

基于纹理特征的多区域水平集图像分割方法

王慧斌¹, 高国伟^{1,2}, 徐立中¹, 文成林³

(1. 河海大学计算机与信息学院, 江苏南京 211100; 2. 安阳师范学院软件学院, 河南安阳 455000;
3. 杭州电子科技大学自动化学院, 浙江杭州 310018)

摘 要: 现有多区域水平集方法大多利用复杂的能量函数来驱动多个水平集函数的演变, 这样不仅模型复杂且存在很多限制. 为此本文提出一种基于纹理特征的多区域水平集方法, 利用任意数量的水平集函数来对相应数量的图像区域进行分割. 本文首先对图像的颜色和纹理信息建立联合分布并将其代入能量函数; 引入平滑概率标签, 根据概率性质建立基于标签驱动的多区域水平集迭代更新方程. 之后将每个水平集投影到离散概率空间得到一系列近似标签, 并由这些标签得到基于多区域水平集的先验概率, 从而将多个轮廓演变信息代入统计框架. 而不同区域的统计参数也通过最小化能量函数由概率标签迭代更新. 通过与其他分割算法在大量复杂实景图像上的实验对比, 验证了本文算法的有效性.

关键词: 图像分割; 水平集; 多区域分割; 主动轮廓

中图分类号: TP391 **文献标识码:** A **文章编号:** 0372-2112 (2018)11-2588-09

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2018.11.004

A Multi-region Level Set Model Based on Texture Feature for Image Segmentation

WANG Hui-bin¹, GAO Guo-wei^{1,2}, XU Li-zhong¹, WEN Cheng-lin³

(1. College of Computer and Information, Hohai University, Nanjing, Jiangsu 211100, China;
2. School of Software Engineering, Anyang Normal University, Anyang, Henan 455000, China;
3. School of Automation, Hangzhou Dianzi University, Hangzhou, Zhejiang 310018, China)

Abstract: Most of the existing level set methods for multi-region use complex energy functions to drive the evolution of multiple level sets, which not only makes the model more complex but also has many limitations. In this paper, we propose a fast multi-region active contour method based on texture features by using an arbitrary number of level sets functions to segment an image into regions of the corresponding amount. We first establish a joint distribution of color and texture information and bring it into data term of energy function. Then, we introduce the smooth probability label and establish an update equation of level set function for multi-region driven by probability labels. And, each level set for different regions is projected into the discrete space to get a series of approximate labels. Due to these labels, a prior probability based on multi-level-sets is obtained, which introduce the evolution information of multiple contours into the statistical framework. The statistical parameters of each region are also updated iteratively from the smooth probability labels by minimizing the energy function. We experimentally compare the proposed approach with other methods on complicated real-world images and demonstrate its good performance in practice.

Key words: image segmentation; level set; multi-region segmentation; active contours

1 引言

图像分割是根据需要将图像分成多个子区域的过程, 是分析理解图像的一个必要基础技术. 目前已出现

多种分割算法, 如直方图阈值、区域增长、统计聚类、图割等. 其中水平集方法得益于成熟的数学模型, 能够最小化任意的能量函数, 因而可以很自然地扩展以适应关于图像及其结构的各种信息, 并以其像素级的精确

性、光滑规则的分割轮廓等特点被广泛应用于多个领域^[1-5].

现有水平集方法大多针对两区域属于竞争模型^[6,7],学者们也尝试将其应用至多区域分割^[8-12],典型方法是将水平集函数与每个区域相关联,并以耦合方式演化这些函数以抑制分割区域产生间隙或重叠^[8].其他方法如文献[9]将 Chan-Vese 模型^[7]拓展到多区域,但只能用 n 个水平集函数分割 2^n 个区域.之后文献[10]在每次迭代的多个区域中选出一个最大的区域作为背景,其他区域与之进行竞争,但没有考虑区域相邻情况.文献[11]中采用联合优化多个水平集来分割多个重叠细胞,并在能量函数中引入细胞内和细胞间的限制,方法复杂且应用较为局限.也有方法使用单个水平集函数分割多个区域^[12,13],但这类方法忽略了同类区域间的联系.上述方法大多需要通过较难实现的能量函数来调节多个水平集的互动关系,往往有一定限制.此外,通过求解偏微分方程的演化过程以及人工初始化也导致这些算法具有较高的计算代价.

此外,现有水平集方法大多使用全局或局部的灰度、颜色信息,很难处理一些富含纹理的自然图像.因此基于纹理的水平集方法被提出,这些方法大致可分为两类,一类是使用 Gabor 滤波^[14]或其他高维特征^[15,16],但大多只针对灰度图像;另一种类于稀疏表示^[17,18]可用来分割彩色图像.与梯度和均值等传统特征相比,纹理特征的维度更高,这不可避免地使建模和实现复杂化.而基于稀疏表示的水平集方法词典构造的计算代价较大,且利用图像区块相似表征纹理结构,对全局空间信息考虑较少.以上这些方法通过建模复杂的能量函数进行分割,并不能有效地表征分割中的纹理,更重要的是大多不能进行多区域分割.

多区域分割能力不足可以说是制约水平集推广应用的关键因素之一,究其原因主要是建模思想一直局限于多个水平集函数间的关系上,使得能量函数越来越复杂.本文提出一种独立于区域的数量多区域分割方法,利用高斯混合模型对纹理增强的图像观测值建模,并将其带入简单有效的能量函数中.为了进一步减少微小的拓扑分裂,本文还引进了局部平滑概率标签,在图像区块内部建立统计依赖,并利用该标签来驱动多个水平集函数的更新.此外,还建立了来自于水平集函数的几何先验,这样水平集就在概率标签的驱动下进行演变,并以先验的形式作用于下一次概率标签的估计中.最后,本文通过概率性质改写了能量函数,在统计框架下通过平滑概率标签高效的迭代更新分割区域的统计参数.

2 颜色及纹理特征

令一个 d 维的随机变量 $I(x_j), j = \{1, 2, \dots, N\}$ 来表

示一幅图像中像素 x_j 的观测值, Ω 是二维图像空间,并令 $\Omega_i, i \in \{1, 2, \dots, K\}$ 用来表示图像不同的区域. 为便于表示,令 $I_j = I(x_j)$.

本文先将颜色由 RGB 映射到 $L * a * b$ 空间,有 $I_j = [I_j^L, I_j^a, I_j^b]^T$. 因纹理具有局部邻域属性,区域大小影响纹理的描述. 本文使用基于边缘极性(方向)尺度选择的纹理提取方法,而极性^[19]是由 x_j 附近像素的主导方向计算,定义为:

$$\rho_{\sigma_j} = \frac{\left| \sum_{j=1}^N G_{\sigma_j} [\nabla I^L \cdot \zeta]_+ - \sum_{j=1}^N G_{\sigma_j} [\nabla I^L \cdot \zeta]_- \right|}{\sum_{j=1}^N G_{\sigma_j} [\nabla I^L \cdot \zeta]_+ + \sum_{j=1}^N G_{\sigma_j} [\nabla I^L \cdot \zeta]_-} \quad (1)$$

其中 $\rho \in [0, 1]$, σ_n 是像素 x_j 高斯平滑核 G_{σ_j} 的方差也可认为是窗口的尺度, ∇I^L 为颜色分量梯度,求 ∇I^L 时不需要平滑. ζ 为垂直于主方向也就是二阶矩阵主特征向量的单位向量. 操作算子 $[\cdot]_+$ 和 $[\cdot]_-$ 分别衡量窗口 G_{σ_j} 中有多少梯度向量在主方向的“正侧”和“负侧”上.

极性 ρ_{σ} 随尺度 σ 变化而变化,当所有的 ρ_{σ} 值保持趋近 1 时表示边缘. 而纹理包含多个方向,方向的主导性会降低, ρ_{σ} 会随着 σ 的增加衰减. 本文利用极性与图像结构的关联,采用文献[19]的方法来选择合适的尺度. 首先对图像 I^L 关于尺度 $\sigma^m = \frac{m}{2}$, 且 $m = 0, 2, \dots, 7$ 计算一系列的极性图谱 ρ . 然后,对于每个 m 得到的 ρ_{σ} 使用方差为 $2\sigma^m$ 的高斯核滤波得到光滑的极性图 $\tilde{\rho}^m$. 对 x_j 在连续的 m 上求得第一个满足 $\tilde{\rho}^{m+1} - \tilde{\rho}^m \leq 2\%$ 的即为所选的尺度,尺度为 $\sigma'_j = 0.5 \times (m + 1)$.

本文使用由上述方法确定的 σ'_j 来计算加窗二次矩阵作为纹理描述符:

$$\mathfrak{w}_j = G_{\sigma'_j} * (\nabla I^L) (\nabla I^L)^T \quad (2)$$

其中 \mathfrak{w}_n 是 2×2 的对称正半定矩阵. 对一固定尺度 σ 的像素 x_j , 令 λ_1 和 λ_2 代表 \mathfrak{w}_j 的特征值. 当 $\lambda_1 \geq \lambda_2$ 时,局部邻域具有主方向. 本文使用 \mathfrak{w}_j 特征值代替其全体原始数据,由二次矩阵的特征值,即可得到各向异性和归一化的纹理对比度^[20]作为图像纹理:

$$I_j^{\text{Pol}} = \rho_{\sigma'_j}, I_j^{\text{Ani}} = 1 - \frac{\lambda_2}{\lambda_1}, I_j^{\text{Con}} = 2 \sqrt{\lambda_2 + \lambda_1} \quad (3)$$

则图像观测值由 6 个颜色和纹理分量组成:

$$I_j = [I_{\sigma'_j}^L, I_{\sigma'_j}^a, I_{\sigma'_j}^b, I_j^{\text{Pol}}, I_j^{\text{Ani}}, I_j^{\text{Con}}]^T \quad (4)$$

上式中前三个分量是在选定的尺度 σ'_j 下使用高斯平滑后的 $L * a * b$ 空间向量,同样三个纹理分量也是以选定的尺度计算得到. 如图 1 所示, $L * a * b$ 空间中各颜色分量尤其是图 1(b) 和 (c) 中的斑马条纹由可变尺度的 $G_{\sigma'_j}$ 滤除,而条纹对应较高的各向异性 I^{Ani} 和纹理对比度 I^{Con} .

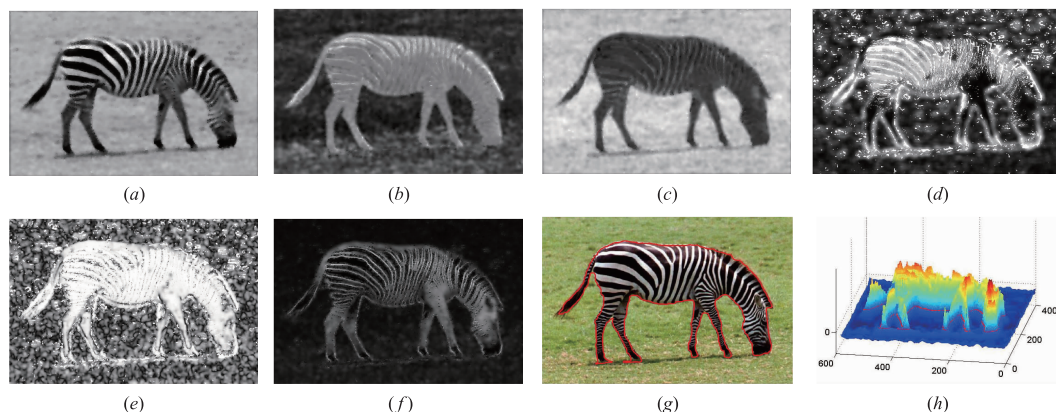


图1 纹理分量: (a) $I_{\sigma_j}^L$; (b) $I_{\sigma_j}^a$; (c) $I_{\sigma_j}^b$; (d) I^{Pol} ; (e) I^{Ani} ; (f) I^{Con} ; (g) 分割轮廓; (h) 水平集函数.

高斯混合模型模型 (Gaussian mixture model, GMM) 被用来建模包含颜色和纹理特征观测值 x_j 的联合分布, 概率密度表示为:

$$\mathfrak{F}(I_j | \Pi, \Theta) = \sum_{i=1}^K \pi_i p(I_j | \theta_i) \quad (5)$$

其中 $\Pi = \{\pi_i\}$, $i = \{1, 2, \dots, K\}$ 为 x_j 属于区域 Ω_i 的先验概率并且满 $0 \leq \pi_i \leq 1$, $\sum_{i=1}^K \pi_i = 1$. 高斯分布 $p(I_j | \theta_i)$ 为 GMM 的元素, 可表示为:

$$p(I_j | \theta_i) = \frac{1}{(2\pi)^{d/2} |\Sigma_i|^{1/2}} \exp\left\{-\frac{1}{2}(I_j - \mu_i)^T \Sigma_i^{-1} (I_j - \mu_i)\right\} \quad (6)$$

其中 $\theta_i = \{\mu_i, \Sigma_i\}$, μ_i 为均值, Σ_i 是 $d \times d$ 的方差矩阵, $|\Sigma_i|$ 是 Σ_i 的行列式, 维度 $d = 6$. 维度 d 仅影响概率分布, 而不直接影响水平集函数的演化.

3 多区域水平集模型

3.1 能量函数与平滑概率标签

本文目标是使用高维模型来精确地表示图像特征, 并在低维空间中高效地进行分割. 为了将由 N 个像素分割为 K 个区域, 假定分割区域的数量 K 是给定的, 本文使用一定数量的有符号距离函数 φ_i 作为水平集来分割得到相应数量的区域 Ω_i , 则多区域能量函数建模为:

$$E(\Phi, \Theta) = \sum_{i=1}^K \int_{\Omega} (-\log p(I(x) | \theta_i) H(\varphi_i) + \beta |\nabla H(\varphi_i(x))|) dx + \gamma \int_{\Omega} \left(\sum_{i=1}^K H(\varphi_i(x)) - 1\right)^2 dx \quad (7)$$

其中 $H(\cdot)$ 为单位阶跃函数, 第一项中分别为数据项和轮廓的长度项. 多个分割曲线在分割过程中必然会出现重叠或者间隙, 当两个轮廓重叠时 $\sum_{i=1}^K H(\varphi_i(x))$

$= 2$; 而当某一像素不被任何分割曲线包括时 $\sum_{i=1}^K H(\varphi_i(x)) = 0$, 本文引入上式中的第二项作为规则项来抑制重叠和间隙. 权重 β 和 γ 用来调节各项关系. 由于 $H(\cdot)$ 不连续为不可导函数, 在实际中经常使用近似来代替^[7], 令 $\varphi_{ij} = \varphi_i(x_j)$, 本文使用双曲正切函数达到同样目的:

$$\tilde{H}(\varphi_{ij}) = \frac{1}{2} \left(1 + \tanh\left(\frac{\varphi_{ij}}{2\varepsilon}\right)\right) = \frac{1}{1 + e^{-\varphi_{ij}/\varepsilon}} \quad (8)$$

当 ε 趋于零时, 等式成立. 当 $\varepsilon = 1$ 时, 上式则为 Logistic 方程.

水平集方法对于初始化较为敏感, 多以手工方式交互进行, 在多区域时会造成诸多不便, 本文使用一种自动初始化方法. 首先应用 K -means 算法对 6 维纹理增强图像进行聚类, 聚类数为 K . 得到的这些聚类的均值和方差矩阵用来初始化式(6)中 GMM 的 μ_i 和 Σ_i . 则像素 x_j 属于 Ω_i 的后验概率由下式给出:

$$p(\Omega_i | x_j) = \frac{\pi_i p(I_j | \theta_i)}{\sum_{n=1}^K \pi_n p(I_j | \theta_n)} \quad (9)$$

其中, 先验分布 π_i 由 K -means 得到的每个聚类中的像素数与总像素数的比值来初始化.

为减少轮廓初始化和演化中的零碎区域, 本文用 α_j 表示 x_j 的邻域, 得到平滑概率标签:

$$p_{ij} = \frac{1}{|\alpha_j|} \sum_{l \in \alpha_j} p(\Omega_i | x_l) \quad (10)$$

其中 $|\alpha_j|$ 是 x_j 邻域 α_j 中像素总数, p_{ij} 需要进行归一化处理. 不同于现有水平集方法直接对观测值或水平集滤波, 本文的滤波过程施加在概率空间, 能够保留更多的信息. 方法在图像区块中建立统计依赖, 本质上是使用了局部信息.

类似文献[21], 本文利用优势对数 (Logarithm of the odds ratio) 定义水平集函数 φ :

$$\varphi_{ij} \stackrel{\text{def}}{=} \varepsilon \log \frac{p_{ij}}{1-p_{ij}} \quad (11)$$

其中参数 ε 定义了水平集 φ 的尺度. 上式将概率映射到了欧式空间, 且没有改变水平集函数为带符号距离函数的本质. 但上式仅用来进行定义及初始化, 水平集的演变将在下文利用 Euler-Lagrange 方程来进行.

本文在代价函数中的规则项能够有效的抑制多个分割轮廓的间隙和重叠, 但在复杂图像的快速分割中偶尔还会出现. 轮廓重叠即某个区域中特定的像素属于了两个或者两个以上的区域, 也就是说该像素具有多重标签; 同理若出现间隙, 则说明像素没有指派标签. 周期性初始化是水平集分割常用手段^[23], 而概率标签的唯一性则能在一定程度解决分割曲线重叠和空隙的问题, 因此本文使用式(11)进行周期初始化来保证分割的稳定进行.

3.2 多区域水平集更新及几何先验

固定参数 θ_i , 由梯度下降得到的 φ_i 的演化方程:

$$\varphi_{ij}(t + \Delta t) = \varphi_{ij}(t) + \frac{\partial \varphi_{ij}}{\partial t} \Delta t \quad (12)$$

其中 Δt 是步长而 $\frac{\partial \varphi_{ij}}{\partial t}$ 是对式(9) $E(\Phi, \Theta)$ 求一阶导数得到:

$$\begin{aligned} \frac{\partial \varphi_{ij}}{\partial t} = & \delta(\varphi_{ij}) \left[\log p(I_j | \theta_i^{(k)}) + \beta \operatorname{div} \left(\frac{\nabla \varphi_{ij}}{|\nabla \varphi_{ij}|} \right) \right. \\ & \left. - 2\gamma \left(\sum_{i=1}^K H(\varphi_{ij}) - 1 \right) \right] \end{aligned} \quad (13)$$

其中 δ 是 Dirac delta 函数常使用近似值来代替^[6,7]. 与以往算法不同, 本文的 $\delta(\cdot)$ 通过式(8)中定义的 $\tilde{H}(\varphi_j)$ 得到:

$$\delta(\varphi_{ij}) = \frac{\partial}{\partial \varphi_{ij}} \tilde{H}(\varphi_{ij}) = \frac{1}{\varepsilon} \frac{e^{-\varphi_{ij}/\varepsilon}}{(1 + e^{-\varphi_{ij}/\varepsilon})^2} = \frac{1}{\varepsilon} p_{ij}(1 - p_{ij}) \quad (14)$$

将式(8)、(13)和(14)代入式(12)可得到概率化的水平集函数更新方程:

$$\begin{aligned} \varphi_{ij}(t + \Delta t) = & \varphi_{ij}(t) + \Delta t \frac{1}{\varepsilon} p_{ij}(1 - p_{ij}) \left[\log p(I_j | \theta_i^{(k)}) \right. \\ & \left. + \beta \operatorname{div} \left(\frac{\nabla \varphi_{ij}(t)}{|\nabla \varphi_{ij}(t)|} \right) - 2\gamma \left(\sum_{i=1}^K \frac{1}{1 + e^{-\varphi_{ij}(t)/\varepsilon}} - 1 \right) \right] \end{aligned} \quad (15)$$

其中 p_{ij} 由式(9)和(10)得到. 针对式(9)中的先验概率 π_i , 本文提出一种基于水平集函数演变的几何先验. 因本文水平集函数 φ_{ij} 是由平滑概率标签 p_{ij} 通过式(11)初始化, 假设由上式迭代更新得到的水平集函数 φ_{ij} 总有一个概率标签 \tilde{p}_{ij} 与其对应且服从式(11)的定义, 即有 $\varphi_{ij} = \varepsilon \log(\frac{p_{ij}}{1-\tilde{p}_{ij}})$, 经过变形就可得到由水平集函数确定的概率标签的近似值:

$$\tilde{p}_{ij} = \frac{1}{1 + e^{-\varphi_{ij}/\varepsilon}} \quad (16)$$

其中 φ_{ij} 由式(15)得到. 通过比较图 2(c) 和 (d), 可以看到 \tilde{p}_{ij} 反映了 φ 的演变, 更接近图 2(a) 和 (b) 中的最终的结果, 之后利用类似有限混合模型(FMM)的方法得到几何先验:

$$\pi_i = \frac{\sum_{j=1}^N \tilde{p}_{ij}}{\sum_{j=1}^N \sum_{i=1}^K \tilde{p}_{ij}} \quad (7)$$

π_i 可以理解为是每次 φ 演变后选中第 i 个区域的概率, 它将 φ 中蕴含的全局几何信息通过 Bayes 推断代入统计框架, 这使式(9)中后验概率的边缘在零水平集附近收敛. 因此, 尽管 FMM 只考虑每个观察值独立于标签, 但本文中的标签是建立在分割轮廓演变的空间约束上.

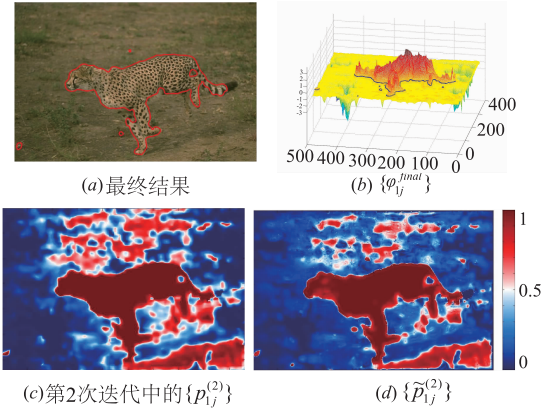


图2 概率标签: ($|\alpha_j| = 7 \times 7$)

3.3 参数估计

本文提出一种新的基于概率标签的区域参数估计方法. 将式(11)带入式(8), 可以得到:

$$\tilde{H}(\varphi_{ij}) = p_{ij} \quad (18)$$

$\tilde{H}(\cdot)$ 可视为像素 x_j 属于对应区域的概率, 不同于单位阶跃函数, 这里的软指派可以反映更多的不确定性, 例如相邻的像素分别在边缘内外. 利用上式改写式(7)中的能量函数并离散化, 将(6)中定义的概率密度 $p(I_j | \theta_i)$ 代入, 则有:

$$\begin{aligned} E(\Omega, \Theta) = & - \sum_{j=1}^N \sum_{i=1}^K p_{ij} \log p(I_j | \theta_i) + \beta \sum_{j=1}^N \sum_{i=1}^K \|\nabla p_{ij}\| \\ & + \gamma \sum_{j=1}^N \left(\sum_{i=1}^K p_{ij} - 1 \right)^2 \\ = & \sum_{j=1}^N \sum_{i=1}^K p_{ij} \left\{ \frac{d}{2} \log(2\pi) + \frac{1}{2} \log |\Sigma_i| \right\} \\ & + \sum_{j=1}^N \sum_{i=1}^2 p_{ij} \left\{ \frac{1}{2} (I_j - \mu_i)^T \Sigma_j^{-1} (I_j - \mu_i) \right\} \\ & + \beta \sum_{j=1}^N \sum_{i=1}^K \|\nabla p_{ij}\| + \gamma \sum_{j=1}^N \left(\sum_{i=1}^K p_{ij} - 1 \right)^2 \end{aligned} \quad (19)$$

关于 μ_i 最小化能量函数即是求上式关于均值 μ_i 的一阶导数并令其等于零, 则可得到:

$$\mu_i = \frac{\sum_{j=1}^N p_{ij} I_j}{\sum_{j=1}^N p_{ij}} \quad (20)$$

同样的对式(19)求解 $\partial E / \partial \Sigma_j^{-1} = 0$, 得到:

$$\Sigma_i = \frac{\sum_{j=1}^N p_{ij} (I_j - \mu_i) (I_j - \mu_i)^T}{\sum_{j=1}^N p_{ij}} \quad (21)$$

不同于之前的水平集方法, θ_i 的估计是通过 p_{ij} 作为一个软指派来获得的, 这可以给 θ_i 的计算带来更多的信息, 从而有效地加速分割. 以上统计参数的更新与 GMM-EM^[22] 的 M 步相似, 但本文是通过最小化能量函数得到, 而 EM 则通过最大化对数似然函数来获得.

为便于理解, 算法流程总结如算法 1 所示.

算法 1 基于纹理特征的多区域水平集分割算法

输入: 原始图像 I
 输出: 基于水平集隐式表达的分割曲线
 初始化: $L=0, m=0, 1, \dots, 7$
 Step 1: 将 I 转换至 $L * a * b$ 空间, 并分别使用多个 $\sigma^m = m/2$ 对 I^L 通过(1)得到 8 个极性图谱 ρ_{σ^m} ;
 Step 2: 对 ρ_{σ^m} 和 $\rho_{\sigma^{m+1}}$ 分别使用 $G_{2\sigma^m}$ 和 $G_{2\sigma^{m+1}}$ 卷积得到 $\tilde{\rho}^m$ 和 $\tilde{\rho}^{m+1}$;
 Step 3: $\tilde{\rho}^{m+1} - \tilde{\rho}^m \leq 2\%$, 则选定尺度 $\sigma'_j = (m+1)/2$ 并执行下一步, 否则 $m = m+1$ 转到 Step 2;
 Step 4: 利用 σ'_j 通过式(2)~(4)得到纹理增强的图像特征;
 Step 5: 使 K -means 方法得到初始均值 μ_i^0 , 方差 Σ_i^0 和先验 π_i^0 , 并通过式(9)~(11)得到初始水平集 φ^0 ;
 Step 6: 使用式(20)和式(21)更新 μ_i^{k+1} 和 Σ_i^{k+1} , 并通过式(16)和式(17)更新 π_i^{k+1} ;
 Step 7: 通过式(9)和式(10)计算得到平滑概率标签 p_{ij}^{k+1} , 并计算似然函数 L^{k+1} ;
 Step 8: 若满足周期, 则使用式(11)重新初始化得到 φ^{k+1} , 否则通过式(15)更新 φ^{k+1} ;
 Step 9: 若 $L^{k+1} - L^k \leq 0.1\%$ 则停止, 否则 $k = k+1$ 转到 Step 6.

4 实验结果分析

本文算法需要首先确定参数, 其中 $\Delta t / \varepsilon$ 控制 φ 的




图3 纹理合成图像($\beta=0.8, \gamma=0.3$): (a)本文算法初始轮廓; (b)本文算法分割结果; (c)本文算法均值标签图; (d)DMAC算法结果; (e)MCV.

演变. 若 φ 的演化速度太快, 会导致对数似然函数 L 收敛于局部最优使得轮廓太紧, 这时就要减少 $\Delta t / \varepsilon$ 以减缓轮廓的演变. 而 β 控制轮廓捕捉形状大小的灵敏度, 通常在 $[0, 1]$. 参数 γ 取值一般在 0.5 附近. 实验默认设置 $\Delta t = 0.2$ 和 $\varepsilon = 0.3$, 并根据实际情况调整 β 和 γ , 重复初始化周期默认设置为 $T=6$. 由于算法由概率标签驱动, 当 $L^{[22]}$ 收敛时, 水平集演变无法获得更多信息, 因此本文利用 L 的收敛作为停止条件, 也可设置固定的迭代次数. 本文使用 Global Consistency Error (GCE)^[27] 和 Normalized Probabilistic Rand (NPR) index^[26] 来定量评估分割性能. GCE 值越低分割的质量越好, 而 NPR 则越高越好. 实验图像来自 Berkeley Segmentation image database (BSD)^[27], 标准结果也来自该数据库. 所有参与对比验证的算法都在个人电脑 (Intel i5 3.2GHz, 8GB RAM) 和 MATLAB 环境中执行和测试.

首先利用来自 Brodatz 纹理库^[28] 的合成图像验证本文算法对于多纹理的分割效果. 图 3 中含有四种纹理但颜色相近. 图 3(a) 是利用 K -means 方法自动初始化得到的轮廓, 可见本文的纹理描述算子能够很好的滤除规则的纹理, 但是对于大条纹和颜色过于相近的情况, 则需使用本文提出的多区域水平集方法进一步分割. 图 3(b) 和 (c) 分别为基于稀疏纹理字典的主动轮廓方法 (DMAC)^[18] 以及使用 RGB 特征的多区域 CV 模型 (MAC)^[9] 得到的结果.

图 4 给出了本文算法分别使用纹理特征和 RGB 颜色特征在自然图像上分割结果的对比. 算法使用 3 个水平集函数图片分割为 3 个区域, 图 4(a)~(c) 是初始的 3 个水平集, 图 4(d) 是初始的分割轮廓. 能够看出自动初始化得到的水平集包含较多图像结构信息, 分割结果如图 4(e)~(h) 所示. 图 4(i) 给出了本文算法不使用纹理特征而使用 RGB 特征得到的结果. 图 4(j)~(l) 为多区域分割算法包括 MCV、多区域局部拟合模型 (MLBF)^[23] 以及使用单个水平集函数基于图割的多区域主动轮廓 (GPAC)^[12] 分割得到的结果. 对比算法由手工初始化且参数经过优化, 由于图像中区域颜色较为相近, 只用颜色信息无法完整将目标分割出来.

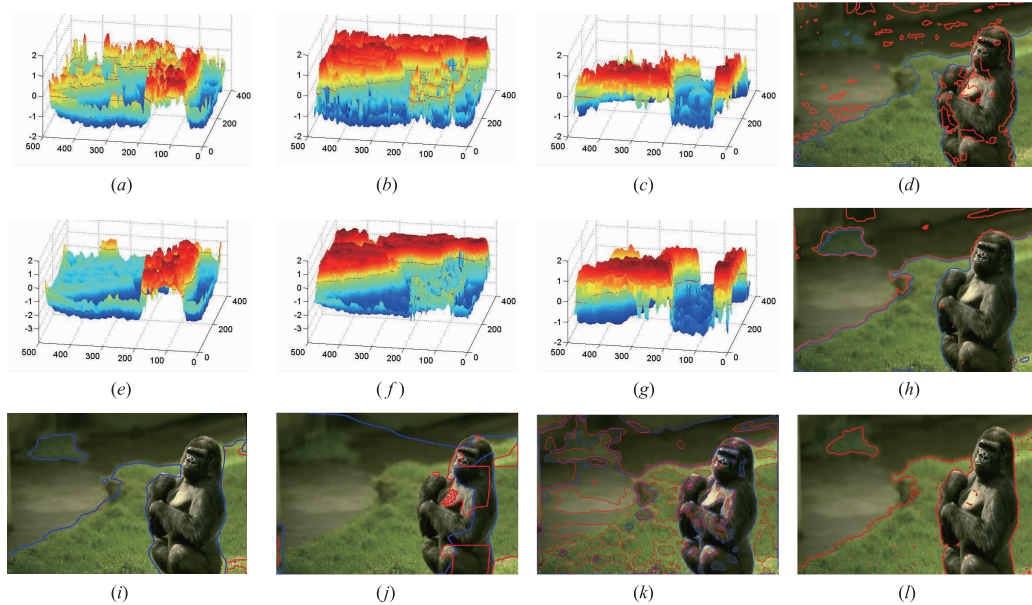


图4 纹理分量在分割中的应用($\beta=0.5, \gamma=0.1$): (a)~(c)初始水平集; (d)初始轮廓; (e)~(g)最终水平集; (h)最终轮廓; (i)本文算法使用RGB特征; (j)MAC; (k)MLBF; (l)GPAC.

图5给出了使用不同 $|\alpha_j|$ 得到的分割结果,由图可知平滑概率标签能够有效减少分割轮廓中的碎片区域而不影响分割边缘的准确性,但是过大的 $|\alpha_j|$ 会造成欠分割,这是由于本文算法中水平集的更新依赖于概率标签.此外水平集的演化还受概率分布及上次迭代的水平集的作用,因此概率标签与分割曲线并不完全对应.为了更客观的说明 $|\alpha_j|$ 对分割的影响,本文在BSD数据集500张图片上,当 $K=3$ 时,使用不同 $|\alpha_j|$ 的平滑概率标签进行对比试验,由表1中的NPR值可以得出,尺度并非越大越好,因此本文默认设置 $|\alpha_j| = 7 \times 7$.

图6给出了与其他多区域水平集算法的对比试验,另外4种算法分别是上文提到的MCV、MLBF、GPAC以及DMAC方法.本组实验调整这四种方法的参数以达到最佳效果,图中的分割区域 $K = \{3, 3, 4, 3\}$,本文算法是自动初始化,其他算法采用相同的手工初始化.从图6可以看出,本文提出的算法分割效果较好,表2给出了各个算法的耗时,其中GPAC和DMAC主要函数由C++编译.从中可以看出,由于本文水平集的演变由概率标签驱动,有着较低的计算代价.

表1 $K=3$ 在BSD数据集500张图片上使用不同 $|\alpha_j|$ 分割结果的量化比较

	—	3 × 3	7 × 7	9 × 9	15 × 15
NPR	0.6955	0.6980	0.7008	0.7009	0.6917
GCE	0.2169	0.2095	0.1867	0.1760	0.1622

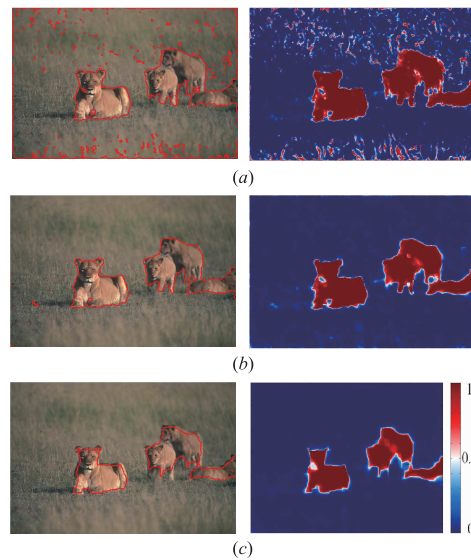


图5 不同 $|\alpha_j|$ 的平滑概率标签分割结果($\varepsilon = 0.08, \beta = 1, \gamma = 0.5$): (a)3×3; (b)7×7; (c)15×15.

表2 图6中各算法对各个图片分割耗时(单位:秒)

	MCV	MLBF	GPAC	DMAC	本算法
牛	38.05	10.46	5.49	41.98	3.91
鹿	68.51	20.12	14.87	50.90	8.57
犀牛	79.82	21.88	15.12	51.68	11.30
花	66.64	16.86	6.59	45.19	4.85

图7给出了一组图片来对比本文算法与常见的多区域分割算法,包括高斯混合模型(GMM-EM)、基于空间约束的GMM模型(SVGMM)^[24]和图割算法

(KGC)^[25]的分割效果. 图中分割区域由上到下分别是3、3、4、5、3和4. 四种方法都使用 K -means初始化, 由于本文算法将全局几何信息带入统计框架, 又通过联合

分布将纹理信息带入水平集框架, 取得了较好的分割结果. 尤其是对于前面两幅及最后一幅富含纹理的图像, 单纯依靠颜色信息的其它3种算法无法有效分割.

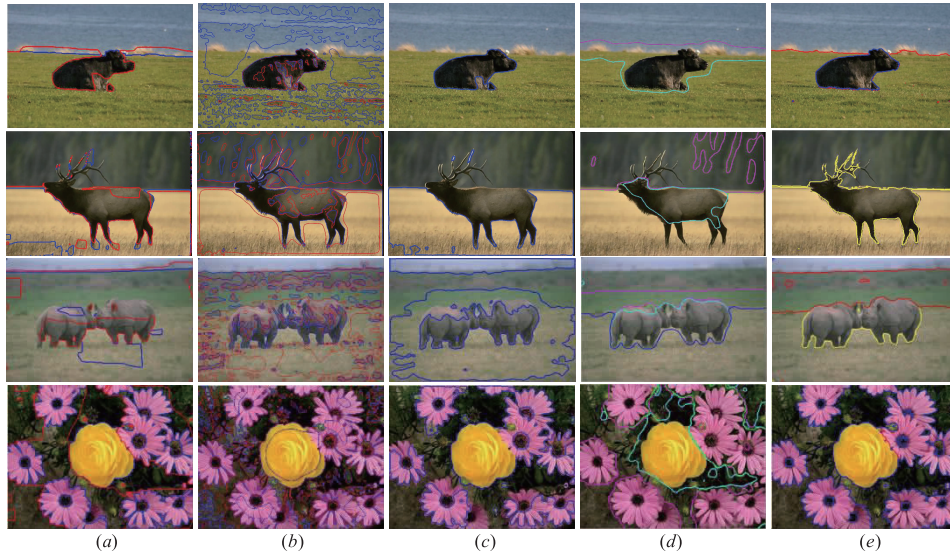


图6 与多区域水平集方法对比(由上自下: 牛、鹿、犀牛和花图片): (a)MCV; (b)MLBF; (c)GPAC; (d)DMAC; (e)本文算法.



图7 与多区域分割方法对比: (a)本文算法得到的分割轮廓. (b)本文算法得到的均值标签; (c) GMM-EM; (d)SVGMM; (e)KGC.

为进一步说明本文算法的有效性, 本文与上述对比算法在 Berkeley 数据库的 500 张图片上, 当 K 分别为

3、5、7、10、15 和 20 的情况下,采用 NPR 和 GCE 来量化分析分割结果,较高的 NPR 值表示更好的分割性能,而 GCE 则相反. BSD 每张图片都提供了多人工标记的标准结果,每张图片的 NPR 和 GCE 都是对这些不同标准结果的平均. 为了使实验更为客观,实验中 GMM-EM 和 SVGMM 也同本文算法一样采用 6 维纹理和颜色特征. 与前面实验不同,参数统一设置 $\Delta t = 0.2$, $\varepsilon = 0.3$, $\beta = 0.9$ 和 $\gamma = 0.1$. 从图 8 中 GCE 和 NPR 数值可以看出,本文提出的算法具有较高的 NPR 和较低的 GCE,明显优于对比算法,尤其是当分割区域 $K \leq 10$ 时. 此外,算法 KGC 主函数是由 C++ 编译,其他三种算法都是 Matlab 实现. 本文算法、GMM-EM 和 SVGMM 三种算法在对数据集 500 张图片使用不同的区域数量进行分割的平均耗时分别为 20.3、19.2 和 41.5 秒,本文算法耗时与 GMM-EM 相当,优于 SVGMM,有着较高的计算效率.

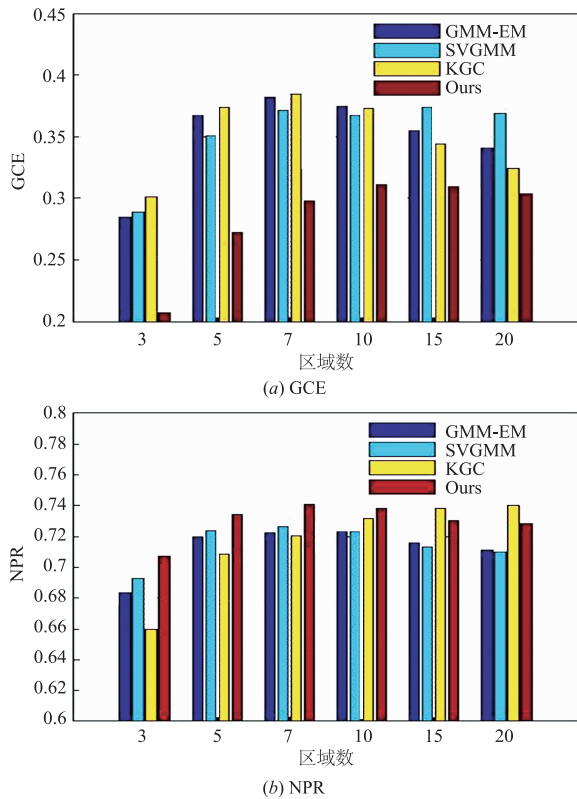


图8 在BSD数据集500张图片上使用不同算法对不同区域数量分割结果的量化对比

5 结论

本文提出一种新的基于纹理特征的多区域水平集图像分割方法,使用任意多个水平集来对相应数量的区域进行分割. 本文绕过构建复杂的能量函数,通过联合分布将纹理信息带入水平集框架,使得算法能够使用高维模型准确表示纹理特征,在低维空间高效的演化水平集函数;算法通过平滑概率标签充分利用了局

部空间的统计信息,有效的抑制了分割中的碎片区域;又在统计框架下最小化多个水平集的能量函数来估计区域参数,利用平滑概率标签有效的加快分割. 经实验证明,本文提出的多区域水平集方法具有良好的分割效果,能够对复杂的自然图像进行较为准确的分割,且具有较高的运行效率.

参考文献

- [1] 王顺风,冀晓娜,张建伟,等. 局部熵驱动的 GAC 模型在生物医学图像分割中的应用[J]. 电子学报,2013,41(12):2487-2492.
Wang S F, Ji X N, Zhang J W, et al. Application of GAC model driven by the local entropy on medical image segmentation[J]. Acta Electronica Sinica, 2013, 41(12):2487-2492. (in Chinese)
- [2] 林政宗,吕科,杨磊,等. 基于 Level Set 的海岸线检测[J]. 电子学报,2014,42(2):391-397.
Lin Z Z, Lv K, Yang L. A method for coastline detection based on level set[J]. Acta Electronica Sinica, 2014, 42(2):391-397. (in Chinese)
- [3] 陈哲,王慧斌,沈洁,等. 基于光强-光谱-偏振信息融合的水下目标检测[J]. 通信学报,2013(3):192-198.
Chen Z, Wang H B, Shen J, et al. Light intensity, spectrum and polarization information fusion based underwater object detection[J]. Journal on Communications, 2013, 34(3):192-198. (in Chinese)
- [4] Chen Z, Wang X, Sun Z, et al. Motion saliency detection using a temporal fourier transform[J]. Optics & Laser Technology, 2016, 80:1-15.
- [5] Xu M, Sun Q, Lu Y, et al. Nearest-neighbors based weighted method for the BOVW applied to image classification[J]. Journal of Electrical Engineering and Technology, 2015, 10(4):1877-1885.
- [6] 于海平,何发智,潘一腾,等. 一种基于多特征的距离正则化水平集快速分割方法[J]. 电子学报,2017,45(3):534-539.
Yu H P, He F Z, Pan Y T, et al. A fast distance regularized level set method for segmentation based on multi-features[J]. Acta Electronica Sinica, 2017, 45(3):534-539. (in Chinese)
- [7] Chan T, Vese L. Active contours without edges[J]. IEEE Transactions on Image Processing, 2001, 10(2):266-277.
- [8] Christophe S, Laure Blanc-Féraud, Gilles Aubert, Josiane Zerubia. A level set model for image classification[J]. International Journal of Computer Vision, 2000, 40(3):187-197.
- [9] Vese L, Chan T. A multiphase level set framework for image segmentation using the Mumford and Shah model[J]. International Journal of Computer Vision, 2002, 50(3):271-293.
- [10] Brox T, Weickert J. Level set segmentation with multiple

- regions [J]. IEEE Transactions on Image Processing, 2006, 15(10): 3213 – 3218.
- [11] Lu Z, Carneiro G, Bradley P. An improved joint optimization of multiple level set functions for the segmentation of overlapping cervical cells [J]. IEEE Transactions on Image Processing, 2015, 24(4): 1261 – 1272.
- [12] Bertelli L, Sumengen B, Manjunath B S, et al. A variational framework for multiregion pairwise-similarity-based image segmentation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2008, 30(8): 1400 – 1414.
- [13] Dubrovina A, Rosman G, Kimmel R. Multi-region active contours with a single level set function [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37(8): 1585 – 601.
- [14] Houhou N, Thiran J, Bresson X. Fast texture segmentation based on semi-local region descriptor and active contour [J]. Numerical Mathematics-theory Methods and Applications, 2009, 2(4): 445 – 468.
- [15] Lowry N, Mangoubi R, Desai M, et al. Texton-based segmentation and classification of human embryonic stem cell colonies using multi-stage bayesian level sets [A]. IEEE International Symposium on Biomedical Imaging (ISBI) [C]. IEEE, 2012. 194 – 197.
- [16] Min H, Jia W, Wang X F, et al. Anintensity-texture model based level set method for image segmentation [J]. Pattern Recognition, 2015, 48(4): 1547 – 1562.
- [17] Gao Y, Bouix S, Shenton M, Tannenbaum Allen. Sparse texture active contour [J]. IEEE Transactions on Image Processing, 2013, 22(10): 3866 – 3878.
- [18] Dahl A B, Dahl V A. Dictionary snakes [A]. IEEE International Conference on Pattern Recognition (ICPR) [C]. IEEE, 2014. 142 – 147.
- [19] Carson C, Belongie S, Hayit Greenspan, et al. Blobworld: image segmentation using expectation-maximization and its application to image querying [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2002, 24(8): 1026 – 1038.
- [20] Garding J, Lindeberg T. Direct computation of shape cues using scale-adapted spatial derivative operators [J]. International Journal of Computer Vision, 1996. 17(2): 163 – 191.
- [21] Pohl K M, Fisher J, Bouix S, et al. Using the logarithm of odds to define a vector space on probabilistic atlases [J]. Medical Image Analysis, 2007, 11(5): 465 – 477.
- [22] Bishop C. Pattern Recognition and Machine Learning [M]. Springer-Verlag New York, Inc, 2006.
- [23] 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 Transactions on Image Processing, 2011, 20(7): 2007 – 2016.
- [24] Sfikas G, Nikou C, Galatsanos N. Edge preserving spatially varying mixtures for image segmentation [A]. CVPR [C]. IEEE, 2008. 1 – 7.
- [25] Ben S M, Mitiche A, Ben A I. Multiregion image segmentation by parametric kernel graph cuts [J]. IEEE Transactions on Image Processing, 2011, 20(2): 545 – 557.
- [26] Unnikrishnan R, Pantofaru C, Hebert M. Toward objective evaluation of image segmentation algorithms [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2007, 29(6): 929 – 944.
- [27] Martin D, Fowlkes C, Tal D, et al. A database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics [A]. ICCV [C]. IEEE, 2001. 416 – 423.
- [28] Brodatz P, Textures: A Photographic Album for Artists and Designers [M]. New York, USA: Dover (1999).

作者简介



王慧斌 男, 1967 年出生, 山西阳泉人, 博士, 河海大学教授, 主要研究方向为图像处理、多传感器系统与信息融合等。
E-mail: hbwang@hhu.edu.cn



高国伟 男, 1981 年出生, 河南安阳人, 现工作于安阳师范学院, 主要研究方向为图像处理、模式识别等。
Email: gaoguowei@126.com



徐立中 男, 山东东营人, 1958 年出生, 博士, 河海大学教授、博士生导师, 主要研究方向为多传感器系统与信息融合、遥感遥测信号处理、系统建模与优化融合等。
Email: lzhu@hhu.edu.cn



文成林 男, 1963 年出生, 河南开封人, 博士, 杭州电子科技大学教授, 博士生导师。主要从事多源信息融合、故障诊断与预报、目标识别与跟踪等方面的研究。
E-mail: wencil@hdu.edu.cn