

边缘引导和轮廓约束下的 跨域香农熵最大化导向的自动阈值选取方法

邹耀斌¹, 乔 焰², 孙水发¹, 臧兆祥¹, 夏 平¹, 王俊英¹, 董方敏¹, 龚国强¹

(1. 三峡大学计算机与信息学院, 湖北宜昌 443002; 2. 安徽农业大学信息与计算机学院, 安徽合肥 230036)

摘 要: 为了处理诸如高斯、伽马、极值、瑞利、均匀或贝塔等基本灰度分布情形下的阈值选取难题, 本文提出了一种跨域香农熵最大化导向的自动阈值选取方法. 该方法利用不变的引导边缘图像和变化的约束轮廓图像共同构造出一系列持续变化的一维灰度直方图, 并采用香农熵作为熵计算模型, 从而得以跨越图像中若干局部区域去计算跨域香农熵, 并以最大跨域香农熵对应的阈值作为最终阈值. 在 40 幅合成图像和 50 幅真实世界图像上的实验结果表明, 该方法虽然在计算效率方面不优于 Masi 熵阈值方法、Tsallis 熵阈值方法、局部香农熵阈值方法和迭代三类阈值方法, 但在分割适应性方面有显著增强, 且在误分割率方面有显著下降.

关键词: 阈值分割; 最大熵原理; 跨域香农熵; 香农熵差; 全局熵方法; 局部熵方法

中图分类号: TN911.73 **文献标识码:** A **文章编号:** 0372-2112 (2019)12-2495-10

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.3969/j.issn.0372-2112.2019.12.007

Automatic Threshold Selection Guided by Maximizing Cross-Region Shannon Entropy Under Edge Guidance and Contour Constraints

ZOU Yao-bin¹, QIAO Yan², SUN Shui-fa¹, ZANG Zhao-xiang¹, XIA Ping¹,
WANG Jun-ying¹, DONG Fang-min¹, GONG Guo-qiang¹

(1. College of Computer and Information Technology, China Three Gorges University, Yichang, Hubei 443002, China;

2. School of Information and Computer, Anhui Agricultural University, Hefei, Anhui 230036, China)

Abstract: When the basic distribution constituting one gray level histogram is presented as a non-Gaussian distribution, such as gamma, extreme value, Rayleigh, uniform or beta distribution, how to automatically select the best possible segmentation threshold is still quite challenging. To deal with the issue of threshold selection in the above-mentioned different gray level distributions, we propose an automatic method of threshold selection that is guided by maximizing cross-region Shannon entropy under edge guidance and contour constraints. This method utilizes constant guiding edges and dynamically changing contours to construct a series of continuously changing one-dimensional gray level histograms, and adopts Shannon entropy as the entropy calculation model. Therefore, it can calculate the cross-region Shannon entropy across several local regions in the image, and it takes the threshold corresponding to the maximum cross-region Shannon entropy as the final segmentation threshold. The proposed method is compared with Masi entropy thresholding, Tsallis entropy thresholding, Shannon entropy thresholding, and iterative triclass thresholding on 40 synthetic images and 50 real-world images. The results show that the proposed method is not superior to the 4 compared methods in computational efficiency, but it has significant enhancement in segmentation adaptability and a significant decrease in the mis-segmentation rate.

Key words: image thresholding; maximum entropy principle; cross-region Shannon entropy; Shannon entropy difference; global entropy method; local entropy method

收稿日期: 2019-01-18; 修回日期: 2019-06-28; 责任编辑: 覃怀银

基金项目: 国家重点研发计划资助项目 (No. 2016YFB0800403); 国家自然科学基金 (No. 61871258, No. 61502274); 湖北省水电工程智能视觉监测重点实验室开放基金项目 (No. 2017SDSJ04)

1 引言

阈值分割是图像分析和理解中最常用的低层图像处理方法之一^[1-3],它将每个像素的灰度值与选取的阈值进行比较,以决定该像素是属于目标还是背景. 阈值选取由此成为准确阈值分割的关键^[4],而利用最大熵原理去选取阈值是一种代表性思想^[5-7]. 根据熵计算时所用灰度直方图的维度以及构建灰度直方图过程中所涉及到的图像空间,可以将灰度直方图分为全局一维和局部二维两大类.

全局一维灰度直方图通过对整幅图像的灰度值进行统计而建立,以此为基础的最大熵阈值选取方法通常被称为全局熵方法^[8-12]. 全局熵方法可追溯到最大化香农熵方法^[8],然而香农熵不能有效地表示非扩展性信息,从而难以保证所选阈值的合理性. 最大化 Rényi 熵方法^[9],最大化 Tsallis 熵方法^[10],以及最大化 Masi 熵方法^[12]等继承了最大化香农熵方法的核心思想. 这些改进方法具有提升最大化香农熵方法的潜力,然而它们所使用的熵模型都属于参数熵,它们的分割结果对熵参数较敏感^[6,12].

以局部二维灰度直方图为基础的最大熵阈值选取方法通常被称为局部熵方法^[5,13,14]. 局部熵方法意识到全局熵方法的一个共性问题:在构建一维灰度直方图时忽略了像素间的空间相关性. 局部熵方法通过构建二维灰度直方图以尝试拓展全局熵方法,但仍存在三个不足:①它们将空间相关性限制在小范围的局部邻域;②如果采用参数熵作为熵计算模型,它们将面临熵参数的自动评估难题;③在建立二维灰度直方图后就不再考虑原始图像,割裂了原始图像和分割阈值之间的关联.

为了克服全局熵方法和局部熵方法的不足,也是为了在统一框架内处理不同灰度分布情形下的自动阈值选取问题,提出了一种边缘引导和轮廓约束下的跨域香农熵最大化(Cross-region Shannon Entropy Maximization, CSEM)导向阈值选取方法. CSEM 方法利用不变的引导边缘图像和动态变化的约束轮廓图像共同构造一系列的一维灰度直方图,这些一维灰度直方图直接反映了图像中不同局部区域的灰度统计特征,兼顾了像素的灰度分布信息和空间位置信息,为应用最大香农熵理论去自动选取合理阈值奠定了基础.

2 香农熵差的定义和单调性

给定一个灰度直方图,用灰度 l 将其分为左右两部分. 假设左部有 m 个灰度级,其离散概率分布为 $q_i (1 \leq i \leq m)$ 且 $\sum_{i=1}^m q_i = 1$,总频数为 λ_- ;右部有 n 个灰度级,其

离散概率分布为 $p_i (1 \leq i \leq n)$ 且 $\sum_{i=1}^n p_i = 1$,总频数为 λ_+ .

令 H_- 和 H_+ 分别表示左部和右部的香农熵(以 2 为基), H 表示整个直方图的香农熵:

$$H = - \sum_{i=1}^{m+n} o_i \log_2 o_i \quad (1)$$

其中:

$$o_i = \begin{cases} \frac{\lambda_-}{\lambda_- + \lambda_+} q_i, & 1 \leq i \leq m \\ \frac{\lambda_+}{\lambda_- + \lambda_+} p_i, & m+1 \leq i \leq m+n \end{cases} \quad (2)$$

定义 1 $H_+ - H$ 为香农熵差.

命题 1 香农熵差 $H_+ - H$ 等于 $s(H_+ - H_-) + s \log_2 s + (1-s) \log_2 (1-s)$, 其中 $s = \frac{\lambda_-}{\lambda_- + \lambda_+}$.

$$\begin{aligned} \text{证明} \quad H &= - \sum_{i=1}^{m+n} o_i \log_2 o_i \\ &= - \sum_{i=1}^m o_i \log_2 o_i - \sum_{i=m+1}^{m+n} o_i \log_2 o_i \\ &= - \sum_{i=1}^m \left(\frac{\lambda_-}{\lambda_- + \lambda_+} q_i \right) \log_2 \left(\frac{\lambda_-}{\lambda_- + \lambda_+} q_i \right) \\ &\quad - \sum_{i=1}^n \left(\frac{\lambda_+}{\lambda_- + \lambda_+} p_i \right) \log_2 \left(\frac{\lambda_+}{\lambda_- + \lambda_+} p_i \right) \\ &= - \sum_{i=1}^m \left(\frac{\lambda_-}{\lambda_- + \lambda_+} q_i \right) \log_2 \left(\frac{\lambda_-}{\lambda_- + \lambda_+} \right) \\ &\quad - \sum_{i=1}^m \left(\frac{\lambda_-}{\lambda_- + \lambda_+} q_i \right) \log_2 q_i \\ &\quad - \sum_{i=1}^n \left(\frac{\lambda_+}{\lambda_- + \lambda_+} p_i \right) \log_2 \left(\frac{\lambda_+}{\lambda_- + \lambda_+} \right) \\ &\quad - \sum_{i=1}^n \left(\frac{\lambda_+}{\lambda_- + \lambda_+} p_i \right) \log_2 p_i \\ &= - \left(\frac{\lambda_-}{\lambda_- + \lambda_+} \right) \log_2 \left(\frac{\lambda_-}{\lambda_- + \lambda_+} \right) \\ &\quad - \left(\frac{\lambda_-}{\lambda_- + \lambda_+} \right) \sum_{i=1}^m q_i \log_2 q_i \\ &\quad - \left(\frac{\lambda_+}{\lambda_- + \lambda_+} \right) \log_2 \left(\frac{\lambda_+}{\lambda_- + \lambda_+} \right) \\ &\quad - \left(\frac{\lambda_+}{\lambda_- + \lambda_+} \right) \sum_{i=1}^n p_i \log_2 p_i \\ &= -s \log_2 s + s H_- - (1-s) \log_2 (1-s) \\ &\quad + (1-s) H_+ \end{aligned}$$

则 $H_+ - H = s(H_+ - H_-) + s \log_2 s + (1-s) \log_2 (1-s)$, 证毕.

命题 2 当 $s > \frac{1}{1+2^{H_+ - H_-}}$ 时, $H_+ - H$ 是关于 s 的单调递增函数.

证明 变量 s 是非连续的,不能直接求 $H_+ - H$ 关于 s 的导数. 对此,可以将 s 的定义域由原来的非连续点集扩展到连续区间 $(0, 1)$, 此时 $H_+ - H$ 关于 s 的导数为:

$$H_+ - H_- + \log_2 s + s \times \frac{1}{s} \times \log_2 e - \log_2(1 - s) \\ + (1 - s) \times \frac{1}{1 - s} \times (-1) \times \log_2 e$$

化简为 $H_+ - H_- + \log_2 s - \log_2(1 - s)$, 令其大于 0, 解得 $s > \frac{1}{1 + 2^{\mu_+ - \mu_-}}$. 而当 $s > \frac{1}{1 + 2^{\mu_+ - \mu_-}}$ 时, $H_+ - H$ 是关于 $s \in (0, 1)$ 的单调递增函数, 证毕.

命题 3 当 $H_+ > H_-$ 时, $H_+ - H$ 是关于 $H_+ - H_-$ 的单调递增函数.

证明 $H_+ - H$ 关于 $H_+ - H_-$ 的导数为 s , 显然 $s > 0$, 从而 $H_+ - H$ 是关于 $H_+ - H_-$ 的单调递增函数, 证毕.

命题 1 到 3 表明: 当 $s > \frac{1}{1 + 2^{\mu_+ - \mu_-}}$ 且 $H_+ > H_-$ 时, 更大的 s 和 $H_+ - H_-$ 使得香农熵差取更大值. 考虑 $s = \frac{\lambda_-}{\lambda_- + \lambda_+}$ 以及 H_+ 和 H_- 的相对大小关系, 并结合概率分布越趋向均匀则香农熵越大的性质^[15], 使香农熵差倾向于取更大值的一种灰度直方图是: 由较少像素构成的右部直方图应尽量在更广范围内均匀分布, 而由较多像素构成的左部直方图应尽量在更窄范围内集中分布.

3 香农熵差最大化导向的引导边缘图像计算

令 f 表示一幅灰度图像, ∇g_x 表示高斯函数 $g(x, y; \sigma) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{x^2+y^2}{2\sigma^2}}$ 对 x 的偏导, $k_x(\sigma)$ 表示 f 与 ∇g_x 卷积运算后的绝对值, 即:

$$k_x(\sigma) = |f * \nabla g_x| \quad (3)$$

定义 f 在 x 轴方向的多尺度乘积变换为 u_x 个 $k_x(\sigma_i)$ 的乘积, 即:

$$K_{u_x} = \prod_{i=1}^{u_x} k_x(\sigma_i) \quad (4)$$

可以参考文献[16, 17]计算尺度 $\sigma_i; \sigma_i = 0.25 \times i$ ($i \geq 1$).

在图像 K_{u_x} 的灰度值被规范到 $[0, 255]$ 前提下, 随着图像数量 u_x 的逐渐增多, 噪声(或随机细节)的响应值的乘积将逐渐趋向 0, 而边缘的响应值的乘积将散布在 $[0, 255]$ 内, 这样 K_{u_x} 的灰度直方图将呈现如下特点: ① 右重尾分布; ② 众数逐渐左移, 并在 u_x 值足够大时等于 0; ③ 持续增大 u_x 值以至于超过某临界值, 乘积效应将使更多的边缘响应值也趋向 0, 其结果是 $(0, 255)$ 内的灰度分布越来越稀疏.

图像 K_{u_x} 的灰度直方图与 u_x 值之间的关系表明: 需要寻找一个恰当的 u_x 值, 使 K_{u_x} 的灰度直方图更符合第 2 节所期望的分布特征. 对此, 可以最大化 K_{u_x} 的灰度直方图的香农熵差为目标, 其形式化表述为:

$$(u_x^*, l_x^*) = \arg \max_{u_x \in Z^+} \max_{l_x \in [0, 255]} (H_+(u_x) - H(u_x)) \quad (5)$$

一旦确定了参与多尺度乘积变换的图像数量 u_x^* , 就可以结合式(3)和(4)来计算对应的图像 $K_{u_x^*}$. 这里将 $K_{u_x^*}$ 称为 x 轴方向的引导边缘图像. 类似地, 对于 y 轴方向的多尺度乘积变换图像 K_{u_y} , 可以根据式(6)计算出参与多尺度乘积变换的图像数量 u_y^* :

$$(u_y^*, l_y^*) = \arg \max_{u_y \in Z^+} \max_{l_y \in [0, 255]} (H_+(u_y) - H(u_y)) \quad (6)$$

相应的图像 $K_{u_y^*}$ 被称为 y 轴方向的引导边缘图像.

4 跨域香农熵最大化导向的阈值选取

对于灰度图像 f (见图 1(a)), 如果用一个灰度值 t 对其阈值化, 可得一幅二值图像 b_t (见图 1(b)). 从 b_t 中提取出约束轮廓图像 c_t (见图 1(d)), 然后用 c_t 中值为 1 的像素对第 3 节计算出的引导边缘图像 $K_{u_x^*}$ (见图 1(c)) 和 $K_{u_y^*}$ 分别进行取样, 并以取样所得像素重新构造灰度直方图 χ_t (见图 1(e)) 和 β_t .

CSEM 方法采用如下原则选取最终阈值 t^* :

$$t^* = \arg \max_{t \in [t_{\min}, t_{\max}]} ((H_x(t) + H_y(t))/2) \quad (7)$$

其中, t_{\min} 和 t_{\max} 分别表示图像 f 的最小和最大灰度值, $H_x(t)$ 和 $H_y(t)$ 分别是基于灰度直方图 χ_t 和 β_t 计算出的香农熵. 由于 χ_t 和 β_t 借助于引导边缘图像和约束轮廓图像而构造, 并采用无参数的香农熵作为熵计算模型, 这使得 $H_x(t)$ 和 $H_y(t)$ 能够跨越图像中若干局部区域去计算这些局部区域对应的香农熵, 据此方式计算出的香农熵本文称之为跨域香农熵.

下面将分析按式(7)计算最终阈值 t^* 的合理性. 对跨域香农熵 $H_x(t)$ 和 $H_y(t)$ 的分析是类似的, 这里仅以 $H_x(t)$ 为例. 有两种方式计算 χ_t 对应的跨域香农熵 $H_x(t)$, 一种是对 χ_t 做整体计算, 一种是用式(5)计算所得灰度 l_x^* 将 χ_t 分为左右两部分(见图 1(e)), 并用第 2 节计算 H 一样的方式计算香农熵. 第一种方式效率更高, 在算法实现时将予以采用. 第二种方式可构建出一个由 3 个自变量组成的多元函数, 便于分析阈值 t 合理取值的理论依据. 根据第二种方式得:

$$H_x(t) = (1 - s^*)H_+(t) + s^*H_-(t) \\ - s^* \log_2 s^* - (1 - s^*) \log_2(1 - s^*) \quad (8)$$

其中, $H_+(t)$ 表示 χ_t 中大于灰度 l_x^* 的右部对应的香农熵, $H_-(t)$ 表示 χ_t 中小于灰度 l_x^* 的左部对应的香农熵,

而 $s^* = \frac{\lambda_-^*}{\lambda_-^* + \lambda_+^*}$, 其中 λ_-^* 为左部的像素个数, λ_+^* 为右部的像素个数.

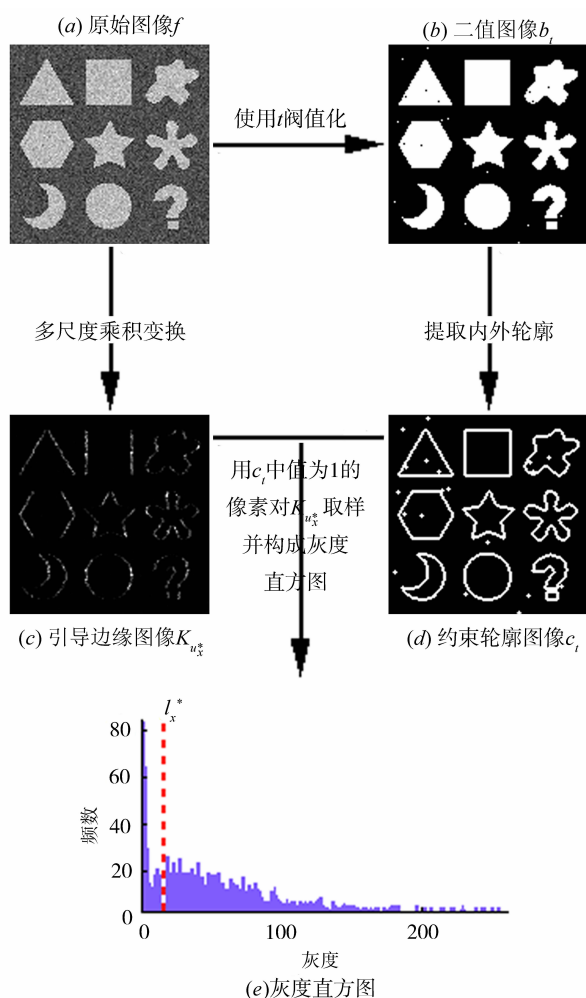


图1 CSEM方法中核心概念和关键步骤的示意图

命题4 当令 $s^\perp = \frac{1}{1 + 2^{H_+(t) - H_-(t)}}$, 则当 $s^* \in (s^\perp, 1)$ 时, 跨域香农熵 $H_x(t)$ 关于 s^* 单调递减; 当 $s^* \in (0, s^\perp)$ 时, 跨域香农熵 $H_x(t)$ 关于 s^* 单调递增.

证明 变量 s^* 是非连续的, 不能直接求 $H_x(t)$ 关于 s^* 的导数. 对此, 可以将 s^* 的定义域由原来的非连续点集扩展到连续区间 $(0, 1)$, 再计算 $H_x(t)$ 对 s^* 的导数, 有:

$$\begin{aligned} & -H_+(t) + H_-(t) - \log_2 s^* - s^* \times \frac{1}{s^*} \times \log_2 e \\ & + \log_2(1 - s^*) + (1 - s^*) \times \frac{1}{(1 - s^*)} \times \log_2 e \\ & = -H_+(t) + H_-(t) - \log_2 s^* + \log_2(1 - s^*) \end{aligned}$$

当 $s^* \in (s^\perp, 1)$ 时, $-H_+(t) + H_-(t) - \log_2 s^* + \log_2(1 - s^*) < 0$, 知 $H_x(t)$ 在区间 $(s^\perp, 1)$ 内关于 s^* 单调递减; 当 $s^* \in (0, s^\perp)$ 时, $-H_+(t) + H_-(t) - \log_2 s^* + \log_2(1 - s^*) > 0$, 知 $H_x(t)$ 在区间 $(0, s^\perp)$ 内关于 s^* 单调递增, 证毕.

灰度直方图 χ_t 是由引导边缘图像 $K_{u_t}^*$ 中的边缘像素和非边缘像素所构成, 小于灰度 I_x^* 的左部绝大部分由 $K_{u_t}^*$ 中的非边缘像素构成, 而大于灰度 I_x^* 的右部绝大部分由 $K_{u_t}^*$ 中的边缘像素构成, 因此 s^* 值反映约束轮廓图像 c_t 中位于引导边缘图像 $K_{u_t}^*$ 的非边缘区域和边缘区域的比例. 对约束轮廓图像 c_t 而言, 相对更小的 s^* 意味着非边缘区域占比更小, 这是良好分割所期望的一个特性, 而命题4指出在 $s^* \in (s^\perp, 1)$ 时, 更小的 s^* 值对应于更大的跨域香农熵 $H_x(t)$, 这表明了按式(7)计算最终阈值 t^* 的合理性. CSEM方法的具体过程如算法1所示.

算法1 CSEM

输入: 待分割的灰度图像 f

输出: 阈值 t^* 及分割结果图像

步骤1: 根据式(3)、(4)、(5)和(6)计算引导边缘图像 $K_{u_t}^*$ 和 $K_{v_t}^*$.

步骤2: 用 h 记录循环处理过程中两个跨域香农熵 $H_x(t)$ 和 $H_y(t)$ 的算术均值, 并用 h_{\max} 记录循环处理过程中最大的 h 值, 用 t^* 记录对应于 h_{\max} 的灰度值. h 、 h_{\max} 和 t^* 的初始值均为0. 对于图像 f 中每一个可能的灰度值 t , 按从小到大的顺序重复执行步骤3到6.

步骤3: 使用 t 阈值化图像 f , 获得相应的二值图像 b_t .

步骤4: 从 b_t 中提取出约束轮廓图像 c_t , 具体可以分为3个小步骤. 初始时, 令 c_t 的像素值全为1; 然后提取内约束轮廓: 如果在 b_t 中的某个像素值为1, 且该像素4邻域的像素值均为1, 则设置该像素在 c_t 中对应位置的像素值为0; 最后提取外约束轮廓: 将 b_t 取反得 \bar{b}_t , 然后在 \bar{b}_t 上也同样进行像素及其4邻域的判断, 并在 c_t 上进行设置.

步骤5: 利用 c_t 中值为1的像素对引导边缘图像 $K_{u_t}^*$ 进行采样, 然后以采样所得像素构造归一化灰度直方图, 并据此直方图计算跨域香农熵 $H_x(t)$; 对 $K_{v_t}^*$ 也同样处理, 并计算相应的跨域香农熵 $H_y(t)$.

步骤6: 计算 $H_x(t)$ 和 $H_y(t)$ 的算术均值 h , 然后判断 h 和 h_{\max} 的大小, 如果 $h > h_{\max}$, 则令 h_{\max} 等于 h , 令 t^* 等于 t .

步骤7: 以最终计算出的 t^* 阈值化图像 f 得到二值图像 b_{t^*} , 输出 t^* 及二值图像 b_{t^*} .

5 实验结果与讨论

实验软硬件环境为: Intel Core i3-2350M 2.3GHz CPU, 4GB DDR2 内存, Windows 7 32位操作系统, Matlab 2009a 32位开发平台. 测试图像集包含合成图像40幅, 真实世界图像50幅. 每幅测试图像的分割参考图像都利用 Photoshop 软件手工产生. 测试图像集、分割参考图像集和分割参考图像的制作规范可以访问在线资源^[18]获得. 误分类率 (Misclassification Error, ME)^[4] 被用于定量评估分割方法的分割精度.


CSEM方法和 Masi 熵阈值 (Masi Entropy Thresholding, MET)方法^[12], 自适应 Tsallis 熵阈值 (Tsallis Entropy Thresholding, TET)方法^[11], 局部香农熵阈值 (Shannon Entropy Thresholding, SET)方法^[5], 迭代三类阈值 (Iterative Triclass Thresholding, ITT)方法^[19]以及交互阈

值(Interactive Thresholding, IT)方法^[20]进行了比较. IT方法通过交互方式选取一个阈值,该阈值对应的二值图像具有最小的ME值.


5.1 在合成图像上的实验

为了检验6个分割方法对不同直方图模式的分割适应能力,将40幅合成图像分成8组进行测试.第1、2组图像中的目标和背景所占比例约等于3:7,而在第3、4组中目标和背景所占比例约等于3:1997.第1、3组通过对无噪合成图像分别添加高斯、伽马、极值、瑞利和均匀噪声而产生测试图像,用于模拟基本分布分别为高斯、伽马、极值、瑞利和均匀分布的情形.第2、4组通过

对无噪合成图像添加不同参数的贝塔噪声来产生测试图像,用于模拟基本分布为贝塔分布的情形.在第1、2组中,除了均匀分布情形下测试图像直方图为无峰模式外,其它所有图像的灰度直方图均呈现为双峰或多峰模式.第3、4组因为目标和背景所占比例严重失衡,图像的灰度直方图均呈现出单峰模式.第5~8组测试图像分别通过对第1~4组测试图像进行高斯点扩散而产生,其中第5、6组图像的灰度直方图的主要特征是双峰平谷,而第7、8组图像都是在模糊背景上显示了一个小的模糊目标,其灰度直方图的特征是右偏单峰.



(a) MET, TET, SET和ITT方法的结果比较



(b) CSEM和IT方法的结果比较

图2 6个方法在40幅合成图像上的误分割量化比较

在图2中,每5个编号对应于一组,比如图像编号1~5对应着组1,编号6~10对应着组2,以此类推.从图2中可以观察到:①就MET、TET、SET和ITT方法而言,它们各自有相对比较适合分割的测试图像,比如ITT方法比较适合分割具有双峰直方图模式的测试图像,但是对单峰直方图模式的测试图像误分割严重,而MET和TET方法比较适合分割具有右偏单峰直方图模式的测试图像;②在所有8组测试图像上,CSEM方法的分割精度都明显高于前述4种分割方法.③在第1、

2、3、4、7组测试图像上,CSEM方法和IT方法获得完全一致的分割精度,达到了理论上的最优分割;在第5、6、8组测试图像上,CSEM方法和IT方法的分割结果有极微小的差别.

5.2 在真实世界图像上的实验

50幅真实世界图像被用于进一步检验6个方法的分割适应性,它们的灰度直方图可用高斯、伽马、极值、瑞利、均匀和贝塔分布中的若干分布的混合进行逼近.其中,编号1~11图像的灰度直方图呈现为单峰左偏、

右偏或者无偏模式;编号 12~28 图像的灰度直方图呈现为双峰深谷或者平谷模式;由于存在复杂的背景,编号 29~46 图像的灰度直方图呈现为多峰模式,其峰数大于等于 3;编号 47~50 图像的灰度直方图呈现为无峰模式。

在图 3 中水平虚线标示对应情形下 ME 值的均值,可以观察到:①对灰度直方图为单峰、双峰、多峰或者无峰模式的图像,CSEM 和 IT 方法对应的 ME 均值都小于 0.6%;而其它方法,除了 TET 方法在单峰模式和 ITT

方法在双峰模式外,每种方法对应的 ME 均值都大于 7%;②ITT 方法尽管对具有双峰模式的图像有良好的分割精度,但是它在单峰、多峰和无峰模式情况下,误分割都很严重,各自的 ME 均值都超过了 24%;③SET 方法在 4 种情况下的误分割都较大,各自的 ME 均值都大于 11%,并且在 12 幅图像上的 ME 值大于 20%;④相对于 SET 和 ITT 方法,TET 和 MET 方法的总体分割精度略优,但后两者在 4 种灰度直方图模式下,部分图像的相应 ME 值较大,甚至超过 20%。

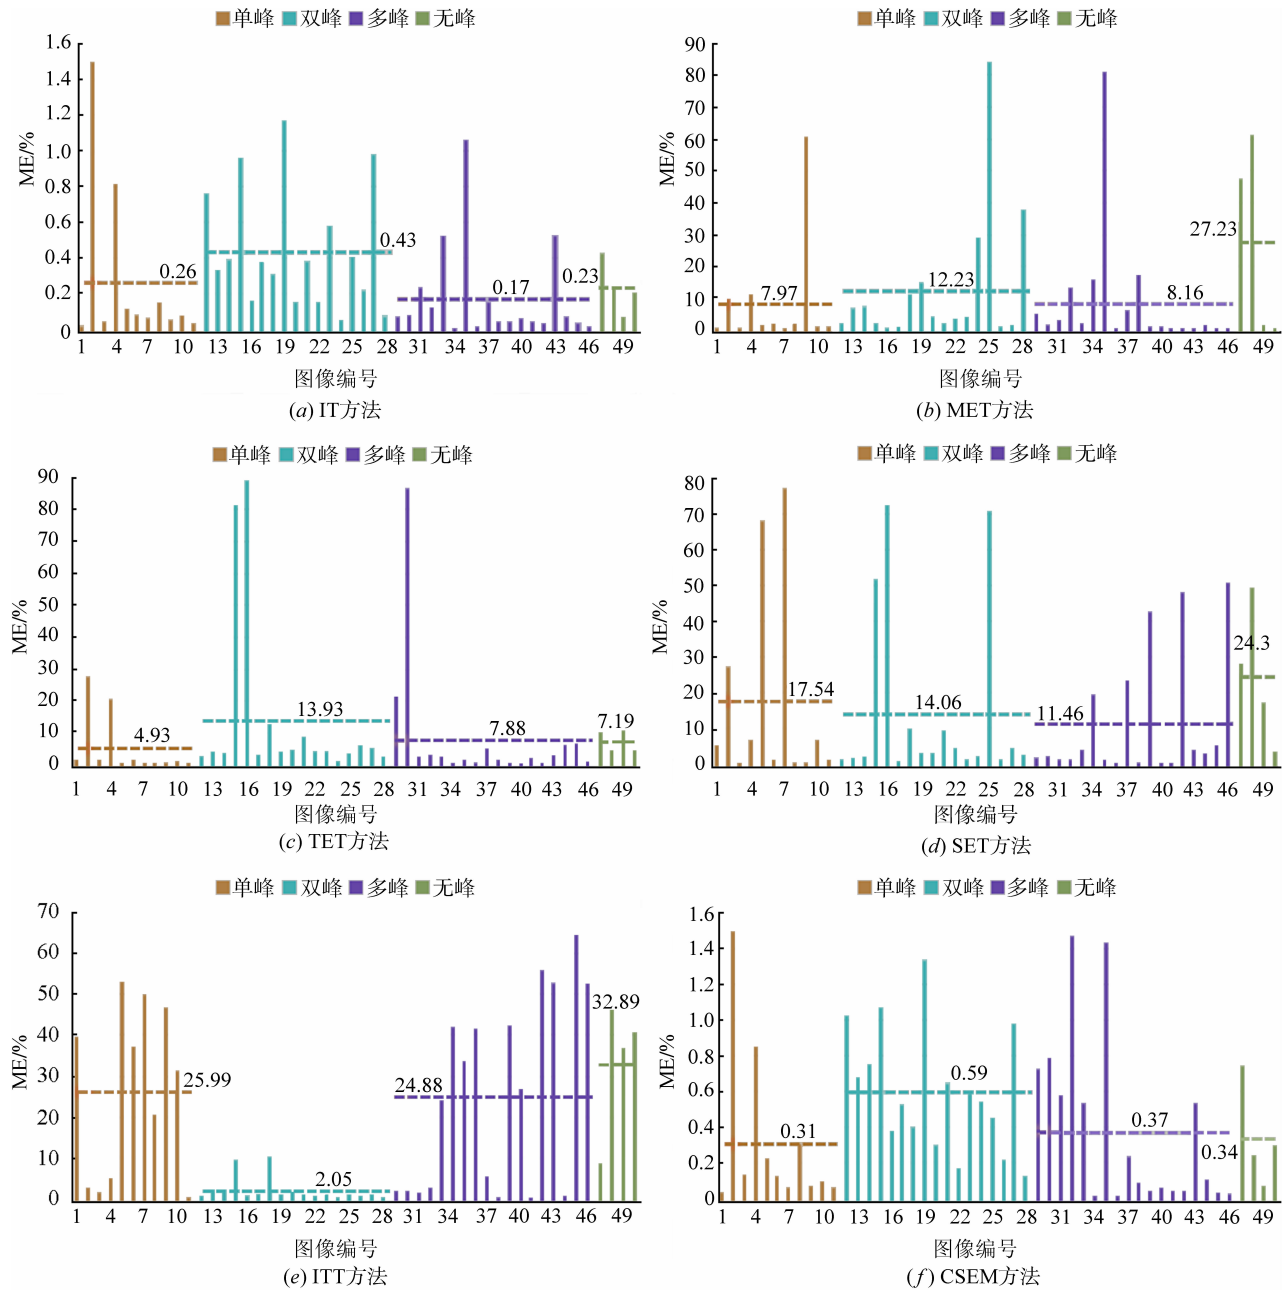


图3 6个方法在50幅真实世界图像上的误分割量化比较

5.3 计算效率的比较

表 1 显示了 5 个自动分割方法在测试图像上 CPU 耗时的均值和标准偏差. 从中可以观察到, ITT 和 MET 方法的计算效率相对更高, 而 TET、SET 和 CSEM 方法的计算效率相对更低.

ITT、MET 和 TET 方法需要先统计原始图像的灰度分布, 然后 ITT 方法进行相对简单的均值和方差运算, MET 方法进行基于对数的 Masi 熵计算, 而 TET 方法需要通过分析图像的冗余度来自动计算 Tsallis 熵的熵指数 q , 以及各灰度分布概率的 q 次幂. SET 方法需要利用原始图像先构建灰度共生矩阵, 该过程的计算代价相对较大, 结果平均 CPU 耗时高于前三者. CSEM 方法的主要计算代价发生在引导边缘图像、约束轮廓图像, 以及构建于两者之上的跨域香农熵的计算, 其计算代价最大, 平均 CPU 耗时最多.

表 1 5 个自动阈值分割方法的运行时间比较/s

阈值方法	合成图像上 CPU 耗时		真实图像上 CPU 耗时	
	均值	标准偏差	均值	标准偏差
CSEM	0.609	0.255	0.939	0.562
MET	0.038	0.032	0.048	0.026
TET	0.182	0.029	0.268	0.099
SET	0.441	0.118	0.455	0.136
ITT	0.007	0.002	0.008	0.005

6 扩展到多阈值分割

为简洁起见, 用符号 $\zeta(t)$ 表示式(7)中的 $(H_x(t) + H_y(t))/2$:

$$\zeta(t) = (H_x(t) + H_y(t))/2, t \in [t_{\min}, t_{\max}] \quad (9)$$

假设 t^* 为从函数 $\zeta(t)$ 中选取的某个合理阈值, 而 t_- 和 t_+ 分别是小于和大于 t^* 的两个灰度值, 它们对应的 $\zeta(t)$ 值为两个合理局部极小值(见图 4(h)), 则自动选取分割阈值 t^* 可形式化定义为:

$$t^* = \operatorname{argmax}_{t \in [t_-, t_+]} \zeta(t) \quad (10)$$

从 $\zeta(t)$ 中自动选取若干合理阈值, 就转化为自动评估若干灰度值三元组 (t^*, t_-, t_+) , 或者自动评估若干局部极值三元组 $(\zeta(t^*), \zeta(t_-), \zeta(t_+))$. 从选取阈值的角度看, $\zeta(t)$ 上的一些局部极值可能是虚假局部极值(见图 4(c)). 视 $\zeta(t)$ 为含有噪声(虚假局部极值)的一维信号, 那么从 $\zeta(t)$ 中寻找合理局部极值三元组, 就是从含有噪声的一维信号中寻找局部强信号.

提出了一种多尺度空间滤波和非参数概率密度估计相结合的合理局部极值评估方法. 用 $\zeta_w(t)$ 表示经过

尺度为 w 的局部加权线性回归滤波器^[21]平滑后的函数(见图 4(d)). 尺度 w 表示该滤波器每次滤波时所涉及的数据个数, 取值为 1 到 11 的奇数. 对于每个函数 $\zeta_w(t)$, 运用如下规则分别判断局部极大值和局部极小值:

$$\zeta_w(t-1) \leq \zeta_w(t) \text{ 且 } \zeta_w(t) \geq \zeta_w(t+1), t \in (t_{\min}, t_{\max}) \quad (11)$$

$$\zeta_w(t-1) \geq \zeta_w(t) \text{ 且 } \zeta_w(t) \leq \zeta_w(t+1), t \in (t_{\min}, t_{\max}) \quad (12)$$

将计算出的每个局部极大值和局部极小值对应的灰度值 t 分别归入集合 ω 和 ψ . 图 4(e) 和 (f) 中蓝色条状分别表示集合 ω 和 ψ 中每个元素出现的频率.

应用 Parzen 窗概率密度估计方法^[22], 对集合 ω 和 ψ 分别建立对应的概率密度函数 $\operatorname{pdf}_{\omega}(t)$ 和 $\operatorname{pdf}_{\psi}(t)$, 其中核函数选择高斯函数, 核宽则根据 3Sigma 原则自动计算: $(t_{\max} - t_{\min})/6$. $\operatorname{pdf}_{\omega}(t)$ 和 $\operatorname{pdf}_{\psi}(t)$ 反映了从所有 $\zeta_w(t)$ 中确定的局部极大值和局部极小值发生的概率(见图 4(e) 和 (f) 中红色曲线). 从 $\operatorname{pdf}_{\omega}(t)$ 和 $\operatorname{pdf}_{\psi}(t)$ 中分别寻找各自的局部极大值, 将更可能获得合理的三元组 (t^*, t_-, t_+) 或者 $(\zeta(t^*), \zeta(t_-), \zeta(t_+))$, 相应的概率密度局部极大值判断原则为:

$$\operatorname{pdf}_{\omega}(t-1) < \operatorname{pdf}_{\omega}(t) \text{ 且 } \operatorname{pdf}_{\omega}(t) > \operatorname{pdf}_{\omega}(t+1) \quad (13)$$

$$\operatorname{pdf}_{\psi}(t-1) < \operatorname{pdf}_{\psi}(t) \text{ 且 } \operatorname{pdf}_{\psi}(t) > \operatorname{pdf}_{\psi}(t+1) \quad (14)$$

将计算出的概率密度局部极大值对应的灰度值 t 分别归入集合 ω^* 和 ψ^* . 图 4(e) 和 (f) 中红色曲线顶部的数字分别标识了 $\operatorname{pdf}_{\omega}(t)$ 和 $\operatorname{pdf}_{\psi}(t)$ 中局部极大值所对应的灰度值, 它们构成了集合 ω^* 和 ψ^* . 图 4(g) 绘制了集合 ω^* 和 ψ^* 中的每个元素在函数 $\zeta(t)$ 曲线上对应的函数值, 它们标识出粗定位的局部极大值点和局部极小值点, 注意 ψ^* 中的第一个和最后一个灰度值没有显示出来, 因为第一个灰度值小于图像 f 的最小灰度值, 最后一个灰度值大于图像 f 的最大灰度值.

最后结合集合 ω^* 、 ψ^* 以及函数 $\zeta(t)$ 自动计算 (t^*, t_-, t_+) . 对于 ω^* 中每个元素 $\omega^*(i)$, 如果在 ψ^* 中能到找到相邻的两个元素 $\psi^*(j)$ 和 $\psi^*(j+1)$, 且同时满足式(15)和式(16)的约束关系:

$$\omega^*(i) \geq \psi^*(j) \text{ 且 } \omega^*(i) \leq \psi^*(j+1) \quad (15)$$

$$\zeta(\omega^*(i)) \geq \zeta(\psi^*(j)) \text{ 或 } \zeta(\omega^*(i)) \geq \zeta(\psi^*(j+1)) \quad (16)$$

则 $t_- = \psi^*(j)$, $t_+ = \psi^*(j+1)$. 根据式(10)寻找区间 $[t_-, t_+]$ 内最大 $\zeta(t)$ 对应的灰度值即为一个分割阈值 t^* (见图 4(h)).

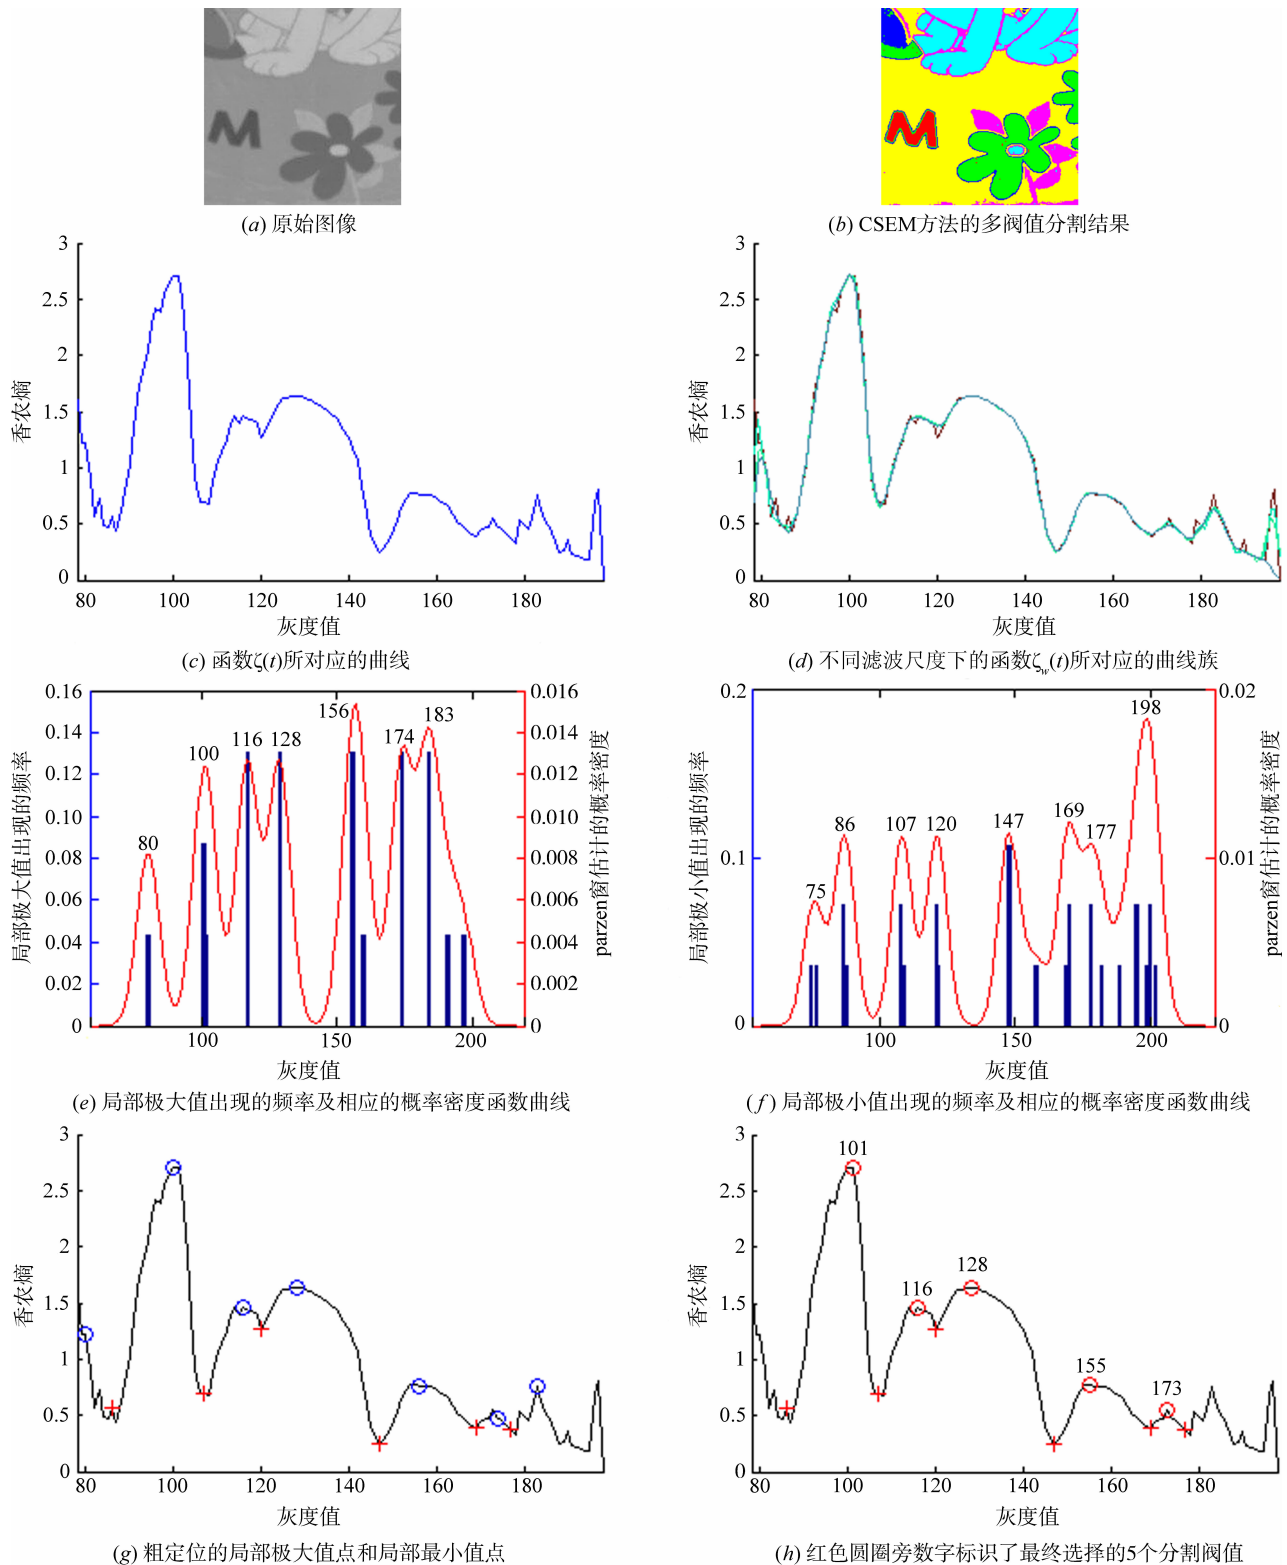


图4 多阈值分割情形下CSEM方法自动选取阈值的关键步骤

7 结论

对具有单峰、双峰、多峰或者无峰灰度直方图模式

的灰度图像,当目标或背景的灰度分布可以用高斯、伽马、极值、瑞利、均匀或贝塔分布逼近时,相对于 MET、TET、SET 和 ITT 方法而言,CSEM 方法具有更强的阈

值选取自适应性和更高的分割精度。

CSEM 方法之所以具有这两项优点主要得益于:①它利用引导边缘图像和约束轮廓图像共同构造一系列的一维灰度直方图,并采用香农熵作为熵计算模型,从而得以跨越图像中若干局部区域去计算跨域香农熵。②对原始图像中每一个可能的灰度值,CSEM 方法都利用它去产生相应的二值图像,并从二值图像中提取约束轮廓图像,再由该约束轮廓图像和引导边缘图像共同构建灰度直方图。在该过程中,分割阈值借助于约束轮廓图像和原始图像之间保持密切关联。

参考文献

- [1] 陈海鹏,申铨京,龙建武.采用高斯拟合的全局阈值算法阈值优化框架[J].计算机研究与发展,2016,53(4):892-903.
CHEN Hai-peng, SHEN Xuan-jing, LONG Jian-wu. Threshold optimization framework for global thresholding algorithms using Gaussian fitting[J]. Journal of Computer Research and Development, 2016, 53(4): 892-903. (in Chinese)
- [2] 吴成茂.基于后验概率熵的正则化 Otsu 阈值法[J].电子学报,2013,41(12):2474-2478.
WU Cheng-mao. Regularization Otsu's thresholding method based on posterior probability entropy[J]. Acta Electronica Sinica, 2013, 41(12): 2474-2478. (in Chinese)
- [3] 吴一全,孟天亮,吴诗娅.图像阈值分割方法研究进展 20 年(1994-2014)[J].数据采集与处理,2015,30(1):1-23.
WU Yi-quan, MENG Tian-liang, WU Shi-hua. Research progress of image thresholding methods in recent 20 years (1994-2014)[J]. Journal of Data Acquisition and Processing, 2015, 30(1): 1-23. (in Chinese)
- [4] ZOU Y B, LIU H, ZHANG Q. Image bilevel thresholding based on stable transition region set[J]. Digital Signal Processing, 2013, 23(1): 126-141.
- [5] CHANG C I, DU Y, WANG J, et al. Survey and comparative analysis of entropy and relative entropy thresholding techniques[J]. IEE Proceedings-Vision, Image and Signal Processing, 2006, 153(6): 837-850.
- [6] 雷博,范九伦.一维 Renyi 熵阈值法中参数的自适应选取[J].光子学报,2009,38(9):2439-2443.
LEI Bo, FAN Jiu-lun. Self-adaptation preferences in one-dimensional Renyi entropy thresholding[J]. Acta Photonica Sinica, 2009, 38(9): 2439-2443. (in Chinese)
- [7] 曹建农.图像分割的熵方法综述[J].模式识别与人工智能,2012,25(6):958-971.
CAO Jian-nong. Review on image segmentation based on entropy[J]. Pattern Recognition and Artificial Intelligence, 2012, 25(6): 958-971. (in Chinese)
- [8] KAPUR J N, SAHOO P K, WONG A K C. A new method for gray-level picture thresholding using the entropy of histogram[J]. Computer Vision, Graphics and Image Processing, 1985, 29(1): 273-285.
- [9] SAHOO P K, WILKINS C. Threshold selection using Rényi entropy[J]. Pattern Recognition, 1997, 30(1): 71-84.
- [10] ALBUQUERQUE M P D, ESQUEF I A, MELLO A R G, et al. Image thresholding using Tsallis entropy[J]. Pattern Recognition Letters, 2004, 25(9): 1059-1065.
- [11] ABDIEL R R, ALEJANDRO R H M, GERARDO H C, et al. Determining the entropic index q of Tsallis entropy in images through redundancy[J]. Entropy, 2016, 18(8): 1-14.
- [12] NIE F Y, ZHANG P F, LI J Q, et al. A novel generalized entropy and its application in image thresholding[J]. Signal Processing, 2017, 134(5): 23-34.
- [13] ABUTABLEB A S. Automatic thresholding of gray-level pictures using two-dimensional entropy[J]. Computer Vision Graphics & Image Processing, 1989, 47(1): 22-32.
- [14] 吴一全,朱丽,吴诗娅.基于二维 Arimoto 灰度熵的图像阈值分割快速迭代算法[J].华南理工大学学报(自然科学版),2016,44(5):48-57.
WU Yi-quan, ZHU Li, WU Shi-hua. Fast iterative algorithm for image threshold segmentation based on two-dimensional Arimoto gray entropy[J]. Journal of South China University of Technology (Natural Science Edition), 2016, 44(5): 48-57. (in Chinese)
- [15] KELBERT M. Information Theory and Coding by Example[M]. Cambridge: Cambridge University Press, 2013. 26-27.
- [16] LINDBERG T. Scale-space for discrete signals[J]. IEEE Transactions of Pattern Analysis and Machine Intelligence, 1990, 12(3): 234-254.
- [17] GONZALEZ R C, WOODS R E. Digital Image Processing (4 Edition)[M]. New Jersey: Pearson, 2018. 190-197.
- [18] 邹耀斌.测试图像集、分割参考图像集和分割参考图像的制作规范[EB/OL]. <https://share.weiyun.com/5DG9wxw>, 2018-05-22.
- [19] CAI H M, YANG Z, CAO X H, et al. A new iterative tri-class thresholding technique in image segmentation[J]. IEEE Transactions on Image Processing, 2014, 23(3): 1038-1046.
- [20] BEMIS R. Thresholding Tool[EB/OL]. <http://cn.mathworks.com/matlabcentral/fileexchange/6770-thresholding-tool>, 2018-10-22.
- [21] CLEVELAND W S, DEVLIN S J. Locally weighted regression: an approach to regression analysis by local fit

ting[J]. Journal of the American Statistical Association, 1988, 83(403):596-610.

[22] PARZEN E. On estimation of a probability density func-

tion and mode[J]. The Annals of Mathematical Statistics, 1962, 33(3):1065-1076.

作者简介



邹耀斌(通信作者) 男,1978 年生于江西鹰潭. 现为三峡大学副教授、硕士生导师. 主要研究方向为图像处理和相似性理论.

E-mail: zyb@ctgu.edu.cn




乔焰 女,1984 年生于河北邯郸. 现为安徽农业大学副教授、硕士生导师. 主要研究方向为物联网和机器学习.

E-mail: qiaoyan101@gmail.com



孙水发 男,1977 年生于江西黎川. 现为三峡大学教授、硕士生导师. 主要研究方向为图像处理和计算机视觉.

E-mail: sunshuifa1977@yeah.net



臧兆祥 男,1985 年生于云南曲靖. 现为三峡大学副教授、硕士生导师. 主要研究方向为机器学习和进化计算.

E-mail: ambingo@zoho.com



夏平 男,1967 年生于湖北麻城. 现为三峡大学教授、硕士生导师. 主要研究方向为计算机视觉、智能信息处理、多尺度几何分析及应用.

E-mail: xiaping1967@163.com



王俊英 女,1971 年生于湖北黄梅. 现为三峡大学教授、硕士生导师. 主要研究方向为模式识别与人工智能.

E-mail: jywang1971@21cn.com



董方敏 男,1965 年生于湖北荆门. 现为三峡大学教授、博士生导师. 主要研究方向为智能信息处理和图形图像处理.

E-mail: fmdong_ctgu@126.com



龚国强 男,1976 年生于湖北荆门. 现为三峡大学副教授、硕士生导师. 主要研究方向为无线通信和大数据处理.

E-mail: gqiangong@21cn.com