

贝叶斯融合多核学习的图像显著性检测

陈雪敏*, 唐红梅, 韩力英, 高振斌

河北工业大学电子信息工程学院, 天津 300401

摘要 针对当前图像显著性检测算法存在的检测不准确和边缘不清晰问题, 提出基于改进的贝叶斯公式融合算法。采用 compactness 先验得到初级显著图, 并以初级显著图作为训练样本, 采用多核学习方式得到次级显著图, 而后基于贝叶斯公式以一定的比例融合初级和次级显著图, 最终获得精确的显著性检测图。实验结果表明, 算法在 2 个公开数据集上进行检测时, 所得结果能够有效地突出目标物体, 去除边缘模糊的现象, 且实验结果在 3 个数据指标(精确度、召回率和 F -measure 值)方面均优于其他 8 种算法, 算法运行速度较快, 实验结果也更为精确。

关键词 图像处理; 贝叶斯公式融合; 显著性检测; compactness 先验; 初级显著图; 多核学习; 次级显著图

中图分类号 TP391

文献标识码 A

doi: 10.3788/LOP56.161010

Image Saliency Detection of Bayesian Integration Multi-Kernel Learning

Chen Xuemin*, Tang Hongmei, Han Liying, Gao Zhenbin

School of Electronics and Information Engineering, Hebei University of Technology, Tianjin 300401, China

Abstract An improved fusion algorithm based on Bayesian formula is proposed for addressing inaccurate detection and unclear edge problems in existing image saliency detection algorithms. First, compactness prior is used for obtaining the primary saliency map. Then, the secondary saliency map is obtained via multi-kernel learning using primary saliency maps as training samples. Finally, a Bayesian formula is used to integrate the primary saliency map with the secondary saliency map at a certain proportion to obtain an accurate saliency map. Experimental results obtained on two public datasets demonstrate that the proposed algorithm can effectively highlight the target object and remove blurred edges. The proposed algorithm is superior to eight existing algorithms from the viewpoint of accuracy, recall rate, and F -measure value. Furthermore, the running speed of the proposed algorithm is faster, and it demonstrates more accurate experimental results.

Key words image processing; Bayesian formula integration; saliency detection; compactness prior; primary saliency map; multi-kernel learning; secondary saliency map

OCIS codes 100.4993; 100.4994; 100.5010

1 引言

近年来, 图像显著性检测算法的研究越来越得到人们的关注, 在场景中找到信息最丰富的区域, 成为解决信息问题的有效方式。显著性检测被应用于诸多领域, 如目标识别^[1]、视觉跟踪^[2]、图像压缩^[3]等。一般地, 显著性检测算法通过自底向上^[4]或者自顶向下^[5]的算法进行分类。自底向上的算法利用的是低层次的图像信息, 如对比颜色、纹理和边界的特征。Harel 等^[6]构造马尔可夫链, 快速提取图像

显著性区域的 GBVS (Graph-Based Visual Saliency) 算法, 应用心理学特征, 但计算复杂, 显著图分辨率很低; Margolin 等^[7]用主成分分析的方法 (PCA) 计算图像数据, 利用内部结构计算得到最后的显著性图, 但计算复杂, 检测效果不理想; Yang 等^[8]对传统的中心先验进行改良, 提出粗略估计显著目标位置的 HC (Histogram Contrast) 算法, 该算法存在边界模糊问题; Tong 等^[9]提出了基于多尺度超像素的 SD-MS (Saliency Detection with Multi-Scale Superpixels) 显著性检测算法, 并在 2015 年

收稿日期: 2019-01-21; 修回日期: 2019-03-19; 录用日期: 2019-03-27

基金项目: 天津市科技计划 (16JCTPJC50600)

* E-mail: wxmchen@163.com

通过增强学习^[10] (BL) 获得准确性更高的显著结果, 但运行时间较长, 实验结果也受到影响。而自顶向下的算法分析任务驱动的视觉时, 需要大量的训练样本对其进行监督学习。如 Cheng 等^[11] 提取三通道颜色特征差异计算显著性值, 由于只通过颜色特征来分析, 故只能粗略检测出显著图, 该算法称为 Global Contrast Based Salient Region Detection, 简称 GR 算法, 对背景抑制能力较弱; Jiang 等^[12] 考虑突出的外观和空间分布, 利用马尔可夫链吸收节点 AMC (Absorb Markov Chain) 的时间来计算显著性值, 计算复杂, 运算效率较低, 并且实验效果并不理想; Li 等^[13] 采用稀疏稠密传播重建误差, 并对高斯算法进行改进以获取显著值, 该算法称为 Dense and Sparse Reconstruction, 简称 DSR 算法, 算法效率低。

针对图像显著性检测算法存在的检测不准确和边缘不清晰问题, 利用贝叶斯公式算法将通过

compactness 先验得到的初级显著性图和通过多核学习得到的次级显著性图融合, 同时运用多尺度分割, 得到最终的显著性图。本文结合两种检测算法的优势, 提取空间特征, 训练学习样本, 同时运用贝叶斯公式融合, 可以大幅提高检测结果的精确性。

2 算法整体框架

底层特征的传统显著性检测方式常通过提取场景的低级特征来突出目标, 故对于复杂背景的抑制与目标内部纹理的均匀性检测效果欠佳, 检测结果边缘模糊, 目标边界附近像素归类容易产生误差。为解决以上问题, 提出了一种基于多核学习与贝叶斯公式融合的显著性检测算法。基于多核学习方式能有效突出显著性目标, 基于 compactness 先验对比能够紧密地区分显著目标的位置, 将两种显著图以贝叶斯公式融合, 优势互补。整体框架如图 1 所示。

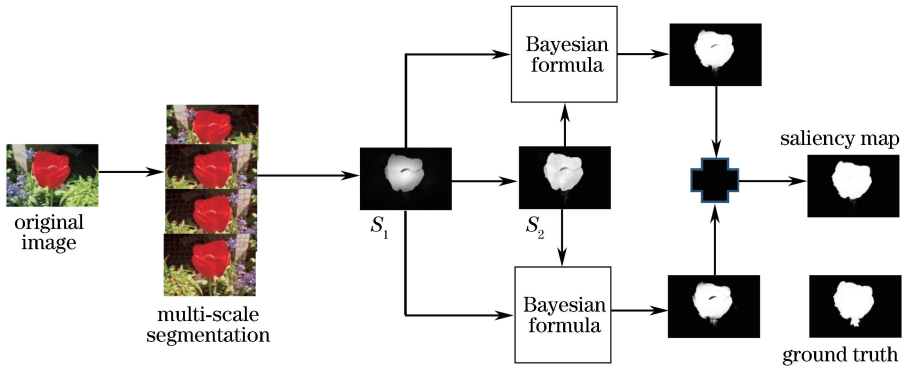


图 1 显著性检测整体框图

Fig. 1 Framework of saliency detection

3 初级和次级显著图

3.1 初级显著图

在基于底层线索的全局或局部的显著性检测算法中, 无论是背景还是目标的颜色纹理等细微变化, 都可以在显著性结果中呈现出来, 因此引入误差的概率较大。图像的显著性检测目标一般都对对应真实存在的物体, 他们通过互相连接的区域组合起来, 所以, 相比于背景区域, 显著性目标具有更加紧凑的空间分布特性, 因此引入了 compactness 先验^[14] 的算法从空间紧凑度的角度来提高算法的性能。

从场景角度分析, 图像的前景目标物体通常被背景区域紧紧包围, 这就意味着空间域的颜色分布在背景区域较为分散, 故任一超像素的颜色空间差

异越大就越可能是背景区域。首先将输入图像分割成 n 个超像素, 其中任意超像素 v_i 的空间差异性 $s(i)$ 的计算公式为

$$s(i) = \frac{\sum_{j=1}^N a_{ij} n_j \| \mathbf{b}_j - \mathbf{u}_i \|}{\sum_{j=1}^N a_{ij} n_j}, \quad (1)$$

式中: $\mathbf{b}_j = [b_j^x \ b_j^y]$ 为超像素 v_j 的所有超像素的归一化水平方向位置均值和归一化垂直方向位置均值组成的向量; n_j 为超像素 v_j 所包含的像素个数; $a_{ij} = \exp(l_{ij}/\omega^2)$ 为超像素间相似性, $l_{ij} = \| c_i - c_j \|$ 为超像素节点在 CIELab 颜色空间的欧氏距离, c_i 为在颜色节点中对应的超像素 n_i 均值, ω 为权重调控参数; i 和 j 为像素节点; N 为图像分割的超像素数量; 空间位置均值表达式为 $\mathbf{u}_i = [u_i^x \ u_i^y]$, 坐标

公式为

$$\mathbf{u}_i^x = \frac{\sum_{j=1}^N a_{ij} \mathbf{n}_j \mathbf{b}_j^x}{\sum_{j=1}^N a_{ij} \mathbf{n}_j}, \quad (2)$$

$$\mathbf{u}_i^y = \frac{\sum_{j=1}^N a_{ij} \mathbf{n}_j \mathbf{b}_j^y}{\sum_{j=1}^N a_{ij} \mathbf{n}_j}. \quad (3)$$

根据摄影学原理,物体大多被安排在图像靠近中央的位置,这使得图像更加美观,同时也更容易在看到图像的同时能够捕捉到图像的焦点,即显著目标。故任一超像素到图像中心的空间距离 $\rho(i)$ 可表示为

$$\rho(i) = \frac{\sum_{j=1}^N h_{ij} n_j \|\mathbf{b}_j - \mathbf{p}\|}{\sum_{j=1}^N h_{ij} n_j}, \quad (4)$$

式中: $\mathbf{p} = [p_x \ p_y]$ 为图像中心坐标; $h_{ij} = a_{ij} \times \exp\left(-\frac{\|\mathbf{b}_i - \mathbf{b}_j\|}{\lambda^2}\right)$ 为空间距离的相似性值, λ 为常量。通过 compactness 先验得到的初级显著性值为

$$M_{an}(i) = 1 - \text{Norm}[s(i) + \rho(i)], \quad (5)$$

式中: $\text{Norm}(\cdot)$ 为归一化函数,表示将函数参数归一化。

3.2 次级显著图

次级显著性检测算法采用多核学习^[10]的方法,多核学习是结合多个支持向量机(SVM)分类器的方式,每个 SVM 可以提取不同的信息特征,由于具有各个核提取不同特征的特点,可解决特征选择和协调特征的缺陷问题。对图像进行训练,将训练与测试放在同一张图像中,给定样本集合 $\{u_\sigma, \theta_\sigma\}$, $\sigma \in (1, T)$, u_σ 代表第 σ 个样本, θ_σ 代表样本标签, T 为样本个数,则将多个特征集合得到的目标函数表示为

$$Z(u) = \sum_{m=1}^M \beta_m [\boldsymbol{\alpha}^T \mathbf{k}_m(u) + g_m], \quad (6)$$

式中: m 代表第 m 个单核单特征的 SVM; M 为核函数和特征量乘积; $\boldsymbol{\alpha} = [\alpha_1 \theta_1 \ \alpha_2 \theta_2 \ \dots \ \alpha_T \theta_T]^T$, α_σ 为拉格朗日乘子; $\mathbf{k}_m(u) = [k_m(u, u_1), k_m(u, u_2), \dots, k_m(u, u_T)]^T$, k_m 为核函数的值,将提取样本的背景部分记作 -1,前景部分记作 1; g_m 是标准 SVM 偏置常数; β_m 为线性组合系数, $\sum_{\sigma=1}^M \beta_\sigma = 1$ 。假设其目标函数为 $z_m(u)$,则上述公式可以简化为

$$z_m(u) = \boldsymbol{\alpha}^T \mathbf{k}_m(u) + g_m, \quad (7)$$

$$z(u) = \sum_{n=1}^D \beta_n z_n(u), \quad (8)$$

式中: n 为增强迭代次数; $z_m(u)$ 为分类能力较弱的单个 SVM 分类器; $z(u)$ 为组合分类器,具有较好的分类性能,由 $z_n(u)$ 及对应的系数 β_n 进行加权组合构成。然后,将样本权重统一成 $w(u) = 1/T$, 目的是得到每个弱分类器的目标函数 $\{z_m(u)\}$, $m = 1, 2, \dots, M$, 最后,得到每一个弱分类器在第 l 次迭代的错误率,计算公式为

$$\epsilon_m = \frac{\sum_{u=1}^T w(u) |z_m(r_u)| \{\text{sgn}[-l_u z_m(r_u)]\} / 2}{\sum_{u=1}^T w(u) |z_m(r_u)|}, \quad (9)$$

式中: r_u 为第 u 个样本; l_u 为样本二值标签; $\text{sgn}(\cdot)$ 是符号函数。当 $\text{sgn}(\cdot)$ 函数值大于 0 时,赋值为 1,其他都为 -1,找到使得错误率最小时的分类器目标函数 $z_l(u)$,并计算出线性组合多个 SVM 的系数,其计算公式为

$$\beta_l = \frac{1}{2} \text{lb} \frac{1 - \epsilon_l}{\epsilon_l} \times \frac{1}{2} \left[\text{sgn} \left(\text{lb} \frac{1 - \epsilon_l}{\epsilon_l} \right) + 1 \right], \quad (10)$$

式中: ϵ_l 为 l 次迭代后的错误率; β_l 是线性组合多个 SVM 的系数,要求 $\beta_l > 0$,使得 $\epsilon_l < 0.5$,这是达到最终分类的重要前提。更新样本后的权重公式为

$$w_{l+1}(\sigma) = \frac{w_l(\sigma) \exp[-\beta_l l_\sigma z_l(r_\sigma)]}{2\sqrt{\epsilon_l(\epsilon_l - 1)}}. \quad (11)$$

(8)式得到的强分类器用于图像样本,经过 l 次迭代得到 l 组 β_l 和 $z_l(u)$,计算得到分类效果较好的分类器 $z(u)$,得到的分类器直接用于图像的检测。根据分类器最后的输出结果,构建出像素级别的显著图,成功分离前景与背景区域,得到次级显著图 M_f 。

3.3 构建多尺度显著图

由于所使用的数据集内容丰富,且图像内目标物体的大小不一样,任意图片的显著物体目标的尺度不同,超像素分割在单一尺度下也未必准确,分割情况会影响显著性检测的效果,因此需采用多尺度^[12]解决分割问题。设立不同的超像素个数, $N = 100, 150, 200, 250$,均采用简单线性超像素分割方法,在不同的尺度上均计算初级显著值 $M_{a,l}$,其中下角标 l 代表尺度, $\{M_{a,l}\}$ 为 4 个尺度下得到的初

级显著图,对4个尺度的初级显著值进行加权计算获得初级显著图 S_1 ,其表达式为

$$S_1 = \frac{1}{4} \sum_{i=1}^4 M_{a,i} \quad (12)$$

同理, $M_{f,i}$ 为次级显著值, $\{M_{f,i}\}$ 为4个尺度下得到的次级显著图,计算出4个次级显著图的均值,得到次级显著值 S_2 ,其表达式为

$$S_2 = \frac{1}{4} \sum_{i=1}^4 M_{f,i} \quad (13)$$

4 贝叶斯公式融合

贝叶斯公式用条件概率表达各个信息要素之间的相关关系,它能够有效地进行多元信息的表达和融合,在某些情况下,类似于自顶向下的机制,通过寻找先验概率、似然概率和后验概率三者之间的相互关系求得结果,以提高显著性检测的精确性。基于此特点,提出了一种用贝叶斯公式^[13]得到的后验概率图,并使用一定的比例将后验概率图进行融合的算法,使得最终结果可以更好地突显出目标。

$$P(F_o | S_d(a)) = \frac{S_o(a)P(S_d(a) | F_o)}{S_o(a)P(S_d(a) | F_o) + (1 - S_o(a))P(S_d(a) | B_o)} \quad (16)$$

同样地,以 S_d 作为先验的显著性计算,得到后验概率显著图,基于贝叶斯公式的融合表达式为

$$B_F(S_1(a), S_2(a)) = \tau P(F_1 | S_2(a)) + (1 - \tau)P(F_2 | S_1(a)), \quad (17)$$

式中: τ 为权重; F_i 为对显著图 S_i 进行二值分割得到的前景区域。

贝叶斯公式融合是将这两种显著图的不同信息充分利用,有效地突出图像中的目标,因为次级显著图受到初级显著图的影响,最终融合时初级显著图作为先验概率得到的后验概率所占比例高一些,经过多次实验证实, $\tau = 0.6$ 时得到的实验检测效果最好。

5 实验结果及分析

本文中所有实验结果均是在同一个环境下运行得出,使用 Matlab R2014b 进行实验分析,运行环境基于 Windows8.1 操作系统平台,内存 4.00 GB,处理器为 Intel Core i5 CPU,主频参数为 1.60。实验使用的两个数据集(MSRA-10K^[14]和 ECSSD^[15])为公开数据集,数据集从互联网的共享信息中获得。

本文采用将显著图作为贝叶斯公式计算概率的方式,有效解决了因先验概率计算而引入的噪声问题。利用不同显著图的有效信息,分别作为贝叶斯公式中的先验概率和似然概率,得到后验概率显著图,首先 $S_o \{o=1,2\}$ 作为先验概率, $S_d \{d=1,2\}$ 即表示似然概率,要求系数 $o \neq d$,然后位置互换再次运算。利用平均显著值来确定 S_o ,并获得其前景 F_o 和背景 B_o ,归一化直方图中的值表示像素 a 在前景和背景中的 S_o 和 S_d 的似然概率,表达式分别为

$$P(S_d(a) | F_o) = \frac{N_{b_{F_o}[S_d(a)]}}{N_{F_o}}, \quad (14)$$

$$P(S_d(a) | B_o) = \frac{N_{b_{B_o}[S_d(a)]}}{N_{B_o}}, \quad (15)$$

式中: $N_{b_{F_o}[S_d(a)]}$ 表示统计得到的显著图 S_d 在前景区域的显著值分布特性; $N_{b_{B_o}[S_d(a)]}$ 表示统计得到的显著图在背景区域的显著值分布特性; N_{B_o} 为背景区域超像素数量; N_{F_o} 为前景区域超像素数量。利用贝叶斯公式得到的后验概率图为

为验证本文算法的有效性,对比分析本文算法与8种经典算法(GBVS^[6]、HC^[8]、PCA^[7]、DSR^[13]、AMC^[12]、GR^[11]、SD-MS^[9]、BL^[10])的实验结果。

5.1 实验分析

在 MRSA-10K^[14] 和 ECSSD^[15] 数据集上进行测试,并通过精确度召回率曲线(P - R 曲线)和 F 曲线直观地对比效果。ECSSD 中包含 1000 张结构复杂的图像,每张图像都有像素级的显著性标记,该数据集中的图像种类广泛,结构复杂。MRSA-10K 里含有 10000 张图像,每张图像都有真值标注,内含图像种类相当丰富,较为简单,适用于显著性检测算法数据对比验证。对比 MRSA-10K 数据集和 ECSSD 数据集,可以清楚地看到本文算法展示的结果,即使显著目标有两个时也具有很好的检测效果。对经过 compactness 先验的图像区域进行空间紧凑度的分析计算,再对处理过的初级显著图进行训练,可更准确地区分背景与前景物体,使得实验结果更为精确,实验效果对比图如图 2 所示。经对比可得出,不管是在多物体检测效果上还是颜色分辨不清晰的图像上,本文实验结果与二值图(GT)更为相近,检测效果更好(为方便描述,用 OUR 来表示本文算法)。

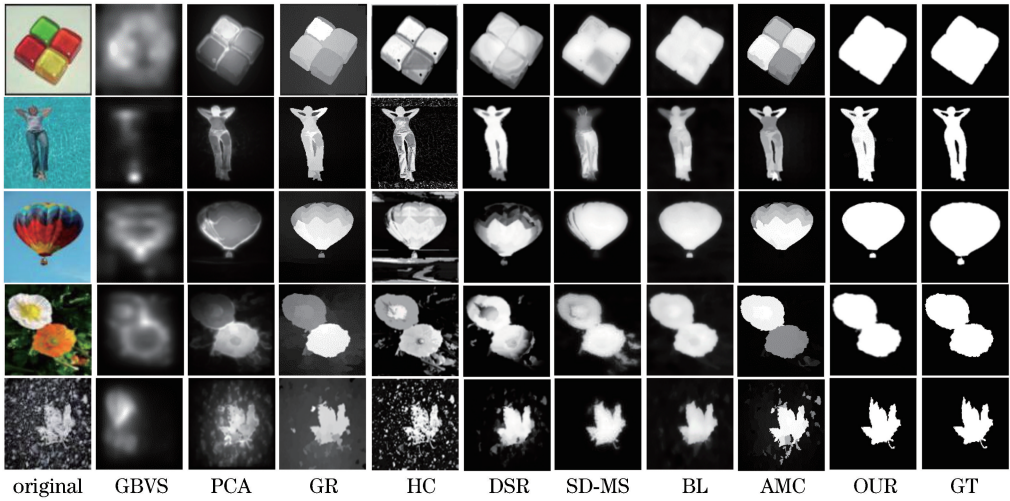


图2 ECSSD和MRS-10K数据集上显著性检测结果

Fig. 2 Saliency test results on ECSSD and MRS-10K datasets

5.2 评测指标

在大多数现有的算法中,采用精确率、召回率和 F -measure 作为比较性能的指标。本研究采用 P - R 曲线^[16],先在 $[0, 255]$ 之间取显著图的标准化阈值,在0到255之间分割图像,生成二进制掩码,并将二进制掩码和真值进行比较,得到 P - R 曲线^[16]。对于每个二进制映射,精确率(简称 P)、召回率(简称

R)和 F -measure(简写成 F)之间的关系为

$$F = \frac{(1 + \gamma^2)PR}{\gamma^2 P + R}, \quad (18)$$

式中: γ^2 根据经验取值为 0.3。根据 F 与 P 、 R 之间的关系, F 值越高,实验效果越好。9种算法在数据集上的 P - R 曲线和 F 曲线的对比如图 3~6 所示。





图3 MSRA-10K数据集上 P - R 曲线。(a)整体曲线;(b)局部曲线

Fig. 3 P - R curves on MSRA-10K dataset. (a) Whole curves; (b) partial curves





图4 MSRA-10K数据集上 F -measure 曲线。(a)整体曲线;(b)局部曲线

Fig. 4 F -measure curves on MSRA-10K dataset. (a) Whole curves; (b) partial curves

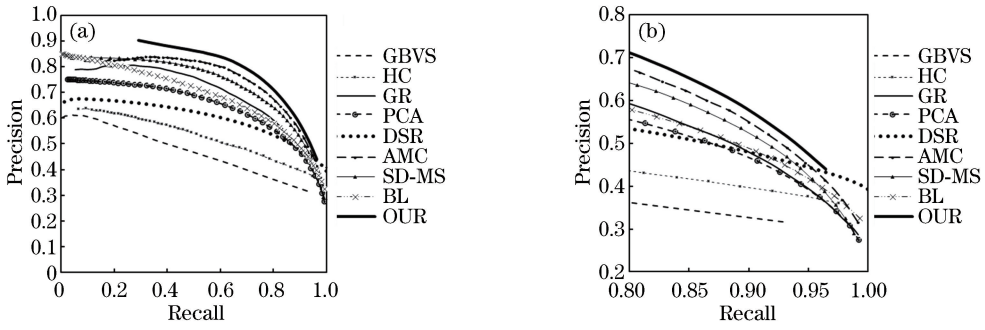


图 5 ECSSD 数据集上 P - R 曲线。(a)整体曲线;(b)局部曲线

Fig. 5 P - R curves on ECSSD dataset. (a) Whole curves; (b) partial curves

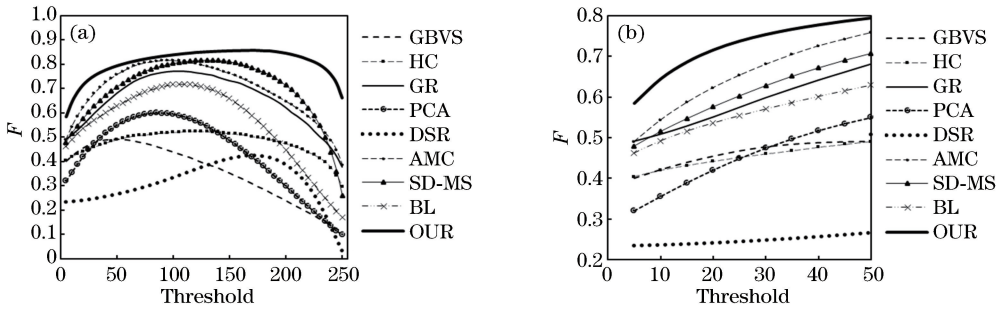


图 6 ECSSD 数据集上 F -measure 曲线。(a)整体曲线;(b)局部曲线

Fig. 6 F -measure curves on ECSSD dataset. (a) Whole curves; (b) partial curves

图 3 为 MSRA-10K 数据集上 P - R 曲线评测结果,图 4 为 MSRA-10K 数据集上 F 值曲线,图 5 为 ECSSD 数据集上 P - R 曲线评测结果,图 6 为 ECSSD 数据集上 F 曲线评测结果。无论从 P - R 曲线还是 F 值曲线都可以很明显地看出本文算法优于其他 8 种经典算法。相对于 P 值与 R 值而言, F 值综合考虑两者因素,结果更加可靠。从图 4 与图 6 可以看出本文算法得到的 F 值相对平滑,说明本文算法的稳定性强。

为便于观察数据,列出 9 种算法中最优 F 值及与其相对应的 P 和 R 的值,由(18)式可以看到 F 值是由 P 和 R 两者共同决定的。为了更加直观地观察各算法最优 F 值,给出算法 F 值柱状图,如图 7 和图 8 所示,可以明显看出,本文算法得到的 F 值最高,这说明本文算法得到的显著图结果最优,从数据结果的同比增长率上来看,在 MRSA-10K 数据集上,本文算法 F 值相比于 GBVS 算法和 HC 算法增长率接近 50%,相比于 BL、SD-MS、AMC、DRS、PCA 和 GR 算法增长率分别为 9.7%,9.0%,9.1%,27%,8.3%,8.4%。同样地,在 ECSSD 数据集上,本文算法增长率也均达到 10%以上。

表 1 比较了本文算法与其他 8 种算法的平均运行时间(C 语言运行环境用 C 表示, M 表示 Matlab

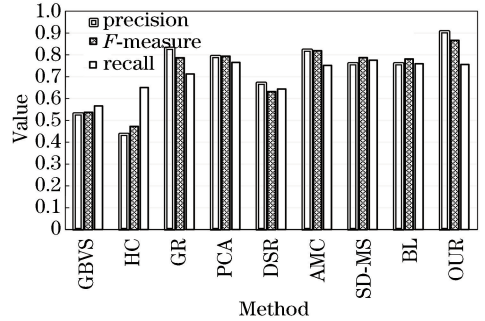


图 7 MSRA-10K 数据集最佳 F 值对比柱形图

Fig. 7 Best F value comparison histogram on MSRA-10K dataset




图 8 ECSSD 数据集最佳 F 值对比柱形图

Fig. 8 Best F value comparison histogram on ECSSD dataset

运行环境),由表可以很清晰地看出本文算法比部分算法运行速度快,并结合图2的实验效果对比得出,虽然一些算法运行速度快一些,但存在结果分辨率低的问题。在本文算法中,处理次级显著图时,需要

对图像进行训练、测试和融合,虽然融合过程也需要大量的计算,也会对图像的运行时间产生一定的影响,但相对来说,本文算法在时间上具有一定的优越性。

表1 多种算法运行环境及时间对比

Table 1 Running environments and time of various algorithms

Dataset	Parameter	GBVS	HC	GR	PCA	DSR	AMC	SD-MS	BL	OUR
MSRA-10K	Calculation time /s	13.23	10.26	5.36	7.08	3.16	1.08	17.93	13.23	12.59
ECSSD	Calculation time /s	11.33	13.26	5.90	7.81	1.37	1.28	16.93	13.55	11.08

6 结 论

针对显著性检测算法存在的检测不准确和边缘不清晰的问题,采用贝叶斯公式将由 compactness 先验的空间紧密性所产生的初级显著性图和经多核学习得到的次级显著图以不同权重进行融合,这样的结合方式使得最终的显著性检测图像更加精确,在多核学习获得次级显著图的过程中,将训练学习限制在一个图像的多尺度内,既增强了检测效率,又减少了计算资源。经对比经典算法,可以看出本文算法性能优于其他算法,可以更加精确地检测出图像显著目标,在运行时间上也略优于部分算法。

参 考 文 献

- [1] Bi L H, Liu Y C. Plant leaf image recognition based on improved neural network algorithm [J]. *Laser & Optoelectronics Progress*, 2017, 54(12): 121102.
毕立恒, 刘云潺. 基于改进神经网络算法的植物叶片图像识别研究 [J]. *激光与光电子学进展*, 2017, 54(12): 121102.
- [2] Li J X, Zong Q. Object tracking based on multi-feature and local joint sparse representation [J]. *Laser & Optoelectronics Progress*, 2017, 54(10): 101502.
李敬轩, 宗群. 基于多特征和局部联合稀疏表示的目标跟踪 [J]. *激光与光电子学进展*, 2017, 54(10): 101502.
- [3] Li F Y, Huo H T, Bai J, *et al.* Hyperspectral target detection based on sparse representation and adaptive model [J]. *Acta Optica Sinica*, 2018, 38(12): 1228004.
李非燕, 霍宏涛, 白杰, 等. 基于稀疏表示和自适应模型的高光谱目标检测 [J]. *光学学报*, 2018, 38(12): 1228004.
- [4] Wang L H, Tu Z Z, Wang Z L. Image saliency detection based on manifold regularized random walk [J]. *Laser & Optoelectronics Progress*, 2018, 55(12): 121005.

- 汪丽华, 涂铮铮, 王泽梁. 基于流形正则化随机游走的图像显著性检测 [J]. *激光与光电子学进展*, 2018, 55(12): 121005.
- [5] Lu Y Y, Qiang J R, Wang Z. Image segmentation based on active contours with local information [J]. *Computer Engineering and Applications*, 2018, 54(10): 208-212.
鲁圆圆, 强静仁, 汪朝. 基于区域信息主动轮廓模型的图像分割 [J]. *计算机工程与应用*, 2018, 54(10): 208-212.
 - [6] Harel J, Koch C, Perona P. Graph-based visual saliency [C] // 19th International Conference on Neural Information Processing Systems, December 4-7, 2006, Canada. Cambridge: MIT Press, 2006: 545-552.
 - [7] Margolin R, Tal A, Zelnik-Manor L. What makes a patch distinct? [C] // 2013 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 23-28, 2013, Portland, OR, USA. New York: IEEE, 2013: 1139-1146.
 - [8] Yang C, Zhang L H, Lu H C. Graph-regularized saliency detection with convex-hull-based center prior [J]. *IEEE Signal Processing Letters*, 2013, 20(7): 637-640.
 - [9] Tong N, Lu H C, Zhang L H, *et al.* Saliency detection with multi-scale superpixels [J]. *IEEE Signal Processing Letters*, 2014, 21(9): 1035-1039.
 - [10] Tong N, Lu H C, Ruan X, *et al.* Salient object detection via bootstrap learning [C] // 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 7-12, 2015, Boston, MA, USA. New York: IEEE, 2015: 1884-1892.
 - [11] Cheng M M, Mitra N J, Huang X L, *et al.* Global contrast based salient region detection [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2015, 37(3): 569-582.
 - [12] Jiang B W, Zhang L H, Lu H C, *et al.* Saliency detection via absorbing Markov chain [C] // 2013 IEEE International Conference on Computer Vision,

- December 1-8, 2013, Sydney, NSW, Australia. New York: IEEE, 2013: 1665-1672.
- [13] Li X H, Lu H C, Zhang L H, *et al.* Saliency detection via dense and sparse reconstruction[C] // 2013 IEEE International Conference on Computer Vision, December 1-8, 2013, Sydney, NSW, Australia. New York: IEEE, 2013: 2976-2983.
- [14] Huang Z C. Research of salient object detection based on prior integration and feature guidance[D]. Hefei: Anhui University, 2017: 32-33.
黄子超. 先验融合和特征指导的显著目标检测方法研究[D]. 合肥: 安徽大学, 2017: 32-33.
- [15] Liu K, Zhang X Y, Chen N J, *et al.* Salient object detection fusing depth information under foggy weather [J]. Journal of Hebei University of Technology, 2015, 44(2): 10-15.
刘坤, 张晓怿, 陈宁纪, 等. 融合深度信息的雾霾情况下显著性目标提取[J]. 河北工业大学学报, 2015, 44(2): 10-15.
- [16] Bi W, Huang W G, Zhang Y P, *et al.* Object detection based on salient contour of image[J]. Acta Electronica Sinica, 2017, 45(8): 1902-1910.
毕威, 黄伟国, 张永萍, 等. 基于图像显著轮廓的目标检测[J]. 电子学报, 2017, 45(8): 1902-1910.