

基于可区分边界和加权对比度优化的 显著度检测算法

姜青竹, 田 畅, 吴泽民, 刘 涛, 张 磊

(中国人民解放军理工大学通信工程学院, 江苏南京 210007)

摘 要: 针对目前基于先验背景的显著度算法中,把图像的所有边界同等对待带来的误判别问题,本文提出一种基于可区分边界和加权对比度优化的显著度检测算法.为了客观评价显著度,本文首先设计了一种粗略评估显著度的指标,用来选择较好的背景图.以该指标为基础,该算法先利用 Hausdorff 距离对边界进行区分,再利用测地线距离变换完成可靠的背景检测;然后,构造了一种前景-背景加权的对比度来计算初始显著度;最后,使用加权的优化模型进行显著度的优化.在5个公开数据集上的实验结果表明,本文算法在保持快速、无训练等优点的同时,检测性能优于目前主流算法.

关键词: 显著度检测;背景图;可区分边界;加权对比度

中图分类号: TP391.4 **文献标识码:** A **文章编号:** 0372-2112 (2017)01-0147-10

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2017.01.021

Saliency Detection Based on Discriminative Boundary and Weighted Contrast Optimization

JIANG Qing-zhu, TIAN Chang, WU Ze-min, LIU Tao, ZHANG Lei

(College of Communications Engineering, PLA University of Science and Technology, Nanjing, Jiangsu 210007, China)

Abstract: To address the misjudgment caused by all boundaries of an image being equally and artificially selected as background in most of state-of-the-art models using background prior, this paper proposes an algorithm called weighted contrast optimization based on discriminative background. Firstly, a metric is constructed to roughly but objectively estimate a saliency map, which is used to choose a better background map. Based on this metric, a reliable background detection model is constructed through geodesic distance transformation after discriminating each boundary via Hausdorff distance. Then, the only background weighted contrast is improved into fore-background weighted contrast. Last, the final saliency map is obtained through weighted optimization framework. Extensive experiments on five public datasets demonstrate that the proposed algorithm outperforms state-of-the-art methods.

Key words: saliency detection; background map; discriminative boundary; weighted contrast

1 引言

视觉显著度检测用于获取图像中最容易引起人眼注意的区域.自从Itti等人^[1]在1998年提出第一个通用的显著度计算模型以来,一直是计算机视觉领域中的一个研究热点.作为一项预处理过程,显著度被广泛应用于图像分割^[2]、图像重定位^[3]、目标跟踪^[4]、图像分类^[5]、视频压缩^[6]等领域.

显著度检测方法通常分为自底向上(Bottom-up)和自顶向下(Top-down)两种模式.前者基于低级视觉特征,由数据驱动;后者基于高级视觉特征,由知识和任务

驱动. Borji 等人在文献[7,8]中对近二十年来的40种算法进行了详细的比较.其中比较有代表性的有基于“Center-Surround”的差异模型^[1]、基于图的模型^[9]、频域模型^[10,11]以及基于直方图的全局对比度模型^[12].这些模型多数都是基于对比度优先或中心优先.

自从Wei^[13]首先利用图片边界作为背景的思路提出后,越来越多的算法采用背景优先或边界优先,取得了较好的检测效果.比如在文献[14]的算法中,将到边界的对比度作为区域的背景性(Backgroundness,属于背景的可能性)特征项进行学习;在文献[15]的算法中,计算像素到图像边界的流形排序值定义显著度;在文献[16]的算

法中,将边界作为先验种子,分别利用密集重构、稀疏重构和贝叶斯融合计算显著度;鲁棒背景检测(Robust Background Detection, RBD)^[17]算法提出边界连通度的概念来估计背景概率,然后对局部对比度进行加权,性能得到较大提升.但所有这些模型都把边界同等处理,没有考虑到目标位于边界的情况.尽管 RBD 算法可以检测部分边界目标情况,但其置信度不高,造成其后期的优化模型效果有限.如何准确判断图像各个边界的背景性,是改进这些基于边界先验的算法的关键.所以,本文针对上述算法人为地将图像各边界同等概率处理带来的背景先验错误,首先利用各边界之间的差异计算其背景性,然后使用测地线距离变换估计背景图,有效地解决了目标位于边界带来的误判别问题.

为进一步提高检测的精度,保持较好的轮廓信息,目前很多算法都采用了图模型.这些方法一般分为两大类:一是基于图的传播模型,文献[18]对几种使用广泛的传播模型如 CRF 模型、二次能量模型、随机游走模型以及流形排序模型等进行了归纳,Liu^[19]构造偏微分方程建立传播模型;二是基于图的优化模型,如 Li^[20]的以显著区域的稀有性、中心偏移性为基础的二次规划模型,Zhu^[17]的结合前景、背景概率和平滑性约束的优化模型(本文简称为 RBD 模型).这两类模型的重点都在于背景或前景种子的选取. RBD 模型在 Borji^[8]的测评中性能和速度都相对较好,本文在 RBD 模型基础上添加适当的权重,获得了更好的优化效果.

另外,如果能客观评估显著图的质量,则可以对显著度的计算、筛选、融合等过程进行有效指导.而在无真实值参考的情况下,目前尚无快速有效的显著图质量评估方法.本文参考文献[21],采用显著图中的紧致性作为核心准则,构造了一种简单有效的无参考评价指标,对显著图质量进行粗略评估.在本文中,该指标被用于多种背景图的筛选.

综上,本文针对无参考值下评估显著图困难,将图像各边界同等概率处理带来的背景先验错误和常规局部对比度计算有所偏差等问题,主要完成了三项工作:(1)提出一种无参考的显著图质量评估指标,用来对背景图进行筛选;(2)基于 Hausdorff 距离和测地线距离变换,提出一种可区分边界的背景图估计算法;(3)基于背景图,构造前景-背景加权对比度计算初始显著图,然后利用加权的优化模型得到最终的显著图.5 个公开数据集上的实验表明,本文算法的性能优于列出的 14 种算法.

2 相关的定义

2.1 测地线距离变换

Wei^[13]首次将测地线距离用于显著度的求解,取得了较好的效果.测地线距离定义为:

$$d(p, q) = \min_{p_i = p, p_2, \dots, p_n = q} \sum_{i=1}^{n-1} D_f(p_i, p_{i+1}) \quad (1)$$

其中 p, q 表示图 $G = (V, E)$ 中的两个点, $D_f(p_i, p_{i+1})$ 表示两个相邻点在特征空间 f 上的距离. Krahenbuhl^[22]做了一步的推广,提出测地线距离变换(Geodesic Distance Transform, GDT)的概念用来计算点 p 到点集 Q 的最短测地线距离:

$$D(p; Q) = \min_{q \in Q} d(p, q), Q \subset V \quad (2)$$

2.2 边界连通度

目前,基于背景先验的方法都默认图像的四条边界作为背景.这种人为指定四边同等作为背景的方式,显然有失普适性.文献[13]通过将边界转换成一维显著度检测的方式进行区分,但鲁棒性不够^[17].而 RBD 算法^[17]根据人眼直观感受和大量数据统计,提出用边界连通度(Boundary Connectivity, BC)的概念来构造背景图:

$$BC(p_i) = \frac{Len_{bnd}(p_i)}{\sqrt{Area(p_i)}} \quad (3)$$

其中, $Area(p_i)$ 表示跟超像素 p_i 特征相近的连通区域的面积, $Len_{bnd}(p_i)$ 表示连通区域跟边界 Bnd 相交的长度.一个超像素 p_i 的背景概率被定义为

$$\omega_i^{BC} = 1 - \exp\left(-\frac{BC^2(p_i)}{2\sigma_{BC}^2}\right) \quad (4)$$

其中 σ_{BC} 用来控制影响的权重,经验性地取 1.

2.3 Hausdorff 距离

Hausdorff 距离是两个点集的距离,一般定义为

$$H(A, B) = \max(h(A, B), h(B, A)) \quad (5)$$

其中 $h(A, B)$ 表示点集 A 到 B 的有向距离:

$$h(A, B) = \max_{a \in A} d_B(a), d_B(a) = \min_{b \in B} \|a - b\| \quad (6)$$

但该距离会由于个别孤立点的存在导致测度不准确,所以 Dubuisson^[23]提出了修正的 Hausdorff 距离(Modified Hausdorff Distance, MHD):

$$h(A, B) = \frac{1}{N_A} \sum_{a \in A} d_B(a) \quad (7)$$

其中 N_A 表示点集 A 的元素个数.该距离适合处理目标相似度匹配问题,但由于其均值化操作会削弱点集之间的差异性区分^[24]. Andree^[25]又提出了广义 Hausdorff 距离:

$$h(A, B) = \frac{1}{N_A - K + 1} \sum_{i=K}^{N_A} d_B(a_i) \quad (8)$$

该式表示从第 K 个距离排序值到最大值的平均值.实际上,当 $K = N_A$ 时表示一般的 Hausdorff 距离, $K = 1$ 时表示 MHD.该定义综合考虑了代表性元素和孤立点的影响.通常情况下 K 值取为 $0.6 \times N_A$ ^[24].

3 无参考的显著图评估

在没有真实值参考的情况下,目前还没有一个能

客观评判显著图质量的指标. 文献[21]给出了一种无参考的显著图比较模型, 但该模型提取特征较多, 计算复杂耗时(约 20 秒/幅), 只能作为后期比较. 大量实验发现^[18,21,26,27], 显著目标的紧致性是其最主要的特征, 一般情况下显著目标都会相对连通且集中. 所以本文主要设计体现紧致性的评价指标.

文献[27]给出了一种计算元素空间距离分布的方法, 借鉴其思想, 本文使用显著度加权的空间距离之和来计算显著图 S 的空间分布性 (Spatial Distribution of Saliency Map, SDSM):

$$SDSM(S) = \sqrt{\frac{1}{S} \sum_{i=1}^N \|x_i - \mu\|_2^2 s_i} \quad (9)$$

其中 x_i 表示元素 (这里的元素可以是像素、矩形块、超像素或更大的区域, 下同) 内所有像素的平均位置, $\mu = \frac{1}{S} \sum_{i=1}^N x_i s_i$ 是所有元素显著值加权的平均位置, $S = \sum_{i=1}^N s_i$ 表示所有元素显著值总和. 显然, SDSM 越大表示高显著值区域越分散. 但是该指标存在两个问题: 一是孤立高显著值点会影响整体的空间分布值; 二是同等空间分布情况下会偏向于值比较低的显著图. 如图 1 所示, 从计算的 SDSM 结果看, 左边的显著图要优于右边, 但这与人眼直观感觉显然不符.

文献[21]中使用覆盖所有显著值一定比例 (比如 80%) 的最小矩形窗口内的平均显著值 (Mean Saliency in Covered Window, MSCW) 来度量紧致性:

$$MSCW(S) = \frac{1}{w \times h} \sum_{i=1}^w \sum_{j=1}^h s(i, j) \quad (10)$$

其中 w, h 是选出窗口 Wnd 的宽和高, $s(i, j)$ 为点 (i, j) 的显著值. 该方法需扫描全图以获取最小覆盖窗口, 运算量过大.

本文从简化计算 MSCW 指标入手. 首先将显著图分别在水平和垂直方向上进行投影并计算其累积和:

$$P_i^H = \sum_{j=1}^w s(i, j), \quad P_j^V = \sum_{i=1}^h s(i, j), \quad (11)$$

$$Cum(P_i^H) = \sum_{k=1}^i P_k^H, \quad Cum(P_j^V) = \sum_{k=1}^j P_k^V.$$

其中 W, H 是图像的宽和高. 假设要搜索覆盖一定比例 $\alpha (0 < \alpha \leq 1)$ 的窗口, 所有像素显著值总和为 S , 定义阈值: $thd_{wnd} = (1 - \alpha) \times S/4$, 则累积显著值在 $[thd_{wnd}, S - thd_{wnd}]$ 之间的即为覆盖窗口, 其边界分别为:

$$Left_{wnd} = \min_i \{ Cum(P_i^H) \geq thd_{wnd} \},$$

$$Right_{wnd} = \max_i \{ Cum(P_i^H) \leq S - thd_{wnd} \} \quad (12)$$

$$Top_{wnd} = \min_j \{ Cum(P_j^V) \geq thd_{wnd} \},$$

$$Bottom_{wnd} = \max_j \{ Cum(P_j^V) \leq S - thd_{wnd} \}$$

图 1 给出了覆盖 80% 显著度窗口的定位示例. 本




图1 MSR测度的示意图

文把显著图 S 的质量评价指标定义为 MSCW 与 SDSM 之比 (MSCW-SDSM Ratio, MSR):

$$MSR(S) = \frac{MSCW(S)}{SDSM(S)} \quad (13)$$

该式表示, 覆盖整体显著图最小窗口内的显著值越高、空间分布越集中, 则该显著图质量越好. 图 1 中, 右侧显著图虽然空间分布 SDSM 低于左侧显著图, 但目标区域相对集中高亮, MSCW 相对较高, 所以总体 MSR 指标应该高于左侧显著图.

为进一步说明这一指标的有效性, 本文以 RBD 算法在 MSRA^[26] 数据集上求出的 5000 张显著图进行统计. 首先, 计算各显著图的 MAE 值和 F-Measure 值作为评判指标的真值. 然后, 分别计算各显著图的 SDSM、MSCW 和 MSR 得分, 并画出各得分与 MAE 和 F-Measure 的散点图, 如图 2 所示. 从图中可以看出, SDSM、MSCW 与 MAE、F-Measure 的关系都不明显, 但 MSR 与 MAE 和 F-Measure 趋势大致相同, 基本成负指数关系, 充分证明 MSR 指标用来评价显著图的可行性. 这里的 MSR 指标主要用于后文中背景图的选择.

4 基于选择性背景的加权对比度优化算法

基于前文中的测地线距离变换、广义 Hausdorff 距离以及 MSR 指标, 本文提出了基于选择性背景的加权对比度优化 (weighted Contrast Optimization based on Selective Background, wCOSB) 算法. 图 3 给出了算法的主要流程. 主要分为五个步骤: (1) 预处理: 将输入图像分割为超像素, 提取特征, 构造图结构; (2) 背景提取: 本文提出一种基于可区分边界 (Discriminative Boundary, DB) 的背景图提取方法, 特别针对目标位于边界的情况; (3) 背景选择: 计算 MSR 指标选择相对较好的背景图; (4) 计算前景-背景加权的局部对比度; (5) 使用 RBD 优化模型进行优化, 得出最终显著图.

4.1 图的构建

首先采用 SLIC 算法^[28] 将原图分割为 N 个超像素, 每个超像素的特征使用该区域内所有像素 CIE Lab 空间内的颜色平均值表示. 构造加权无向图 $G = \langle V, E \rangle$, V 表示超像素点集, E 表示相邻超像素之间的边集. 这里边的权重定义为:




图2 各指标与MAE和F-Measure的散点图(从上到下依次是:SDSM、MSCW和MSR;第一列为MAE指标,第二列为F-Measure指标;图中曲线表示拟合曲线)

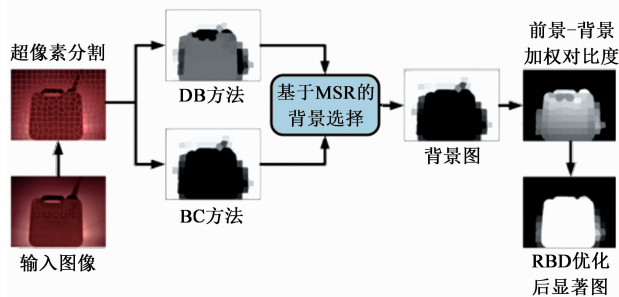


图3 wCOSB算法流程图

$$w_{ij} = \exp\left(-\frac{d_c(p_i, p_j)^2}{2\sigma_c^2}\right) \quad (14)$$

其中 $d_c(p_i, p_j)$ 表示超像素 p_i 和 p_j 在 CIELab 空间上平均颜色值的欧氏距离, 选取 CIELab 颜色空间主要是由于和人类感知更加吻合^[12]. σ_c 用来控制权重的强度, 在 $[5, 15]$ 之间不敏感, 同文献^[17]取 10.

4.2 DB 法背景图估计

对常规的背景区域(如图 4(b)最后一行), BC 方法处理效果较好, 但对位于边界的大目标检测效果较差(如图 4(b)前三行). 主要是该方法在利用边界背景时都将各边界等概率处理, 导致后续计算存在较大误差. 因此, 需要对图像各边界的背景性进行可靠的预估计.

针对显著目标与边界接触的问题, 本文给出一种




图4 BC方法和DB方法背景图及显著图比较:(a)原图;(b)BC背景图;(c)BC优化后显著图;(d)DB背景图;(e)仅背景加权对比度;(f)前景-背景加权对比度;(g)本文优化后显著图;(h)真值

可区分边界的背景估计方法. 首先定义图像的四个边界为 $B = \{top, bottom, left, right\}$, 然后定义与图像各边界相交的超像素集合, 边界集合用 B_n ($n = 1, 2, 3, 4$) 表示. 使用式(2)的测地线距离变换, 每个图像内部的超像素 p_i 到每个边界的相似度定义为:

$$\xi_i^n = \exp\left(-\frac{D^2(p_i; B_n)}{2\sigma_b^2}\right) \quad (15)$$

σ_b 控制权重的强度, 这里取所有测地线距离变换 $D(p; B_n)$ 的标准差. 但如前所述, 每个边界并不一定完全就是背景, 需要对每个边界是否可能存在前景区域进行估计. 这里采用广义 Hausdorff 距离比较各边之间的差异度:

$$H(B_n, B_m) = \max(h(B_n, B_m), h(B_m, B_n)) \quad (16)$$

其中 $h(B_n, B_m)$ 采用式(8)进行计算. 以 $H(B_n, B_m)$ 为元素, 构造边界超像素集合的 4×4 差异度矩阵 H , 然后将 H 按列相加得到每条边与其他边的差异度 $L_n = \sum_{m=1}^4 H(B_n, B_m)$, 则每个边界的背景性定义为

$$P(B_n) = \begin{cases} 1, & \text{if } (L_n - \bar{L})/\bar{L} < thd_L \\ \max(\bar{L}/L_n, 0.5), & \text{otherwise} \end{cases} \quad (17)$$

其中 \bar{L} 为 L 的均值, thd_L 为设定的阈值, 本文实验中取 0.5. 如果某边和其他边差异度超过平均值一定阈值, 则认为该边界很可能存在前景区域, 且偏差越大背景概率越小. 但通常一条边不可能全是前景区域, 所以设定 $P(B_n)$ 的下界为 0.5. 由全概率公式, 得出以边界 B_n 作为背景的所有超像素的背景概率:

$$\omega_i^n = \xi_i^n P(B_n) + (1 - \xi_i^n)(1 - P(B_n)) \quad (18)$$

上式前一项表示与高背景性的边界越相似的超像素背景概率应该越大, 后一项表示与低背景性的边界差异越大的超像素背景概率应该越大. 每选定一条边就可以确定全图中每个超像素的背景概率, 从而形成一张背景图. 最终的背景图定义为四个背景图的平均值:

$$\omega_i = \frac{1}{4} \sum_{n=1}^4 \omega_i^n \quad (19)$$

为了避免超像素的背景概率值过大或过小, 同时

为了保证前景目标的查全率,这里使用 Sigmoid 函数对上述概率进行平滑和拉伸:

$$\omega_i^{DB} = \frac{1}{1 + \exp(-c(\omega_i - b))} \quad (20)$$

这里取参数 $b = 0.6, c = 15$. DB 方法检测的效果如图 4(d) 所示,可见本文提出的可区分边界后的背景图可以准确地估计出目标位于边界的情况.

4.3 背景图的选择

本文的 DB 法可以准确估计出目标在边界的情况,而 BC 法更加适用于目标位于内部的情况.为了综合两种方法,选择较好的背景图,这里采用前面的 MSR 指标对两个背景图进行评估,从 BC 法和 DB 法中选择较好的背景图(Selective Background, SB):

$$\omega^B = \begin{cases} \omega^{BC}, & \text{if } MSR(1 - \omega^{BC}) > MSR(1 - \omega^{DB}) \\ \omega^{DB}, & \text{otherwise} \end{cases} \quad (21)$$

这里 $1 - \omega^{BC}$ 和 $1 - \omega^{DB}$ 表示对背景图取反后作为显著图进行计算.

4.4 前景-背景加权的对比度

文献[17]使用背景概率加权计算超像素的局部对比度:

$$wCtr(p_i) = \sum_{j=1}^N d_c(p_i, p_j) \omega_s(p_i, p_j) \omega_j^B \quad (22)$$

其中 $\omega_s(p_i, p_j) = \exp(-\frac{\|x_i - x_j\|_2^2}{2\sigma_s^2})$ 为超像素空间加权距离,同文献[17,27]取 $\sigma_s = 0.25$. ω_j^B 为超像素 p_j 的背景概率.

如图 4(e) 所示,该局部对比度的定义存在两个问题:一是对于大目标的内部区域由于其周围超像素的背景概率基本为 0,导致累积对比度之和会相对较低,会产生内部空洞;二是对于目标周围的背景区域抑制不够,会保留甚至产生更大的噪声.因此,在式(22)基础上加入前景概率,构造前景-背景双重加权的对比度:

$$wCtr'(p_i) = (1 - \omega_i^B) \sum_{j=1}^N d_c(p_i, p_j) \omega_s(p_i, p_j) \omega_j^B \quad (23)$$

图 4(f) 给出了改进后的效果,可以明显看出,加入前景-背景加权后的对比度可以较好地抑制背景区域,同时加强了前景区域的显著性.5.1 节对这样的改进进行了详细的量化比较.

4.5 显著度优化

显著性目标的检测可以简化为一个前、背景分割问题.前面基于加权对比度计算的显著图或多或少都存在噪声多、平滑性差的问题.参照 RBD 算法,这里提出一种加权的显著度优化模型:

$$\min_{\{s_i\}_{i=1}^N} \omega_i^F (s_i - 1)^2 + \lambda_1 \sum_{i=1}^N \omega_i^B s_i^2 + \lambda_2 \sum_{i,j} w_{ij} (s_i - s_j)^2 \quad (24)$$

其中 $\omega_i^B, \omega_i^F, w_{ij}$ 分别为背景概率、按式(23)求得的初始显著度和式(14)定义的超像素之间相似度, s_i 表示待定的超像素显著度.相较于 RBD 算法,这里加入了两个权值 λ_1 和 λ_2 来控制各项的权重,其中 λ_1 越大表示更加依赖于背景概率, λ_2 越大表示更加区分相似区域的显著度.本文实验中取 $\lambda_1 = 5, \lambda_2 = 1$.采用该模型对初始显著图进行优化后的结果如图 4(g) 所示,可见经过优化后的显著图背景区域得到进一步抑制,目标区域更加高亮和平滑.

5 实验结果

本文在 5 个数据集上测试各算法: ASD^[11]、MSRA^[26]、SED2^[29]、SOD^[30]、ECSDD^[31]. ASD 包含 1000 张图片,使用最为广泛,相对简单;MSRA 包含 5000 张图片,有很多复杂的背景和位于边界的目标;SED2 包含 100 张图片,每张图都有两个目标;SOD 包含 300 张图片,包含多个目标,具有一定挑战性;ECSDD 包含 1000 张图片,其中有很多边沿目标以及大目标,挑战难度较大.这里主要和文献[8]列出的近几年来比较有代表性的 14 种算法比较:SR^[10]、FT^[11]、HC^[12]、RC^[32]、SF^[27]、GS^[13]、PCA^[33]、GC^[34]、MR^[15]、DSR^[16]、HS^[31]、MC^[35]、RBD^[17]、HDCT^[36].

这里分别采用文献[8]所列的 P-R(精度-召回率)曲线、F-measure 值、AUC(Area Under ROC Curve score, ROC 曲线面积)值和 MAE(Mean Absolute Error, 平均绝对差)值进行评估. P-R 曲线通过[0,255]的滑动阈值对每个显著图进行二值化,和真值进行比对求得相应的精度(Precision)和召回率(Recall),然后在整个图库上进行平均. F-measure 一般采用一个自适应的阈值(如平均显著值的 2 倍)对图像进行二值化,然后分别求得精度和召回率:

$$F\text{-measure} = \frac{(1 + \beta^2) \cdot \text{precision} \cdot \text{recall}}{\beta^2 \cdot \text{precision} + \text{recall}} \quad (25)$$

这里一般取 $\beta^2 = 0.3$ 以强调精度. AUC 即 ROC 曲线与坐标轴所夹面积,一般为[0.5,1],0.5 相当于随机猜测,1 表示效果最好. MAE 被定义为显著图 S 和真值 G 的绝对误差的平均值:

$$MAE = \frac{1}{W \times H} \sum_{i=1}^W \sum_{j=1}^H |S(i,j) - G(i,j)| \quad (26)$$

前 3 种评价指标重在强调显著性目标的标注和高亮,而没有考虑被正确分类的负样本点^[8](主要是一些非显著区域),MAE 指标则对这些区域比较敏感.

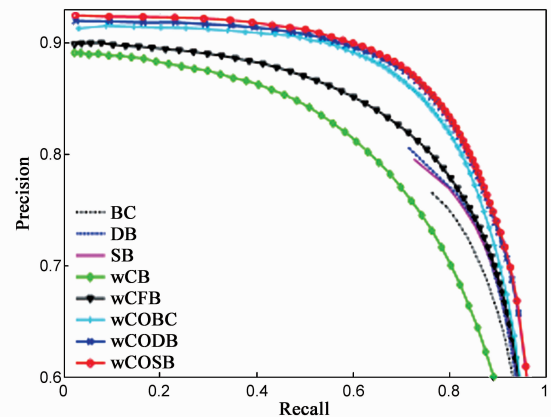
5.1 wCOSB 的性能分析

wCOSB 算法涉及到多个步骤,图 5 给出了在 MSRA 数据集上每步对算法性能影响的定量分析.从 P-R 曲线上可以明显看出,DB 方法要优于 BC 方法,其 MAE 值也较 BC 方法低.选择的结果 SB 比 DB 方法精度稍低,


但其查全率相对较高,选择后的 MAE 值比单独使用 BC 方法和 DB 方法分别降低了 9.3% 和 5.3%。另外,基于前景-背景加权的对比度(wCFB)因其更加抑制了背景区域,精度和召回率远远高于只使用背景加权的对比度(wCB),MAE 值也降低了 36.4%。因为 DB 背景概率的精确性,所以基于 DB 加权对比度优化(wCODB)无论是在精度、召回率还是 MAE 值上要优于基于 BC 加权对比度优化(wCOBC),证明了本文所提的可区分边界背景检测方法的有效性。经过背景选择后的结果(wCOSB)P-R 曲线高于单独使用 BC 或 DB 方法,MAE 值总体降低了 8.5% 和 4.4%。

5.2 算法的性能比较

图 6 给出了本文算法和其他算法的 P-R 曲线和 F-measure 直方图,表 1 给出了所有算法的 AUC 值和 MAE 值。在 ASD 和 MSRA 数据集上,性能较好的有 MR、MC、DSR、RBD,本文算法相对 MR 和 MC 精度稍低,但召回率较高,整体 F-measure 值与之相当,AUC 值相对最好的 DSR 要高,MAE 值比最低的 RBD 算法要低。SED2 和 SOD 数据集含有多个目标,HS、MR、MC、DSR 算法在精度上较高,但召回率非常低,说明其在目标的整体性检测方面明显不足,本文算法在精度和召回率上都有不错的效果,所以整体 F-measure 值和 AUC 值最高,在 SOD 数据集上 MAE 值比 DSR 稍高。ECSSD 数据集背景比较复杂,HS、MR、MC、DSR 和 RBD 算法都存在召回率低的问题,RC 算法和本文算法比较接近,同样本文算法的 AUC 值最高,MAE 值最低。综上,本文算法无论在单目标、多目标还是复杂背景环境下都有较高的精度和召回率,在各数据集上 AUC 值最高,MAE 值基本最低,充分表明本文算法的鲁棒性和有效性。



(a) P-R 曲线



(b) MAE 直方图

图5 本文算法在MSRA数据集上的量化分析(SB: 选择背景图; wCB: 只背景加权的对比度; wCFB: 前景-背景加权的对比度; wCOBC: 基于BC背景加权对比度优化的显著图; wCODB: 基于DB背景加权对比度优化的显著图; wCOSB: 选择背景加权对比度优化的显著图)

表 1 不同算法 AUC 和 MAE 比较(最好的两种算法分别用黑体和斜体标注)

AUC	ASD	MSRA	SED2	SOD	ECSSD	MAE	ASD	MSRA	SED2	SOD	ECSSD
SR	0.7174	0.7050	0.7694	0.6718	0.6077	SR	0.2149	0.2251	0.2196	0.2914	0.3079
FT	0.8627	0.7665	0.8291	0.6006	0.6443	FT	0.2068	0.2410	0.2041	0.3226	0.3275
HC	0.9243	0.8399	0.8843	0.6594	0.6814	HC	0.1757	0.2398	0.1962	0.3497	0.3561
SF	0.9480	0.8853	0.8807	0.7922	0.7551	SF	0.1299	0.1660	0.2094	0.3149	0.2679
GS	0.9746	0.9394	0.8952	0.8270	0.8253	GS	0.1077	0.1445	0.1531	0.2498	0.2549
RC	0.9728	0.9339	0.8594	0.8210	0.8323	RC	0.1060	0.1400	0.1267	0.2417	0.2351
GC	0.9484	0.8926	0.8636	0.7178	0.7655	GC	0.1024	0.1456	0.1841	0.2720	0.2556
PCA	0.9706	0.9369	0.9157	0.8216	0.8166	PCA	0.1565	0.1889	0.2015	0.2740	0.2909
HS	0.9670	0.9296	0.8499	0.8108	0.8293	HS	0.1113	0.1620	0.1871	0.2829	0.2686
MR	0.9737	0.9389	0.8373	0.8099	0.8342	MR	0.0756	0.1290	0.1715	0.2571	0.2371
MC	0.9764	0.9493	0.8874	0.8382	0.8495	MC	0.0938	0.1458	0.1837	0.2604	0.2513
DSR	<i>0.9803</i>	<i>0.9550</i>	<i>0.9203</i>	<i>0.8420</i>	0.8558	DSR	0.0809	0.1192	0.1398	0.2339	0.2263
HDCT	0.9722	0.9438	0.8971	0.7915	0.8135	HDCT	0.1188	0.1418	0.1622	0.2427	0.2493
RBD	0.9789	0.9481	0.9015	0.8362	0.8398	RBD	<i>0.0669</i>	<i>0.1156</i>	0.1727	0.2701	<i>0.2252</i>
wCOSB	0.9868	0.9632	0.9331	0.8477	0.8561	wCOSB	0.0643	0.1093	0.1233	0.2359	0.2208

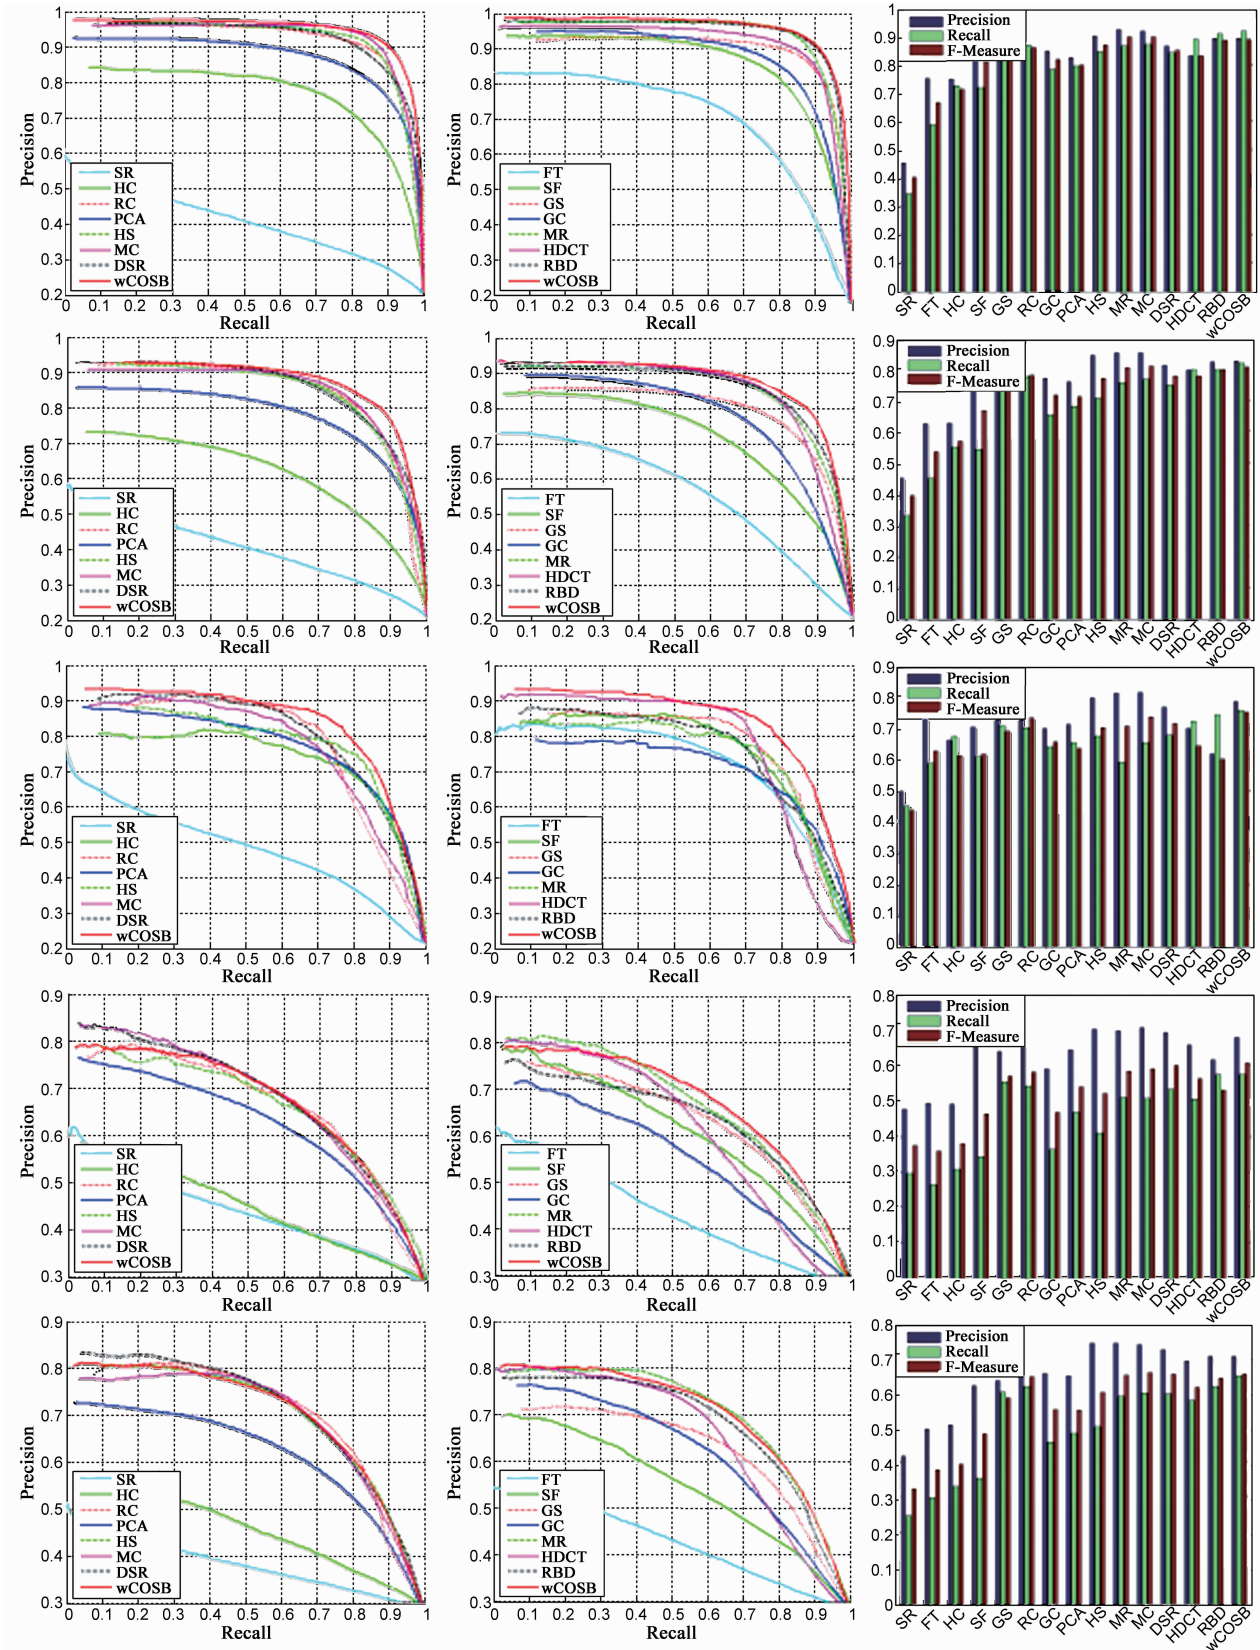


图6 5个数据集上15种算法定量比较(从左至右各列依次是:P-R曲线图1,P-R曲线图2以及自适应阈值计算的精度、召回率和F-Measure值;从上到下各行依次是:ASD、MSRA、SED2、SOD和ECSSD数据集)

图 7 给出了几种典型算法和本文算法检测的效果示例. 示例中, 多数显著性目标都位于图像的边界, 大多数算法的检测效果都相对较差, 而本文算法能完全

高亮整个目标区域. 另外图 7 中后两幅图都存在两个目标, 多数算法检测不够完整, 而本文算法能较准确检测所有目标.




图7 各算法显著图检测效果示例

本文算法只是提取颜色作为特征, 同时为了提高速度取区域内的平均颜色值进行计算, 对目标和背景颜色相近的情况就难以区分. 图 8 给出了本文算法检测失败的示例, 可见当背景和前景极为接近时, 算法容易失效. 如果加入其它的特征如纹理、颜色直方图等应该可以改善这种情况.

5.3 运行时间分析

表 2 给出了本文算法和几种较好算法检测单张图片的平均运算时间比较. 测试环境为 Intel Pentium G630 2.70GHZ, RAM 2GB. 测试数据集为 ASD, 测试图片大小一般为 300×400 . 所有运行的代码都是网上可公开下载的, 主要包括 C 语言和 Matlab 两种实现方式. 可以看

表 2 不同算法平均运算时间比较 (C: C/C++, M: Matlab)

算法	HC	SF	GS	PCA	RC	MC	HS	GC	MR	DSR	HDCT	RBD	wCOSB
时间(s)	0.018	0.19	0.23	4.42	0.12	0.16	0.50	0.05	0.22	9.95	4.54	0.26	0.29
代码	C	C	M	M	C	M+C	C	C	M	M+C	M	M	M

6 结论

本文首先针对目前缺乏显著图客观质量评价指标的问题, 提出了一种基于紧致性的 MSR 指标. 该指标虽然在本文的 wCOSB 算法中用于高质量背景图的筛选, 但是还可用于显著图的融合算法, 或者显著图的优化控制等方面. 针对一般以边界为背景的算法将边界同等处理的问题, 本文提出了一个可区分边界的背景检测方法, 较好地解决了目标区域位于边界的情况. 通过构造前景-背景加权的对比度来计算初始显著图, 相较于单纯的背景加权对比度能更好地抑制背景区域, 使得 wCOSB 能更好地保持目标区域的完整性. 而加权的




图8 本文算法检测失败的示例: (a) 原图; (b) 真值; (c) DB背景图; (d) 加权对比度; (e) 优化后显著图

出, 本文算法的运算时间在 RBD 基础上增加不多, 但性能改进很大. 在 MATLAB 平台下的所有算法中, 本文算法和 GS、MR 和 RBD 时间差不多, 比 PCA、DSR、HDCT 等要快很多, 基本可以满足实时性要求.

RBD 优化模型使最终的显著图更加精确和平滑. 5 个数据集上的测试结果表明, 本文的背景检测算法更加鲁棒, wCOSB 的整体性能优于目前大部分算法. 但 wCOSB 对一些目标和边界背景颜色相近的情况效果不佳, 难以有效区分出背景区域. 下一步, 我们将添加更多的特征来解决颜色特征无法区分的问题, 同时利用提出的 MSR 指标进行多种显著图的融合, 以利用多种方法的优势获取更好的检测结果.

参考文献

- [1] Itti L, Koch C, Niebur E. A model of saliency based visual attention for rapid scene analysis[J]. IEEE Transactions on

- Pattern Analysis and Machine Intelligence, 1998, 20(11): 1254 – 1259.
- [2] Rother C, Kolmogorov V, Blake A. Grabcut: Interactive foreground extraction using iterated graph cuts[J]. ACM Transactions on Graphics, 2004, 23(1): 309 – 314.
- [3] Ding Y, Xiao J, Yu J. Importance filtering for image retargeting[A]. IEEE Conference on Computer Vision and Pattern Recognition (CVPR) [C]. Colorado Springs, USA: IEEE, 2011. 89 – 96.
- [4] Mahadevan V, Vasconcelos N. Saliency-based discriminant tracking[A]. IEEE Conference on Computer Vision and Pattern Recognition (CVPR) [C]. Miami, USA: IEEE, 2009. 1007 – 1013.
- [5] Sharma G, Jurie F, Schmid C. Discriminative spatial saliency for image classification[A]. IEEE Conference on Computer Vision and Pattern Recognition (CVPR) [C]. Rhode Island, USA: IEEE, 2012. 3506 – 3513.
- [6] Hadizadeh H, Baji'c I. Saliency-aware video compression [J]. IEEE Transactions on Image Processing, 2014, 23(1): 19 – 33.
- [7] Borji A, Cheng M, Jiang H, et al. Salient object detection: a survey[J]. arXiv:1411.5878v1[cs.CV]. 2014.
- [8] Borji A, Cheng M, Jiang H, et al. Salient object detection: a benchmark[J]. arXiv:1501.02741v1[cs.CV]. 2015.
- [9] Harel J, Koch C, Perona P. Graph-based visual saliency [A]. Neural Information Processing Systems [C]. NIPS, 2006. 545 – 552.
- [10] Hou X, Zhang L. Saliency detection: a spectral residual approach[A]. IEEE Conference on Computer Vision and Pattern Recognition (CVPR) [C]. Minneapolis, USA: IEEE, 2007. 801 – 808.
- [11] Achanta R, Hemami S, Estrada F, et al. Frequency-tuned salient region detection[A]. IEEE Conference on Computer Vision and Pattern Recognition (CVPR) [C]. Miami, USA: IEEE, 2009. 1597 – 1604.
- [12] Cheng M, Zhang G, Mitra N, et al. Global contrast based salient region detection[A]. IEEE Conference on Computer Vision and Pattern Recognition (CVPR) [C]. Colorado Springs, USA: IEEE, 2011. 409-416.
- [13] Wei Y, Wen F, Zhu W, et al. Geodesic saliency using background priors [A]. 12th European Conference on Computer Vision (ECCV) [C]. Florence, Italy: Springer, 2012. 29 – 42.
- [14] Jiang H, Wang J, Yuan Z, et al. Salient object detection: A discriminative regional feature integration approach[A]. IEEE Conference on Computer Vision and Pattern Recognition (CVPR) [C]. Portland, USA: IEEE, 2013. 2083 – 2090.
- [15] Yang C, Zhang L, Lu H, et al. Saliency detection via graph-based manifold ranking[A]. IEEE Conference on Computer Vision and Pattern Recognition (CVPR) [C]. Portland, USA: IEEE, 2013. 3166 – 3173.
- [16] Li X, Lu H, Zhang L, et al. Saliency detection via dense and sparse reconstruction[A]. IEEE Conference on Computer Vision (ICCV) [C]. Sydney, Australia: IEEE, 2013. 2976 – 2983.
- [17] Zhu W, Liang S, Wei Y, et al. Saliency optimization from robust background detection [A]. IEEE Conference on Computer Vision and Pattern Recognition (CVPR) [C]. Columbus, USA: IEEE, 2014. 2814 – 2821.
- [18] Lu S, Mahadevan V, Vasconcelos N. Learning optimal seeds for diffusion-based salient object detection [A]. IEEE Conference on Computer Vision and Pattern Recognition (CVPR) [C]. Columbus, USA: IEEE, 2014. 2790 – 2797.
- [19] Liu R, Cao J, Lin Z, et al. Adaptive partial differential equation learning for visual saliency detection[A]. IEEE Conference on Computer Vision and Pattern Recognition (CVPR) [C]. Columbus, USA: IEEE, 2014. 3866 – 3873.
- [20] Li J, Tian Y, Duan L, et al. Estimating visual saliency through single image optimization[J]. IEEE Signal Processing Letters, 2013, 20(9): 845 – 848.
- [21] Mai L, Liu F. Comparing salient object detection results without ground truth [A]. 13th European Conference on Computer Vision (ECCV) [C]. Zurich, Switzerland: Springer, 2014. 76 – 91.
- [22] Krahenbuhl P, Koltun V. Geodesic object proposals[A]. 13th European Conference on Computer Vision (ECCV) [C]. Zurich, Switzerland: Springer, 2014. 725 – 739.
- [23] Dubuisson M, Jain A. A modified Hausdorff distance for object matching[A]. International Conference on Pattern Recognition (ICPR) [C]. Jerusalem, Israel: IEEE, 1994. 566 – 568.
- [24] Sim D, Kwon O, Park R. Object matching algorithms using Hausdorff distance measures[J]. IEEE Transactions on Image Processing, 1999, 8(3): 425 – 429.
- [25] Andreev A, Kirov N. Word image matching based on Hausdorff distances [A]. 10th International Conference on Document Analysis and Recognition [C]. Barcelona, Spain: IEEE, 2009. 396 – 400.
- [26] Liu T, Sun J, Zheng N, et al. Learning to detect a salient object[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2011, 33(2): 353 – 367.
- [27] Perazzi F, Krahenbuhl P, Pritch Y, et al. Saliency filters: Contrast based filtering for salient region detection[A]. IEEE Conference on Computer Vision and Pattern Recognition (CVPR) [C]. Rhode Island, USA: IEEE, 2012. 733 – 740.

- [28] 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 – 2281.
- [29] Alpert S, Galun M, Brandt A, et al. Image segmentation by probabilistic bottom-up aggregation and cue integration [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2012, 34(2): 315 – 327.
- [30] Movahedi V, Elder J. Design and perceptual validation of performance measures for salient object segmentation [A]. IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops (CVPRW) [C]. San Francisco, USA; IEEE, 2010. 49 – 56.
- [31] Yan Q, Xu L, Shi J, et al. Hierarchical saliency detection [A]. IEEE Conference on Computer Vision and Pattern Recognition (CVPR) [C]. Portland, USA; IEEE, 2013. 1155 – 1162.
- [32] Cheng M, Mitra N, Huang X, et al. Global contrast based salient region detection [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37 (3): 569 – 582.
- [33] Margolin R, Tal A, Zelnik-Manor L. What makes a patch distinct? [A]. IEEE Conference on Computer Vision and Pattern Recognition (CVPR) [C]. Portland, USA; IEEE, 2013. 1139 – 1146.
- [34] Cheng M, Warrell J, Lin W, et al. Efficient salient region detection with soft image abstraction [A]. IEEE Conference on Computer Vision (ICCV) [C]. Sydney, Australia; IEEE, 2013. 1529 – 1536.
- [35] Jiang B, Zhang L, Lu H, et al. Saliency detection via absorbing Markov chain [A]. IEEE Conference on Computer Vision (ICCV) [C]. Sydney, Australia; IEEE, 2013. 1665 – 1672.
- [36] Kim J, Han D, Tai Y, et al. Salient region detection via high-dimensional color transform [A]. IEEE Conference on Computer Vision and Pattern Recognition (CVPR) [C]. Columbus, USA; IEEE, 2014. 863 – 890.

作者简介



姜青竹 男, 1987 年生, 湖北襄阳人. 2009 年毕业于解放军理工大学通信工程学院, 获学士学位. 现为解放军理工大学硕士研究生, 研究方向为视觉显著性和视频编码.

E-mail: jqbamboo@126.com



田畅 男, 1963 年生, 山东青岛人. 2001 年毕业于解放军理工大学通信工程学院, 获博士学位. 现为解放军理工大学通信工程学院教授, 研究方向为数据链技术、视频编码与传输优化.

E-mail: tianchang163@163.com



吴泽民 (通讯作者) 男, 1973 年生, 四川成都人. 2002 年毕业于解放军理工大学通信工程学院, 获博士学位. 现为解放军理工大学通信工程学院副教授, 研究方向为数据链技术、雷达数据融合、图像视频分析.

E-mail: wuzemin_ice@163.com