主要不同之处如下:

1) 初始子图像边缘的自动给定

在每个给定的 Ω^{hn} 上, 采用目标统计平均形状作为初始目标对象边缘 (活动轮廓)

$$C_0^{hn} = \{(x, y) \in \Omega^{hn} : \bar{\phi}^{hn}(x, y) = 0\} \quad (15)$$

2) 不自动调整模型参数 η^{hn}

该参数取决于对先验形状知识的信任度和当前目标图像的特性, 目前, 我们根据经验确定.

4 早期青光眼病人视乳头图像分割

在早期青光眼诊断和普查中, 彩色眼底照片中视乳头的自动分割、度量和评估起着非常重要的作用^[14]. 但是, 眼底照片常常质量不好, 对比度甚至低到部分视盘边缘难以识别, 再加上血管的部分遮挡、病人之间的差异等使得早期青光眼病人眼底照片中视乳头的自动分割比中、晚期病人的视乳头自动分割更困难. 为有效地自动分割早期青光眼病人视乳头图像中的视盘, 必须将青光眼专家关于视盘形状的先验知识引入自动分割处理过程, 为此, 我们首先采用形状窄带水平集统计模型表达青光眼专家在早期青光眼病人眼底照片上描绘的视盘边缘曲线 (视盘形变先验知识), 然后, 将该视盘形状统计模型表达的视盘形状形变先验知识在 MAP 准则下通过统计多层 Mumford-Shah 模型引入早期青光眼病人视乳头图像的自动分割过程中, 使视盘边缘曲线水平集的演化不仅依赖于当前的眼底照片信息, 而且依赖于青光眼专家提供的视盘形变先验知识, 最终解决早期青光眼病人眼底照片中视乳头的自动分割难题. 本节论述我们的实验结果. 4.1 节描述视盘形状先验知识窄带水平集分布统计建模; 4.2 节描述彩色视乳头图像的视盘分割.

4.1 视盘形状窄带水平集分布统计建模

实验中的视盘形状训练图像集由 8 个不同的早期青光眼病人在 1999 年下半年拍摄的原始眼底照片组成. 在这些照片上, 由青光眼专家人工描绘好视盘边缘曲线. 这些眼底照片选自欧洲青光眼预防研究工程 EGPS 的眼底图像库, 该图像库包含 1100 个病人长达四年的定期检查时拍摄的眼底照片¹.

首先采用梯度下降法寻找配准能量 (4) 最小的姿态配准参数以同时配准上述 8 个视盘形状训练图像, 然后利用这些配准后的早期青光眼病人视盘形状训练图像, 建立早期青光眼病人视盘形状窄带水平集统计分布模型 (7). 统计分析表明其前 4 个主成分 (即最大的 4 个形变模式) 能够表达 90% 以上的视盘形变, 具体情况如下所述.

4.1.1 统计平均形状

样本集平均形状即 $\alpha = \mathbf{0}$ 时 (7a) 确定的零水平集, 也即平均的零水平集, 它是满足 $\bar{\phi} = 0$ 的点集. 图 1 中, 白色曲线为青光眼专家描绘的各样本视盘边缘曲线, 灰色曲线为全体样本视盘形状窄带水平集确定的平均形状. 该图表明, 青光眼专家描绘的各样本视盘边缘与平均形状非常相似, 即视盘形变较小, 这和眼科临床结论一致. 正常情况下, 人眼视盘边缘是不变的, 由各自的生理结构决定, 但各病人之间的视盘有一定的细微变化. 平均形状表达了各病人视盘形状的共同特征, 它们之间的细微变化由非零的模型参数 α 来表达.

4.1.2 统计形状实例

各病人之间视盘形状的细微变化可由其形状窄带水平集统计分布模型 (7) 来表达, 统计形状实例即满足 $\hat{\phi} = 0$ 的点集. 为了便于对比分析, 将青光眼专家描绘的视盘边缘曲线、统计平均形状和统计模型形状实例同时标识在第 1 个视乳头样本图像上, 如图 2 (见下页) 所示. 图中, 白色、灰色和黑色曲线分别标识青光眼专家描绘的视盘边缘曲线、视盘统计平均形状和视盘统计形状实例. 该图展现了统计视盘形状模型的视盘形变表达能力.

图 2 中, 视盘统计形状实例由最大的 2 个形变模式产生, 即先由 $\hat{\phi}_i = \alpha_i \cdot \mathbf{U}_{ki} + \bar{\phi}$ 创建形状实例的水平集函数, 再由满足 $\hat{\phi}_i = 0$ 的点集创建统计形状实例. 其中, 统计形状模型形状参数 $\alpha_i = \pm 0.3 \cdot \sigma_i$, \mathbf{U}_{ki} 为第 i 大形变模式, 即矩阵 \mathbf{U}_k 的第 i 列, $i = 1, 2$.

¹Glaucoma prevention by computer aided diagnostics (GlauCAD). The investigation in GlauCAD was performed on the whole optical data bank established within an ongoing European Glaucoma Prevention Study (EGPS) project, a multicentre multinational clinical trial concerning 1100 patients over a time period of 4 years.

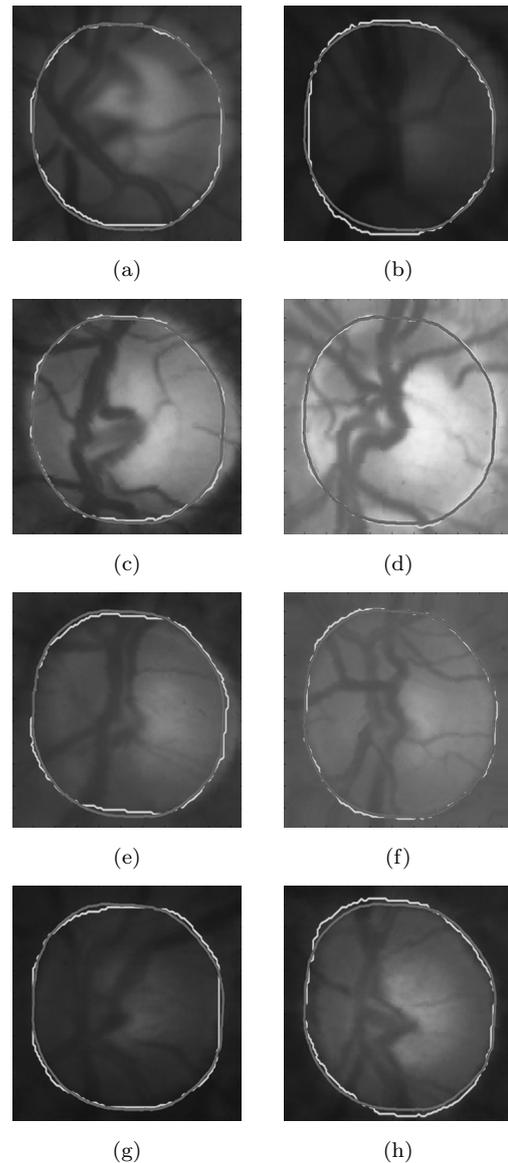


图 1 视盘形状训练样本图像集及其平均形状 (白色曲线为青光眼专家描绘的各样本视盘边缘曲线, 灰色曲线为全体样本视盘形状窄带水平集确定的平均形状: 满足 $\bar{\phi} = 0$ 的点集)

Fig. 1 The training optic disk shapes of early glaucoma patients and their zero level sets of the mean shape (white curves: manual shapes, gray curves: mean shape: $\bar{\phi} = 0$.)

4.2 视盘分割

利用 4.1 节建立的青光眼病人视盘边缘窄带水平集统计模型, 采用集形状窄带水平集分布统计模型的统计多层 Mumford-Shah 向量值图像分割模型 (12) 及其相应的水平集逐层迭代算法, 我们开展了早期青光眼病人视乳头图像中视盘的分割实验研究, 本节论述基本的实验研究结果. 为验证上述方法的有效性, 实验采用 4.1 节中配准后的彩色视乳头图像样本集中两个视盘分割最困难的第 8 个和第 2 个彩色视乳头图像作为原始图像. 第 8 个样本视

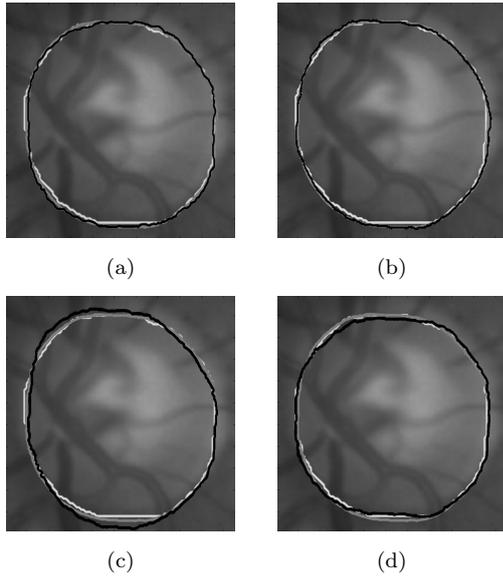


图 2 青光眼病人视盘形状窄带水平集分布统计模型形状实例 (图中, 白色、灰色和黑色曲线分别为青光眼专家描绘的视盘边缘曲线、统计平均形状和统计形状实例)

Fig. 2 Samples of zero level sets of the statistical shapes of the optic disk of early glaucoma patients (white curves: manual shapes; gray curves: mean shape; and black curves: statistical shapes.)

盘明显倾斜, 其形变在样本集中是最大的; 第 2 个样本不仅图像对比度非常小, 而且其视乳头周围有

明显的脉络膜萎缩晕, 这给视盘的正确分割带来很大困难. 为进行对比分析研究, 分别采用不同的模型参数进行视盘分割实验, 并且在原始视乳头图像上分别采用白色、黑色和灰色同时标识青光眼专家描绘的视盘边缘曲线和样本集平均形状与统计多层 Mumford-Shah 向量模型形状确定的视乳头边缘曲线. 图 3 和图 4 (见下页) 分别为第 8 个样本和第 2 个样本视盘分割实验结果. 图中, (a) 为配准后的原始视乳头图像, (b)~(f) 为采用不同模型参数的统计多层 Mumford-Shah 向量模型进行视盘分割的结果.

4.2.1 基本实验结果分析

图 3 和图 4 的实验结果表明, 无论是第 8 个样本还是第 2 个样本视乳头图像, 不依赖于形状先验知识 (即 $\eta^{11} = 0$) 均不能正确分割图像中的视盘, 如图 3 (b) 和图 4 (b). 另一方面, 同时依赖于形状先验知识和图像特征, 均可获得较为满意的分割结果, 如图 3 (c) 和图 4 (d).

4.2.2 形状先验知识对分割结果的影响分析

η^{11} 的不同取值, 即对形状先验知识的依赖程度不同, 获得的分割结果也不同, 如图 3 和图 4 中的 (c)~(e), 这说明视盘形状先验知识的确可以影响分割效果, 实际应用中应根据具体情况选取合适的先验知识权重参数 η^{11} .

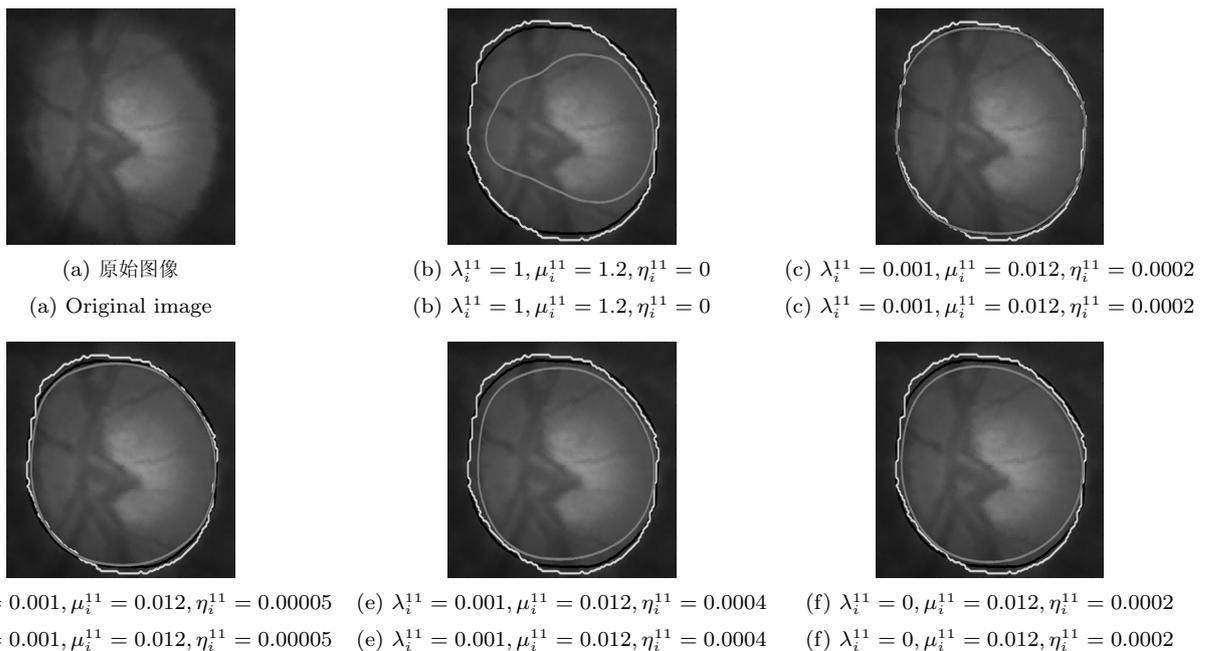


图 3 基于统计多层 Mumford-Shah 模型的第 8 个样本视乳头图像视盘分割结果 (图中, 白色、黑色和灰色曲线分别为青光眼专家描绘的视盘边缘曲线、视盘统计平均形状曲线和统计多层 Mumford-Shah 模型自动识别的视盘边缘曲线.)

Fig. 3 HMSMv-based segmentation of the eighth training shape of optic nerve heads (white curves: manual shape of optic disks; black curves: mean shape; and gray curves: SHMSMv shapes.)

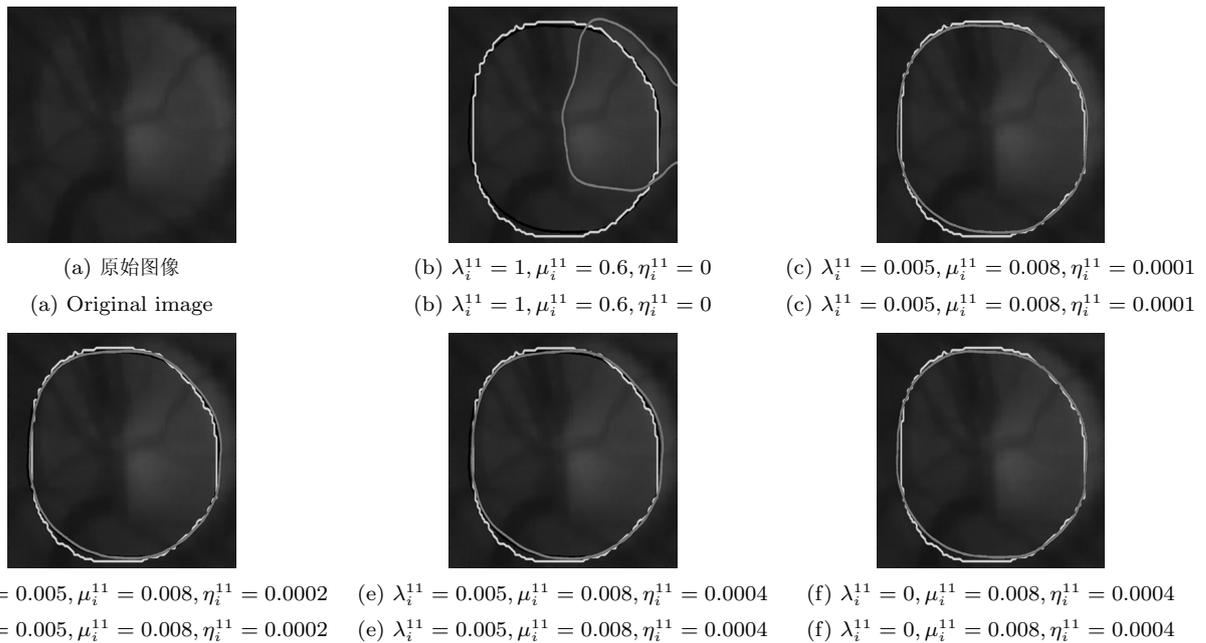


图 4 基于统计多层 Mumford-Shah 模型的第 2 个样本视乳头图像视盘分割结果 (图中, 白色、黑色和灰色曲线分别为青光眼专家描绘的视盘边缘曲线、视盘统计平均形状曲线和统计多层 Mumford-Shah 模型自动识别的视盘边缘曲线.)

Fig. 4 HMSMv-based segmentation of the second training shape of optic nerve heads (white curves: manual shape of optic disks; black curves: mean shape; and gray curves: SHMSMv shapes.)

4.2.3 图像特征对分割结果的影响分析

图像特征本身无疑直接影响分割结果, 有利于视盘分割的图像特征可改进分割效果, 如第 8 个样本图像视盘分割结果图 3(c) 和 (f) 所示. 但图像特征本身并不总是有利于视盘的分割, 如第 2 个样本图像视盘分割结果图 4(c) 和 (f) 所示. 因为第 2 个样本视乳头图像中视乳头周围有明显的脉络膜萎缩晕, 且该图像对比度非常小, 这非常不利于其视盘的分割. 实验表明, 在此情况下, 完全依赖于形状先验知识 (即 $\lambda_i^{11} = 0$) 甚至可获得更好的分割结果, 如图 4(f) 所示.

4.2.4 进一步的研究

由于实验所采用的样本形状集比较小, 导致相应的视盘形状窄带水平集统计分布模型表达的视盘先验知识非常有限, 因而相应的实验结果并不完全令人满意, 即无法通过该方法自动获得青光眼专家描绘的视盘边缘曲线. 因此, 实际应用中, 基于大样本的视盘形状先验知识统计建模是必须的. 另一方面, 视杯形状先验知识统计建模也是最终解决青光眼病人视乳头图像视盘、视杯和盘沿自动分割、度量的关键问题. 我们认为, 视乳头图像视盘、视杯和盘沿自动分割和度量问题可以采用统计多层 Mumford-Shah 模型得到解决, 但还有待进一步深入研究.

5 结束语

统计多层 Mumford-Shah 模型将形状窄带水平集分布统计模型表达的目标形状先验知识集成到多层 Mumford-Shah 向量值模型, 为基于知识的生物医学图像分割提供了一种有效的新方法. 采用该方法的彩色视乳头图像视盘分割实验表明, 该方法不仅能够有效地解决噪声污染、光照不均匀、对比度小、个体间差异大等视乳头 (视网膜) 图像分割中固有的难题, 而且通过利用青光眼性视乳头形变统计分布先验知识, 能够有效地分割被血管遮挡的早期青光眼病人视乳头图像.

另一方面, 形状窄带水平集分布统计模型和水平集分布统计模型具有同样的优点, 即它们建模时均不需要目标形状的标志点及其对应关系, 它们都能够有效地处理目标形状的拓扑结构的改变等, 但形状窄带水平集分布统计模型和水平集分布统计模型相比具有更小的计算复杂度, 特别是在建模的姿态配准预处理阶段, 即形状窄带配准模型比 Tsai 等提出形状训练图像集配准泛函方法更有效.

青光眼病人视乳头形状窄带水平集分布统计建模实验表明窄带水平集分布模型能够有效地表达视乳头形状变化的先验知识.

集成形状先验知识的多层 Mumford-Shah 模型是一种扩展性很强的图像处理泛函模型. 先验知识的表达与集成方法是其关键, 多层 Mumford-Shah 模型为其提供了描述真实图像世界的基本框架, 水

平集演化技术为其提供了强有力的数值处理手段。总之, 该统计多层 Mumford-Shah 模型为复杂的医学图像分割和分析提供了一种有效的新方法。另外, 第一作者可提供本文的彩色插图。

References

- Zeng X L, Staib L H, Schultz R T, Duncan J S. Segmentation and measurement of the cortex from 3D MR images using coupled surfaces propagation. *IEEE Transactions on Medical Imaging*, 1999, **18**(10): 927–937
- Cootes T F, Taylor C J, Cooper D H, Graham J. Active shape models — their training and application. *Computer Vision and Image Understanding*, 1995, **61**(1): 38–59
- Leventon M, Grimson E, Faugeras O. Statistical shape influence in geodesic active contours. In: Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Hilton Head Islands, USA: IEEE, 2000. 316–323
- Tsai A, Yezzi A, Wells W, Tempany C, Tucker D, Fan A. A shape-based approach to the segmentation of medical imagery using level sets. *IEEE Transactions on Medical Imaging*, 2003, **22**(2): 137–154
- Mumford D, Shah J. Optimal approximation by piecewise smooth functions and associated variational problems. *Communications on Pure and Applied Mathematics*, 1989, **42**(4): 577–685
- Chan T F, Vese L A. Active contours without edges. *IEEE Transactions on Image Processing*, 2001, **10**(2): 266–277
- Chen Y M, Tagare H D, Thiruvenkadam S, Huang F, Wilson D, Gopinath K S. Using shape priors in geometric active contours in a variational framework. *International Journal of Computer Vision*, 2002, **50**(3): 315–328
- Bresson X, Vandergheynst P, Thiran J P. A priori information in image segmentation: energy functional based on shape statistical model and image information. In: Proceedings of International Conference on Image Processing. Barcelona, Spain: IEEE, 2003. 425–428
- Yang J, Duncan J S. 3D image segmentation of deformable objects with joint shape-intensity prior models using level sets. *Medical Image Analysis*, 2004, **8**(3): 285–294
- Liu Guo-Cai, Wang Yao-Nan. Hierarchical Mumford-Shah model for image segmentation, denoising, and reconstruction based on level set methods by an iterative tier-by-tier algorithm. *Acta Automatica Sinica*, 2006, **32**(4): 534–540 (刘国才, 王耀南. 基于水平集逐层迭代算法的多层 Mumford-Shah 图像分割、去噪与重建模型. *自动化学报*, 2006, **32**(4): 534–540)
- Liu Guo-Cai, Wang Yao-Nan. Hierarchical Mumford-Shah model for vector-valued image segmentation, denoising, and reconstruction. *Acta Automatica Sinica*, 2007, **33**(6): 602–607 (刘国才, 王耀南. 多层 Mumford-Shah 向量值图像分割、去噪与重建模型. *自动化学报*, 2007, **33**(6): 602–607)
- Osher S, Sethian J A. Fronts propagating with curvature dependent speed: algorithms based on Hamilton-Jacobi formulations. *Journal of Computational Physics*, 1988, **79**(1): 12–49
- Adalsteinsson D, Sethian J A. A fast level set method for propagating interfaces. *Journal of Computational Physics*, 1995, **118**(2): 269–277
- Liu Guo-Cai, Wang Yao-Nan, Quan Hui-Min. Reconstruction segmentation and measurement of the color optic cup and disk image of optic nerve heads based on hierarchical

Mumford-Shah model. *Chinese Journal of Biomedical Engineering*, 2007, **26**(5): 700–708

(刘国才, 王耀南, 全惠敏. 基于多层 Mumford-Shah 向量模型的彩色视乳头图像杯盘重建、分割与度量. *中国生物医学工程学报*, 2007, **26**(5): 700–708)



刘国才 湖南大学电气与信息工程学院副教授, 美国加州大学戴维斯分校生物医学工程系生物医学工程博士后研究员。2007 年获湖南大学模式识别与智能系统博士学位。主要研究方向为图像识别、生物医学图像处理 and 机器视觉。本文通信作者。

E-mail: lgc630819@sina.com, cailiu@ucdavis.edu

(**LIU Guo-Cai** Associate professor at the College of Electrical and Information Engineering, Hunan University and a postdoctoral researcher in the Department of Biomedical Engineering at University of California, Davis, USA. He received his Ph.D. degree from Hunan University in pattern recognition and intelligent system. His research interest covers image recognition, medical image processing, and machine vision. Corresponding author of this paper.)



王耀南 湖南大学电气与信息工程学院教授。1994 年获湖南大学控制科学与控制工程专业博士学位。曾为国防科技大学和德国洪堡博士后研究员。主要研究方向为智能控制、图像处理和智能机器人。E-mail: yaonan@hnu.cn

(**WANG Yao-Nan** Professor at the College of Electrical and Information

Engineering, Hunan University. He was a postdoctoral scholar at National University of Defense Technology in 1995 and was supported by Alexander von Humboldt Foundation. He received his Ph.D. degree from Hunan University. His research interest covers intelligent control, image processing, and intelligent robotics.)



段宣初 中南大学湘雅二医院眼科教授, 青光眼专家。曾为美国威斯康星大学麦迪逊分校博士后研究员。1996 年获中南大学 (原湖南医科大学) 医学博士学位。主要研究方向为青光眼的早期诊断和治疗, 视觉神经保护和图像分析。

E-mail: duanxchu@yahoo.com.cn

(**DUAN Xuan-Chu** Professor in the Department of Ophthalmology of the 2nd Xiangya Hospital at Central South University. He is specialized in glaucoma. He was a postdoctor researcher at University of Wisconsin-Madison, USA. He received his Ph.D. degree from Hunan Medical University (called Xiangya Medical College, Central South University now). His research interest covers early diagnosis and treatment of glaucoma, optic nervous imaging analysis, and neuro protection.)