

基于超像素多特征融合的快速图像分割算法

侯小刚¹, 赵海英², 马 严¹

(1. 北京邮电大学网络技术研究院, 北京 100876; 2. 北京邮电大学计算机学院, 北京 100876)

摘 要: 为了提高高分辨率图像分割效率, 解决复杂图案中待分割目标边缘附近前景与背景区分度小而造成的分割目标不完整问题, 本文通过引入超像素 HOG 特征, 提出了一种基于超像素多特征融合 (superpixel multi-feature fusion, SMFF) 的快速图像分割算法. 首先采用目前最有效的超像素算法对待分割图像进行超像素预分割, 然后提取基于超像素的 HOG 特征、Lab 颜色特征和空间位置特征, 设计基于超像素的多特征度量算法, 最终采用图割理论实现了基于超像素多特征融合的快速图像分割. 实验结果验证了本文算法的有效性, 其算法性能接近于目前最经典图像分割算法, 且本文算法的时间性能要明显优于其它对比算法.

关键词: 图像分割; 多特征融合; HOG 特征; 超像素

中图分类号: TP391 **文献标识码:** A **文章编号:** 0372-2112 (2019)10-2126-08

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2019.10.014

Fast Image Segmentation Algorithm Based on Superpixel Multi-feature Fusion

HOU Xiao-gang¹, ZHAO Hai-ying², MA Yan¹

(1. Institute of Network Technology, Beijing University of Posts and Telecommunications, Beijing 100876, China;

2. School of Computer Science, Beijing University of Posts and Telecommunications, Beijing 100876, China)

Abstract: In order to improve the efficiency of high-resolution image segmentation and solve the problem of incomplete segmentation caused by small discrimination of foreground and background in the complex pattern near the edge of the target to be segmented, we propose a fast image segmentation algorithm based on superpixel multi-feature fusion (SMFF). Firstly, the most effective superpixel algorithm is used for superpixel processing, and then the superpixel-based HOG feature, laboratory color feature and spatial position feature are extracted. Lastly, by designing a multi-feature measurement algorithm, the fast image segmentation algorithm based on superpixel multi-feature fusion is implemented. Experimental results verify the effectiveness of the proposed algorithm, which is close to the most classical image segmentation algorithm, and the time performance of the proposed algorithm is significantly better than other comparison algorithms.

Key words: image segmentation; multi-feature fusion; HOG features; superpixel

1 引言

图像分割是计算机视觉任务中极具挑战且十分重要的底层视觉问题, 具有广泛的应用前景^[1]. 随着数码技术的不断发展, 图像的分辨率有了极大的提高, 但这给目前像素级的图像分割算法不管是时间成本和空间成本都带来了较大挑战, 甚至还可能导致有些算法无法工作. 如图 1(a) 所示为一幅壁画采集图像, 其包含像素达到千万级, 一般图像分割算法已经很难对其直接进行分割, 即使在高性能处理器上使用经典高效的

FH^[2] 算法对其分割, 也需数分钟之久, 其分割结果不够理想, 主要表现为边缘紧贴度低, 特别是在目标边缘附近前景与背景区分度小的区域容易造成误分割现象.

目前有 2 种方法在一定程度上可以提高高分辨率图像分割效率: 1) 通过下采样, 把一幅 $M \times N$ 尺寸的高分辨率图像, 进行 s 倍下采样得到 $(M/s) \times (N/s)$ 的低分辨率图像, 然后进行后续处理. 但这类方法会丢失大量图像的细节信息, 下采样程度越大, 丢失信息越严重; 2) 通过生成超像素 (superpixel), 把成千上亿个像素划分为成百上千个同质的、具有良好边缘紧贴度的子区

域^[3],如图 1(b)所示,这为后续分割带来了方便,这种方法近年来在图像分割中得到了广泛的应用^[4,5].本文提出了一种基于超像素多特征融合(Superpixel Multi-Feature Fusion, SMFF)的快速图像分割算法,较好的解

决了上述问题.对图 1(a)所示图像采用本文所提算法进行分割,分割结果相比 HF 有了较大的改善,且本文算法在 26s 内实现了分割.

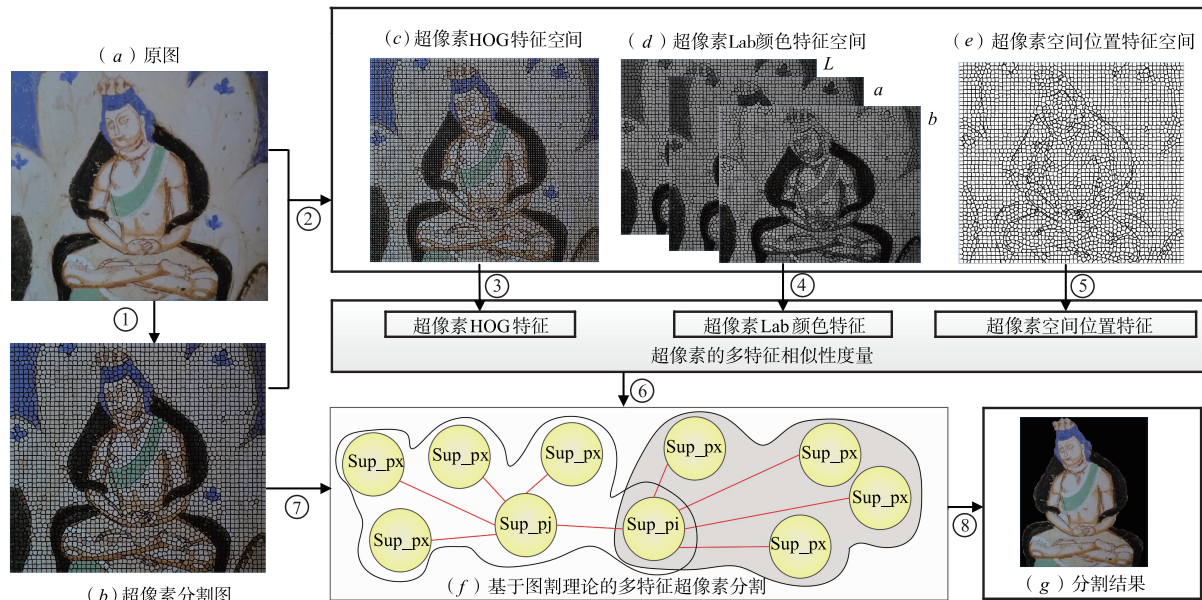


图1 SMFF快速图像分割算法流程图.①超像素预分割,②基于超像素的多特征提取,③基于超像素的HOG特征提取,④基于超像素的Lab颜色特征提取,⑤基于超像素的空间关系特征提取,⑥基于超像素的多特征融合相似性度量,⑦超像素划分,⑧基于图的超像素多特征快速图像分割.

2 相关工作

自上世纪七十年代以来,众多学者基于不同的理论已经发展出了大量图像分割算法^[6],基于超像素不同理论进行图像分割近年来成为一个研究热点,以下仅列举与本文方法相关的典型算法.

基于图论的方法是把图像中每个像素点看做图的顶点,图中的边为各像素点与其4领域或8领域相似度.如归一化割^[7]通过在拉普拉斯图中以迭代的方式找到最佳分割以得到全局最小化的目标函数,虽然取得了较好的效果,但计算复杂度较高.FH^[2]算法效率明显高于归一化割算法,分割效果良好,具有较高的边界召回率,同时兼顾了图像的全局信息,是最经典的基于图的图像分割算法之一.本文以超像素代替像素作为图顶点,不但提高了基于图的图像分割算法的效率,而且更有利于局部特征的提取与结构信息的表达,这是本文的出发点.

区域生长方法从预定义的种子点集合开始,使用不同的技术生成超像素.其中分水岭算法^[8]是基于区域最经典的算法之一.Mean shift算法^[9]是基于区域算法的另一种形式,具有较好的分割精度,然而算法的时间代价较高.文献[10]通过在种子点以测地流生长的方式创建超像素 TurboPixels,该算法效果与种子点位置

有很大的关系,且无法处理细长物体.Achanta等人设计了一种简单线性迭代聚类(SLIC)超像素生成算法^[11].后人在SLIC算法基础上发展了一系列超像素生成算法,如文献[12]通过对SLIC算法的改进,提出了一种本质流形的超像素图像分割方法.文献[13]通过对SLIC算法迭代更新阶段的改进,提出了一种更优的FLIC(Fast Linear Iterative Clustering)算法,FLIC算法比SLIC算法具有更强的鲁棒性、更优的算法性能,是目前最先进的超像素分割算法之一.

近年来,有不少研究通过超像素算法与其他算法相结合的方法实现了图像分割,取得了良好的分割效果.文献[14]在超像素的基础上,通过重新定义图像局部特征中光谱聚类,引入图的理论实现了图像分割.文献[15]提出了一种基于超像素生成目标的图像分割方法,可以实现基于目标的图像分割,但算法时间代价相对较高.文献[16]基于超像素算法与其他方法相结合的思路,实现了彩色图像分割.文献[17]采用SLIC算法对图像进行超像素处理,进行了特定领域图像分割,取得了较高的精度和鲁棒性.可以看出不同的算法有不同的应用背景,目前还没有一种通用的方法能够解决所有图像分割问题,本文针对高分辨率图像中待分割目标边缘附近前景与背景区分度小而容易造成的分割目标不完整的图案,提出了一种基于超像素多特征

融合的快速自动图像分割算法。

3 算法流程

图像梯度方向直方图(Histogram of Oriented Gradient, HOG)是基于形状特征的重要创新^[18],图像局部目标的表象和形状能够被 HOG 特征的梯度和边缘方向密度分布很好地描述. 本文通过结合 HOG 特征与超像素,设计基于超像素的 HOG 特征的提取算法,进行基于超像素的 HOG 特征相似性度量,这是本文的主要创新点. 基于超像素 HOG 特征的引入,一定程度上克服了复杂图案中待分割目标边缘附近前景与背景区分度小、或由于目标边缘处噪音影响而造成的分割不完整问题.

本文首先采用目前效率最高的超像素分割算法对待分割图像进行超像素处理,然后以超像素为基本单元,实现了一种基于超像素多特征融合(superpixel multi-feature fusion, SMFF)的快速图像分割算法,算法流程如图 1 所示. 实验结果表明本文算法精度接近于目前同类最经典算法,但本文算法具有最优的时间性能.

4 SMFF 图像快速分割

4.1 超像素生成

超像素生成质量与效率对基于超像素的图像分割

表 1 不同超像素方法的时间性能和算法性能比较

方法	时间性能(s)					算法性能		
	50 × 50	100 × 100	150 × 150	200 × 200	250 × 250	UE	BR	ASA
FH ^[2]	.097	.172	.489	.824	1.201	0.38	0.76	0.94
MS ^[9]	.116	.427	1.04	1.76	2.758	0.39	0.73	0.93
NC ^[4]	.091	.183	.304	.703	1.193	0.4	0.72	0.95
Intrinsic Manifold ^[12]	.037	.126	.341	.533	1.109	0.12	0.89	0.97
TurboPixels ^[10]	.023	.045	.158	.231	.452	0.15	0.91	--
ER ^[15]	.043	.098	.206	.354	.523	0.09	0.86	0.96
SLIC ^[11]	.024	.042	.168	.207	.305	0.11	0.87	0.95
FLIC ^[13]	.018	.038	.094	.135	.254	0.11	0.88	0.95

注: -- 数据暂缺

4.2 超像素多特征相似性度量

(1) 基于超像素的 HOG 特征相似性度量. 为便于表示,记上文生成的超像素为 Sup_p,各 Sup_p 边界可分为两类:第一类是为了划分 Sup_p 而形成的临时分割边界,需在后续基于超像素的图像分割中合并消失,这类 Sup_p 一般位于图像平滑区;第二类是为刻画目标边界而形成的真实超像素分割边界,需在后续分割中保留的边界,形成最终的分割边界,这类 Sup_p 一般位于图像的可变区.

算法有着直接的影响,本文对几种经典的超像素分割算法从时间性能和分割效果进行了对比,结果如表 1 所示. 可以看出,FLIC 算法在保持较好的超像素生成效果的同时,具有最优的时间效率,且该算法具有实现简单,空间复杂度低等特点. 故本文选择 FLIC 算法对待分割图像进行超像素预分割.

FLIC 算法通过设定一个参数 k (本文设置 k 随图像分辨率自适应变化),把像素数为 N 的图像粗分为步长为 $S = \sqrt{\frac{N}{k}}$ 的规则网格,然后把初始聚类中心移动到邻域内梯度最小的位置形成超像素划分聚类中心. 依据像素各自邻域,在一个三维的 CIELab 颜色空间 (l_i, a_i, b_i) 和一个二维的像素位置空间 (x_i, y_i) ,通过式(1)距离度量 D 对聚类中心周围 $2S \times 2S$ 的范围内的像素进行度量,使每个像素主动搜索属于自己的聚类中心,实现各像素到各自聚类中心的自适应分配和同步更新.

$$D(I_i, I_j) = \sqrt{d_c^2 + \left(\frac{d_s * m}{N_s}\right)^2} \quad (1)$$

$$d_s = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} \quad (2)$$

$$d_c = \sqrt{(l_i - l_j)^2 + (a_i - a_j)^2 + (b_i - b_j)^2} \quad (3)$$

其中变量 m 控制空间位置的权重,本文取 $m = 5, N_s = S$.

基于超像素的 HOG 特征具体提取步骤如下:首先采用积分图像计算待分割图像 $8\text{pixel} \times 8\text{pixel}$ 网格内 9 个方向 $\{0^\circ, 20^\circ, 40^\circ, 60^\circ, 80^\circ, 100^\circ, 120^\circ, 140^\circ, 160^\circ\}$ 上的梯度,得到 9×1 归一化的 HOG 特征;然后进行 HOG 特征与超像素预分割相结合. 超像素图像中 HOG 特征可分为 2 类:一类位于超像素边界上 (HOG 特征 2 像素范围内有超像素分割边界),记为边界 HOG_m;一类位于超像素内部,记为区域 HOG_m. 平滑区域的两类 HOG 特征可以起到弱化第一类边缘的功能,而可变区域的两

类 HOG 特征具有强化第二类边缘的性质. 如图 2 给出了超像素 HOG 特征可视化效果.

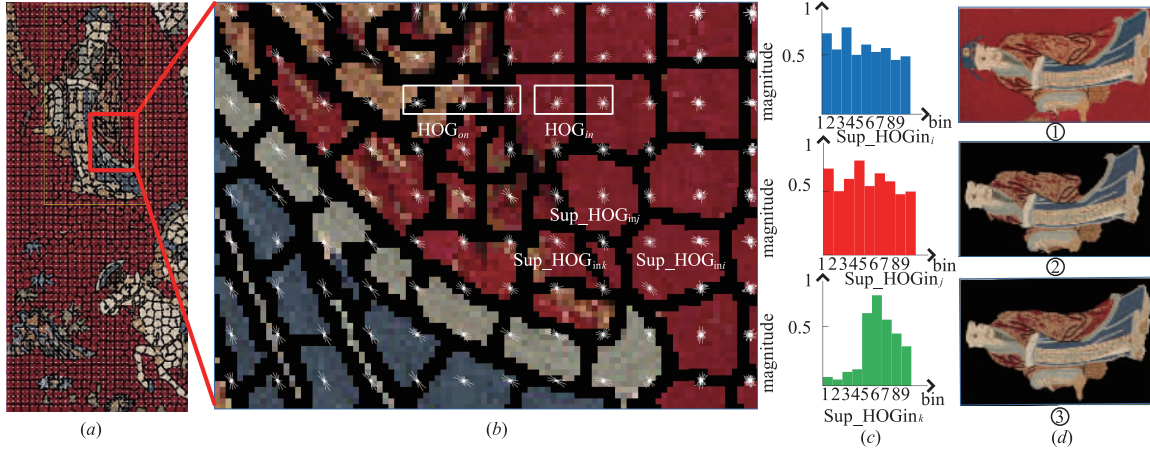


图2 超像素HOG特征示意图。(a) 超像素HOG特征叠加图, (b) 局部放大效果图, (c) Sup_HOG_{in}方向直方图, (d) 分割结果视觉对比效果

本文通过求取各超像素内不同的 HOG_{in} 在 9 个方向上幅度的均值表示该超像素的 HOG_{in} 特征, 记为 Sup_HOG_{in} . 如图 2(b) 所示, Sup_HOG_{in} 表示了 Sup_p_i 中 2 个 HOG_{in} 的均值, Sup_p_j 与 Sup_p_k 中分别只有一个 Sup_HOG_{in} , 故可直接用 Sup_HOG_{inj} 与 Sup_HOG_{ink} 表示. 图 2(c) 分别是 Sup_HOG_{inj} , Sup_HOG_{ink} 和 Sup_HOG_{inl} 对应的方向直方图可视化效果, 可以看出 Sup_HOG_{in} 表征了各 Sup_p 内信息变化的大小和方向. 本文对不同 Sup_p 的 Sup_HOG_{in} 特征相似性度量定义如下:

$$\rho_{S_HOG} = \frac{E[(sup_HOG_{ini} - \mu_i)(sup_HOG_{inj} - \mu_j)]}{\sigma_i \sigma_j} \quad (4)$$

$$\sigma_i = \sqrt{E((sup_HOG_{ini} - \mu_i)^2)} \quad (5)$$

其中, $sup_HOG_{ini} = \{bin_{ix} | x = 1, \dots, 9\}^T$, $sup_HOG_{inj} = \{bin_{jx} | x = 1, \dots, 9\}^T$, μ_i 和 μ_j 为不同 Sup_p 对应 Sup_HOG_{in} 的均值. σ_{S_HOG} 大小度量了不同 Sup_p 间 Sup_HOG_{in} 不同方向幅度差异性大小, σ_{S_HOG} 越大, Sup_p 间相似性越大.

HOG_{on} 表示位于 Sup_p 边界上的特征, 而每个 Sup_p 边上 HOG_{on} 的数量不一定相同, 因此本文采用其边上所有 HOG_{on} 的均值表示该 Sup_p 此条边的 HOG 特征, 记为 Sup_HOG_{on} . 本文采用 $\{\mu_{on}, \Sigma_{on}\}$ 对 Sup_HOG_{on} 差异性进行度量, 其中, μ_{on} 和 Σ_{on} 分别对应于 Sup_HOG_{on} 中 9 个方向幅度的均值和平均标准差. Σ_{on} 越大, 表示 Sup_HOG_{on} 不同方向幅值差异性越大, 说明 Sup_HOG_{on} 所在的此边保留的概率越大, 反之, 说明该条本消失的可能性越大.

基于 Sup_HOG_{in} 和 Sup_HOG_{on} 特征, 本文设计了基于 HOG 特征的超像素相似性度量算法^[19]:

$$Sim_HOG(i, j) = \rho_{S_HOG} + k e^{\Sigma_{on}} \quad (6)$$

常数项 $k = \{1, 0\}$, $k = 0$ 表示超像素 Sup_p_i 和 Sup_p_j

共同边上不存在 HOG_{on} 特征, $k = 1$ 表示存在 HOG_{on} 特征. 式(6)由两项组成: 第一项为区域度量项, 其取值大小表征了两超像素 Sup_p_i 和 Sup_p_j 彼此之间的相似程度; 第二项是边界度量项, 其取值大小表征了两超像素 Sup_p_i 和 Sup_p_j 共同边界存在的可能性. 式(6)取值越大, 超像素相似性越高, 合并的概率越大; 取值越小, 说明差异性越大, 两个超像素合并的概率越小.

(2) 基于超像素的强度特征相似性度量. 本文在 CIELab 颜色空间中进行 Sup_p 相似性度量:

$$Sim_I(i, j) = e^{-\frac{\eta_i \eta_j}{\sigma_i \sigma_j} + d(i, j)} \quad (7)$$

其中 η_i 和 η_j 分别表示不同 Sup_p 内部颜色强度平均标准差, $d(i, j) = \sqrt{(L_i - L_j)^2 - (A_i - A_j)^2 - (B_i - B_j)^2}$ 表示 Sup_p 间颜色强度距离. 式(7)取值越大, 表明 Sup_p_i 和 Sup_p_j 的在颜色空间相似性越高.

(3) 基于超像素的空间关系特征相似性度量. 本文 Sup_p 间空间关系特征相似性度量定义如下:

$$Sim_D(i, j) = e^{-\sqrt{(i_x, j_x)^2 + (i_y, j_y)^2}} \quad (8)$$

其中 (i_x, i_y) 和 (j_x, j_y) 分别表示 Sup_p_i 和 Sup_p_j 生成时分配与更新过程结束后种子点位置. 式(8)取值就越大, 表明他们的相似性越大.

单独的 Sim_HOG 、 Sim_I 和 Sim_D 从不同角度对 Sup_p 进行了相似性度量, 本文通过实验验证发现对以上三种度量进行简单的线性组合就可以得到满意的结果, 本文设计的 SMFF 算法定义如下:

$$Sim_Sup(i, j) = \alpha Sim_HOG(i, j) + \beta Sim_I(i, j) + \gamma Sim_D(i, j) \quad (9)$$

式(9)给出了 Sup_p_i 和 Sup_p_j 相似性的量化度量, Sim_Sup 越大, 表示超其相似性越大. 其中权重 α 、 β 和 γ 是在 BSDS500 数据集上基于 F-measure 值采用梯度上升学习获得^[6].

4.3 基于图的超像素图像分割算法

本文采用图割理论实现图像分割^[2],以 Sup_p 作为图的顶点,以 Sim_Sup 作为顶点间相似性度量权值,实现基于超像素保边缘紧贴度的快速图像分割算法.超像素 Sup_p_i 构成集合 V 中的元素,权值 $\omega(v_i, v_j)$ 表示由边 (v_i, v_j) 连接的两个超像素之间的相似性度量 Sim_Sup . 在基于图割的方法中,分割 S 把 V 分成不同的联通的区域 C ,每个连通域 C 对应一个子图 $G' = (V, E')$,其中 $E' \subseteq E$.

连通域 $C \subseteq V$ 最小生成树 $\text{MST}(C, E)$ 的最大权重作为连通域 C 类内不相似性度量,定义如下:

$$\text{Int}(C) = \max_{e \in \text{MST}(C, E)} \omega(e) \quad (10)$$

上式为连通域 C 内部不相似度量. 取连接两个连通域 $C_1, C_2 \subseteq V$ 边中权值 $\omega(v_1, v_2)$ 最小边作为通域 C_1, C_2 类间不相似性度量,定义如下:

$$\text{Dif}(C_1, C_2) = \min_{v_1 \in C_1, v_2 \in C_2, (v_1, v_2) \in E} \omega(v_1, v_2) \quad (11)$$

如果两个通域 C_1, C_2 彼此之间没有边连接,则 $\text{Dif}(C_1, C_2) = \infty$. 通过 $\text{Int}(C)$ 和 $\text{Dif}(C_1, C_2)$ 的取值,就可以判断连通域 C_1 和连通域 C_2 之间能否进行一次分割 S 以断开彼此之间的连接的边,从而形成一条分割边界 S_{edge} ,本文定义 $S_{\text{edge}}(C_1, C_2)$ 为其存在性度量:

$$S_{\text{edge}}(C_1, C_2) = \begin{cases} \text{true} & \text{if } \text{Dif}(C_1, C_2) > \text{MInt}(C_1, C_2) \\ \text{false} & \text{otherwise} \end{cases} \quad (12)$$

其中 $\text{MInt}(C_1, C_2)$ 表示联通域 C_1 和连通域 C_2 中最小的 $\text{Int}(C)$,定义如下:

$$\text{MInt}(C_1, C_2) = \min(\text{Int}(C_1) + \tau(C_1), \text{Int}(C_2) + \tau(C_2)) \quad (13)$$

其中阈值函数 τ 是联通域 C_1 和 C_2 各自内部不相似性控制函数, $\tau(C) = K/|C|$, $|C|$ 表示连通域 C 内超像素的个数, K 为一个给定的常数.

5 实验与结果

为了验证本文算法的有效性,本文在 (Berkeley Segmentation Dataset BSDS500)^[20] 和文化基因在线 (Culture Gene Online CGO) 两类数据集上,最采用 5.1 分割评价指标^[12],与 6 种经典的超像素分割的算法进行对比. 比算法分为两类:第一类为基于像素级的图像分割, Mean Shift (MS)^[9], FH^[2] 和 Multiscale NCuts (NC)^[4];第二类为基于超像素级的图像分割, Bipartite Graph (BG)^[5], Entropy rate (ER)^[15] 和 Superpixel Watershed (SW)^[17].

5.1 评价指标

欠分割错误率 (USE): 是算法实际分割结果相比 GT 漏分割像素的百分比,定义如下:

$$\text{USE}_g(S) = \frac{\sum_i \sum_{k: S_i \cap G_k \neq \emptyset} |S_i - G_k|}{\sum_i |G_i|} \quad (14)$$

$g = \{G_1, G_2, \dots, G_n\}$ 表示图像真实分割 (Ground Truth GT) 形成的 n 个分割结果, $|G_i|$ 表示第 i 个分割结果的大小, S_k 算法分割出的第 k 个结果. USE 值越小,表示算法分割错误率越低,算法性能越好.

边界召回率 (BR). BR 是算法实际分割目标的边界落在 GT 目标边界 ε 像素内的百分比,是边界紧贴度的度量, BR 定义如下:

$$\text{BR}_g(S) = \frac{\sum_{p \in \delta g} \prod_{q \in \delta S} (\min_{q \in \delta S} \|p - q\| < \varepsilon)}{|\delta g|} \quad (15)$$

其中, δg 和 δS 分别表示 GT 目标边界和 GT 目标边界与算法分割目标边界的交集,指示函数 \prod 表示在 ε 范围内最近像素的距离,本文取 $\varepsilon = 2$. BR 越大,表示边缘紧贴度越好,算法性能越好.

可达分割准确率 (ASA). 给出了基于超像素分割的最高可达精度. 表示如下:

$$\text{ASA}(S) = \frac{\sum_k \max |S_k \cap G_i|}{\sum_i |G_i|} \quad (16)$$

ASA 越大,表示分割算法精度越高.

时间成本 (TC). 时间成本是指在特定处理器下,算法对某一分辨率图像进行运算所需要的执行时间. 本文在 16GB 内存, $4 \times \text{Intel Core i5-3470 } 3.2\text{GHz}$ 处理器上对本文算法进行时间成本测试.

5.2 BSDS500 数据集评价结果

本文在 BSDS500 数据集上,取不同 5 人分割的平均值作为真实分割背景 (Ground Truth GT) 图像,计算各算法在每副图像上的 ESU、BR、ASA 和 TC 值,取平均值,绘制如图 3(a) ~ 图 3(c) 的性能对比曲线. 从图 3(a) 可以看出本文算法的 USE 性能优于其他绝大部分算法, USE 值平均比 FH 算法提升了 0.32, 略低于 USE 性能最好的 ER 算法 0.03; 从图 3(b) 可知, 本文算法 BR 性能略低 ER 算法 0.01, 但相比 FH 算法 BR 性能平均提升了 0.1. 从图 3(c) 中可以看出, 本文算法的 ASA 当测试数据超过一定数量时表现出最好性能; 图 3(d) 可以看出本文表现出了最优的时间成本. 由此可见, 本文算法在 USE、BR 和 ASA 等分割性能接近或超过其他最经典分割算法的前提下, 在时间成本上取得了最好的表现. 图 4 给出了本文算法与其他分割算法的视觉对比实验结果. FH 和 BG 分别代表基于像素和基于超像素图像分割算法, 参数是按原文作者所建议值进行设置. 可以看出, 相比 FH 算法, 本文算法均实现了较为完整的分割区域, 保持了高边缘紧贴度的同时避免了

过分割;相比 BG 算法,本文算法体现了目标内部不一致信息,保持了目标内部细节信息.

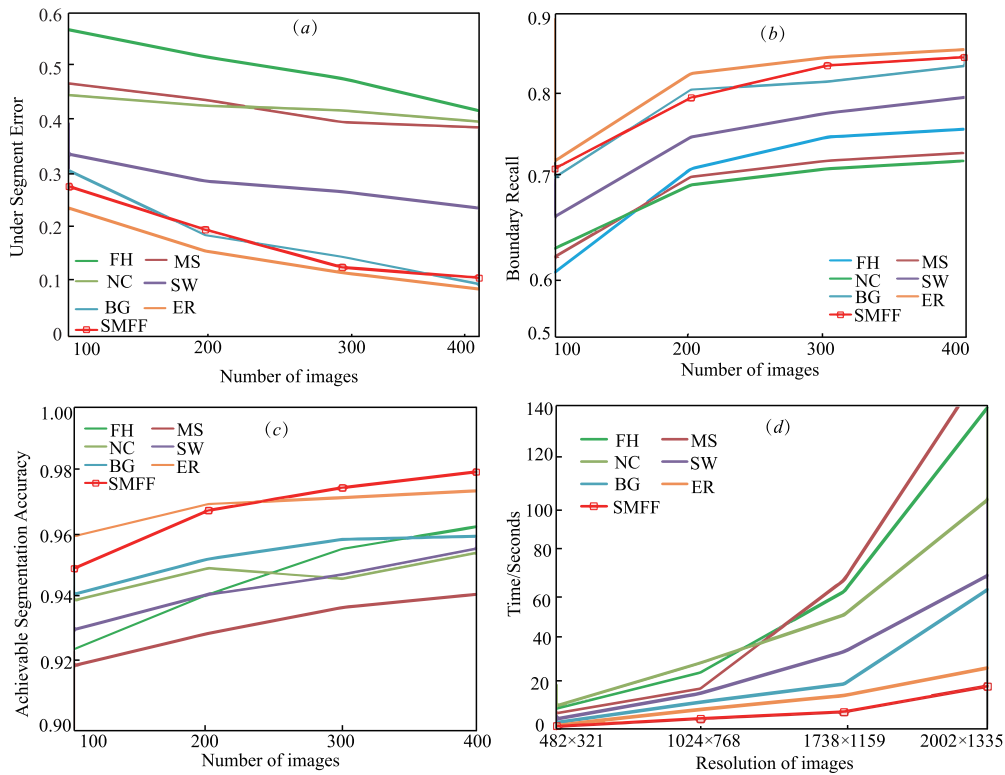


图3 BSDS500数据集上不同算法分割性能曲线图, (a) USE性能曲线, (b) BR性能曲线, (c) ASA性能曲线, (d) TC性能曲线.



图4 BSDS500数据集不同算法分割结果视觉效果对比图. 第1列和第2列分别为测试图像和Ground Truth图像. 第3列到第5列分别为 (FH)^[3] ($\sigma=0.8, k=300$), Bipartite Graph^[8] ($MS+FH2, \sigma=0.8, c=300, M=100$) 和本文算法 ($K=3$) 分割结果

5.3 CGO 数据集评价结果

CGO 是“移动媒体与文化计算北京市重点实验室”用于文化计算的在线数据集,本文选择 CGO 数据集对算法做进一步对比验证. 图 5(a)与图 5(c)是选自 CGO 数据集中壁画图像和民族服饰图像,其选择的特点是图像中待分割目标的某些部位,由于图像年久褪色或

由于图像本身的特点,前景中混合了一些背景颜色,例如如图 5(a)目标①②中龙爪部位和图 5(c)中目标②④,此类目标给分割带来了一定的难度. 采用分割性能较好 ER 算法,分割结果有一定的缺失和不完整,而本文算法取得了较好的分割效果. 这是因为基于超像素的 HOG 特征既考虑了区域的颜色信息,也考虑了区域的

纹理信息,在基于超像素的图像分割中具有一定的抗噪能力和保持目标完整性的特点,对通过颜色、位置等

其他信息难以区分的复杂区域有较好的区分效果.



图5 本文算法CGO数据集上分割结果对比。(a)为民族服饰图像(dpi=300,768×1024,K=5), (c)为壁画图像(dpi=300,2002×1335,K=6), (b) (d)为(a) (c)中相应分割结果分别为采用ER算法和本文算法分割结果(红色边框为本文结果).本文K的取值一般在[2,6]之间较为合理

6 总结及未来工作

本文以超像素为基本单位,提取基于超像素的HOG特征、强度特征和空间关系特征,通过设计基于超像素的多特征融合相似性度量算法,实现了SMFF的快速图像分割,有效的提高了高分辨率图像分割的效率,为实现高分辨率图像快速分割提供了一种解决方法.其中通过引入基于超像素的HOG特征,解决了一些复杂图像中由于年久残损(如图5(a)目标①②中龙爪部位)或图像本身绘画风格(如图5(c)目标②④)使得目标与背景边界处区分度较小,从而采用传统算法会造成目标不完整的问题.算法在BSDS500数据集和CGO数据集上和最经典的图像分割算法进行了对比实验,定量与定性的实验结果表明,本文算法在保证分割质量的同时,有着最低时间成本.但如何提高对线状目标捕捉的能力和能够实现更有效的超像素级高层语义特征提取,仍然值得进一步研究.

参考文献

- [1] Pont-Tuset J, Arbelaez P, Barron J T, et al. Multiscale combinatorial grouping for image segmentation and object proposal generation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(1): 128 - 140.
- [2] Felzenszwalb P F, Huttenlocher D P. Efficient graph-based image segmentation[J]. International Journal of Computer Vision, 2004, 59(2): 167 - 181.
- [3] Achanta R, Sussstrunk S. Superpixels and polygons using simple non-iterative clustering[A]. Proceedings of IEEE Computer Vision and Pattern Recognition[C]. Honolulu, Hawaii, USA: IEEE, 2017. 4895 - 4904.
- [4] Cour T, Benezit F, Shi J. Spectral segmentation with multi-scale graph decomposition[A]. Proceedings of IEEE Computer Vision and Pattern Recognition[C]. San Diego, California, USA: IEEE, 2005. 1124 - 1131.
- [5] Chang S F, Wu X M, Li Z. Segmentation using superpixels: A bipartite graph partitioning approach[A]. Proceedings of IEEE Computer Vision and Pattern Recognition[C]. Providence, Rhode Island, USA: IEEE, 2012. 789 - 796.
- [6] Arbelaez P, Maire M, Fowlkes C, et al. Contour detection and hierarchical image segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2011, 33(5): 898 - 916.
- [7] Shi J, Malik J. Normalized cuts and image segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2000, 22(8): 888 - 905.
- [8] Vincent L, Soille P. Watersheds in digital spaces: an efficient algorithm based on immersion simulations[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1991, 13(6): 583 - 598.
- [9] Comaniciu D, Meer P. Mean shift: A robust approach toward feature space analysis[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2002, 24(5): 603 - 619.
- [10] Levinshstein A, Stere A, Kutulakos K N, et al. TurboPixels: fast superpixels using geometric flows[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2009, 31(12): 2290 - 2297.
- [11] Achanta R, Shaji A, Smith K, et al. SLIC superpixels compared to state-of-the-art superpixel methods[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2012, 34(11): 2274 - 2282.
- [12] Liu Y J, Yu M, Li B J, et al. Intrinsic manifold SLIC: a simple and efficient method for computing content-sensitive superpixels[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018, 40(3): 653 - 666.
- [13] Zhao J X, Ren B, Hou Q B, et al. FLIC: fast linear iterative clustering with active search[J]. Computational Visu-

- al Media, 2018, 4(4):333-348.
- [14] Zhang Z, Xing F, Wang H, et al. Revisiting graph construction for fast image segmentation[J]. Pattern Recognition, 2018, 78(6):344-357.
- [15] Liu M Y, Tuzel O, Ramalingam S, et al. Entropy rate superpixel segmentation[A]. Proceedings of IEEE Computer Vision and Pattern Recognition[C]. Colorado Springs, Colorado, USA; IEEE, 2011. 2097-2104.
- [16] 李磊, 董卓莉, 张德贤. 基于自适应区域限制 FCM 的图像分割方法[J]. 电子学报, 2018, 46(6):1312-1318.
Li L, Dong Zh L, Zhang D X. Adaptive region constrained FCM algorithm for image segmentation [J]. Acta Electronica Sinica, 2018, 46(6):1312-1318. (in Chinese)
- [17] Wu W, Lin J, Wang S, et al. A novel multiphoton microscopy images segmentation method based on superpixel and watershed[J]. Journal of Biophotonics, 2017, 10(4):532-541.
- [18] Dalal N, Triggs B. Histograms of oriented gradients for human detection[A]. Proceedings of IEEE Computer Vision and Pattern Recognition[C]. San Diego, California, USA; IEEE, 2005. 886-893.
- [19] Cordts M, Rehfeld T, Enzweiler M, et al. Tree-structured models for efficient multi-cue scene labeling[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(7):1444-1454.
- [20] 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]. Proceedings of IEEE Computer Vision and Pattern Recognition[C]. Kauai, Hawaii, USA; IEEE, 2001. 416-423.

作者简介



侯小刚 男, 1984 年生, 甘肃天水人, 北京邮电大学博士研究生. 主要研究方向为数字图像处理与文化计算等.
E-mail: houxiaogang05@bupt.edu.cn



赵海英 (通讯作者) 女, 1972 年生, 山东烟台人, 北京邮电大学副教授, 硕士生导师. 主要研究方向为多媒体数据挖掘、图像处理和计算理论体系研究.
E-mail: zhaohaiying@bupt.edu.cn



马严 男, 1955 年生, 北京人, 北京邮电大学教授, 博士生导师. 主要研究方向为计算机网络及其应用、网络管理和网络安全等.
E-mail: mayan@bupt.edu.cn