

基于超像素匹配的图像协同显著性检测

张兆丰 吴泽民 姜青竹 杜麟 胡磊

(中国人民解放军理工大学通信工程学院 南京 210007)

摘要 为了快速有效地完成多图像的协同显著性检测,提出了一种基于超像素匹配的检测模型。首先针对一般单个超像素特征匹配效果较差的问题,提出一种基于 Hausdorff 距离的邻域超像素集匹配算法来进行图像间超像素的精确匹配;然后构建图像内和图像间的双层元胞自动机模型,进行多幅图像之间的显著性传播,从而有效地检测出协同显著性。在公开的测试数据集上的实验结果表明,所提算法的检测精度和检测效率优于目前的主流算法,且具有较强的鲁棒性。

关键词 协同显著性检测, Hausdorff 距离, 超像素匹配, 元胞自动机, 显著性传播

中图分类号 TP393 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2017.11.048

Co-saliency Detection via Superpixel Matching

ZHANG Zhao-feng WU Ze-min JIANG Qing-zhu DU Lin HU Lei

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

Abstract To effectively address the issue of multi-scene co-saliency detection, we proposed a novel model based on superpixel matching and cellular automata. First of all, we introduced an adjacent superpixel sets matching algorithm based on Hausdorff distance to achieve exact matching between image superpixels. Comparing to the traditional superpixel matching algorithm, the new algorithm greatly improves the matching accuracy. In addition, we further proposed the 2-layer cellular automata via intra image and inter images to carry out the significant propagation of multiple images, thus exploit the intrinsic relevance of similar regions through interactions with neighbors in multi-scene. Experimental results demonstrate that our model outperforms state-of-the-art methods. Furthermore, the proposed methods is efficient and robust.

Keywords Co-saliency detection, Hausdorff distance, Superpixel matching, Cellular automata, Saliency propagation

1 引言

近年来,多场景应用的需求,促使协同显著性正逐渐成为一个新兴的研究课题。协同显著性,指多场景(图像或视频)中共同存在的相同或相似目标的显著程度,而协同显著性检测即是对这些共同目标进行标定和凸显。协同显著性对协同分割、多场景目标再识别、图像和视频摘要等都具有重要的应用价值。而单幅图像的显著性检测算法,如非常具有代表性的 Cheng^[1] 的基于直方图的全局对比度模型、Perazzi^[2] 的滤波器模型、Yang^[3] 的流形排序模型、Zhu^[4] 的边界连通度及优化模型以及 Qin^[5] 的元胞自动机模型等,在图像级的显著性计算方面都获得了非常好的效果,但在多图像协同显著性检测方面效果欠佳。

目前协同显著性算法较少,比较典型的有 Li 等人^[6] 在单

个图像显著图检测的基础上,通过多层图结构模型构建图像对的协同显著性,但该方法只适用于两幅图像,难以推广到多幅图像场景中;Fu 等人^[7] 利用颜色聚类提取多幅图像的一致性信息,然后融合颜色对比度、空间分布性和图像间的一致性等线索来构造协同显著图,但其只采用像素级的简单颜色聚类,缺乏目标的结构信息,很容易造成一些具有相同颜色的目标和背景区域的误检测;Liu 等人^[8] 通过图像级分层分割,利用颜色直方图计算分割区域的全局相似性,但由于只是单独采用区域本身的特征进行相似度计算,因此容易产生很多误匹配;Cao 等人^[9] 首先利用多种算法求得单个图像的显著图,然后利用低秩分解的方法进行多显著图的融合来获得最终的协同显著图,但融合显著图受单图像显著性检测算法的精度影响很大;Zhang 等人在文献[10]中通过提取图像的深度特征,对同类图像和不同类图像进行综合训练,以提取共同目

到稿日期:2016-09-12 返修日期:2017-01-20 本文受国家自然科学基金(61501509)资助。

张兆丰(1991—),男,硕士生,主要研究方向为图像处理;吴泽民(1973—),男,博士,副教授,主要研究方向为信息融合、图像处理;姜青竹(1987—),男,硕士,主要研究方向为图像处理;杜麟(1992—),男,硕士生,主要研究方向为视频传输保障;胡磊(1985—),男,博士,讲师,主要研究方向为压缩感知、视频信息处理。

标的特征和背景区域的特征,但在图像间区域相似度匹配中只是采用 CIELab 色彩空间的平均颜色进行匹配,性能有待提升;随后,Zhang 等人又在文献[11]中使用多实例学习和自调式学习的方式寻找共同存在的目标,这两种学习方法都存在需要精确标定目标训练集、复杂度高以及难以推广的问题。总体而言,上述方法主要存在两个问题:1)缺乏图像间的相似目标区域的有效匹配方法;2)缺乏一种适用于计算协同显著性的统一结构框架。

本文针对这两方面的问题,结合协同显著性检测需要保证的重复性和显著性这两大要素,首先提出一种基于 Hausdorff 距离的邻域超像素集的匹配算法来计算图像间区域的相似性,从而刻画区域的重复出现性;然后受文献[5]中的单层元胞自动机的启发,提出一种双层元胞自动机模型来进行计算图像内的和图像间的显著值传播,以保证目标区域完整的显著性。实验结果表明,所提的基于 Hausdorff 距离的超像素匹配算法具有较好的效果,很大程度上减少了传统匹配方法中将目标区域与其颜色相似的背景区域误匹配的现象;同时,图像内和图像间的多图像显著值传播算法具有较强的鲁棒性。在公开数据集上的测试结果表明,所提算法的检测性能优于目前的主流算法。

2 超像素匹配

类似于很多单图像显著性检测算法,本文算法也是在超像素分割的基础上进行的。而为了检测不同图像共同存在的目标,其核心在于图像间超像素的匹配。对于一组包含 n 幅图像的图像集 $I = \{I_i\}_{i=1}^n$,首先使用 SLIC(Simple Linear Iterative Cluster)算法^[22]将每个图像 I_i 划分为超像素集 $R_i = \{r_{i,s}\}_{s=1}^{N_i}$,其中 N_i 为图像 I_i 划分的超像素的数目。本文所指的超像素匹配,是对一幅图像 I_i 中的任一超像素 $r_{i,s}$ 而言的,寻找其在另一图像 $I_j (j \neq i)$ 中满足一定相似度的超像素集。需要说明的是,并非 I_i 中的所有超像素都具有匹配的超像素,且 I_i 中的一个超像素在 I_j 中可以有多个匹配的超像素。

2.1 基于单个超像素的特征匹配

对于寻找与 I_i 中任一超像素 $r_{i,s}$ 匹配的超像素,最简单而直接的方法,就是计算 I_j 中所有超像素与 $r_{i,s}$ 特征向量之间的相似度,满足一定阈值的即为匹配的超像素集。通常定义两幅图像中任意两个超像素之间的特征相似度为:

$$w_{i,j}^{s,t} = \exp\left(-\frac{\|c_{i,s} - c_{j,t}\|^2}{2\sigma_c^2}\right) \quad (1)$$

其中, $c_{i,s}$ 和 $c_{j,t}$ 分别表示超像素 $r_{i,s}$ 和 $r_{j,t}$ 在 CIELab 空间上的平均颜色值, s 和 t 是超像素的下标; σ_c 用来控制权重的强度,在 [5, 15] 之间不敏感,同文献[13]一样取 10。

然后,取 $w_{i,j}^{s,t}$ 大于阈值 δ 的超像素即构成 $r_{i,s}$ 的匹配超像素集。图 1(b)为取 $\delta=0.9$ 时的单个超像素匹配结果图。从图 1(b)中可以看出,只采用单个超像素颜色特征进行匹配时会存在很多误匹配,如会将目标区域和具有相似颜色的背景区域匹配在一起,其原因主要在于独立处理每个超像素时未

考虑超像素的空间结构关系。



图 1 两种方法的超像素匹配示例

2.2 基于 Hausdorff 距离的邻域超像素集匹配

对于一个超像素特征的描述,其除了具有由内部像素构成的本身特征外,还有与其相邻的超像素构成的结构关系特征:若一个超像素与周围超像素特征比较接近,则该超像素的结构特征比较平滑;若与周围超像素相差很大,则通常为一个孤立超像素;若与周围超像素有一半特征相同,有一半特征不同,则通常为边缘超像素。如图 2 所示,图像 I_i 中任一超像素 $r_{i,s}$ 与周围邻接超像素构成邻域超像素集 $N_{i,s}$,而寻找在另一图像 I_j 中与其相匹配的超像素的问题,可以转化为计算两个邻域超像素集 $N_{i,s}$ 和 $N_{j,t}$ 的距离问题。最简单有效的计算两个集合距离的方法是采用 Hausdorff 距离:

$$H(N_{i,s}, N_{j,t}) = \max(h(N_{i,s}, N_{j,t}), h(N_{j,t}, N_{i,s})) \quad (2)$$

其中, $h(N_{i,s}, N_{j,t})$ 表示点集 $N_{i,s}$ 到 $N_{j,t}$ 的有向距离。这里采用 Dubouison^[14] 提出的修正 Hausdorff 距离 (Modified Hausdorff Distance, MHD):

$$h(N_{i,s}, N_{j,t}) = \frac{1}{|N_{i,s}|} \sum_{a \in N_{i,s}} \min_{b \in N_{j,t}} \|c_a - c_b\| \quad (3)$$

其中, c_a 和 c_b 分别表示超像素 a 和 b 在 CIELab 空间上的平均颜色值, $|N_{i,s}|$ 为 $N_{i,s}$ 中的超像素数目。




图 2 基于 Hausdorff 距离的邻域超像素匹配

类似于式(1),定义两个超像素的邻域超像素集的相似度为:

$$v_{i,j}^{s,t} = \exp\left(-\frac{H(N_{i,s}, N_{j,t})^2}{2\sigma_c^2}\right) \quad (4)$$

同样,取 $v_{i,j}^{s,t}$ 大于阈值 δ 的超像素构成 $r_{i,s}$ 的匹配超像素集。图 1(c)即为取 $\delta=0.9$ 时的超像素匹配结果图。从图 1(c)中可以看出,相比于只采用单个超像素颜色特征匹配

的方法,采用邻域超像素集匹配后可以有效消除一些孤立超像素的误匹配,所匹配的超像素基本都在目标内部。

3 基于双层元胞自动机传播的协同显著性检测

文献[5]提出一种单层元胞自动机模型用于计算单幅图像的显著性,其核心思想是一个超像素同时受其自身和周围超像素显著值的影响,在若干次传播后达到整体状态的收敛。但对协同显著性而言(见图3),一个超像素(中间图五角星标注)的显著值不仅与该幅图像内相邻超像素(中间图内层圆点标注和外层小六边形块标注)的状态有关,还与该组图像集其他图像中与之相匹配的超像素(四周图小正方形块标注)的状态有关。

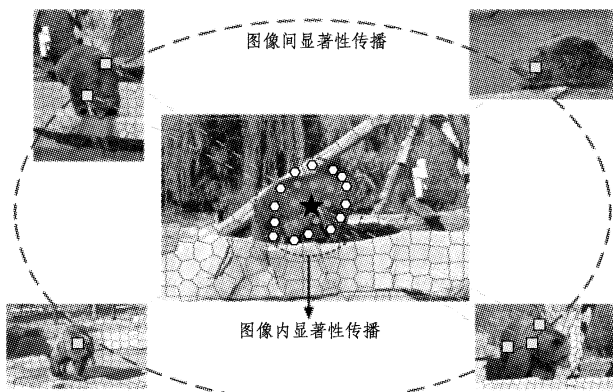


图3 基于双层元胞自动机传播的协同显著性检测模型

据此,提出基于图像内和图像间的双层元胞自动机传播模型:

$$S_i^{m+1} = (1 - \lambda_1 - \lambda_2) S_i^m + \lambda_1 F_i^{intra} S_i^m + \lambda_2 \sum_{j=1, j \neq i}^n F_{i,j}^{inter} S_j^m \quad (5)$$

其中, S_i^m 是图像 I_i 中所有超像素第 m 次状态更新后的显著值, S_i^0 为初始显著值, F_i^{intra} 为图像 I_i 内的超像素影响因子矩阵, $F_{i,j}^{inter}$ 为图像 I_j 对图像 I_i 的超像素影响因子矩阵, λ_1 和 λ_2 分别为影响权重因子。经过 M 次迭代更新后状态机将达到平衡,最终的 S_i^m 值即为图像 I_i 的显著值。其中初始显著值 S_i^0 可以通过很多单幅图像显著性检测算法^[1-5, 15-29]求得,此处选用简单且有效的 MR^[16]算法,一方面其在超像素级别下利用图传播求取显著值,另一方面其所采用的图结构信息在计算图像内的影响因子时还会用到。下面主要介绍图像内的影响因子矩阵 F_i^{intra} 和图像间的影响因子矩阵 $F_{i,j}^{inter}$ 。

3.1 图像内的影响因子矩阵 F_i^{intra}

类似于文献[5, 16],同式(1),图像内部各超像素间的相似性也是采用 CIELab 空间上的颜色相似性求得的。这里定义原始的图像内各超像素之间的影响因子矩阵 $\hat{F}_i^{intra} = [f_{i,t}^{s,t}]_{N_i \times N_i}$:

$$f_{i,t}^{s,t} = \begin{cases} \exp\left(-\frac{\|c_{i,s} - c_{i,t}\|^2}{2\sigma_c^2}\right), & t \in \mathcal{N}_{i,s} \\ 0, & t = s \text{ or others} \end{cases} \quad (6)$$

区别于 2.2 节定义的邻域超像素集 $N_{i,s}$,这里的相邻区

域 $\mathcal{N}_{i,s}$ 同文献[5, 16],不仅包括直接相邻(图3中间图圆形点标注),还包括二阶相邻(相邻点的相邻点,图3中间图正六边形块标注)和边界相邻(图3中间图矩形框所示);然后求得度矩阵 $D_i^{intra} = \text{diag}\{d_1, d_2, \dots, d_{N_i}\}$,其中 $d_i = \sum_t f_{i,t}^{s,t}$ 。对原始矩阵 \hat{F}_i^{intra} 进行行归一化,得到最终的图像内的影响因子矩阵 F_i^{intra} 为:

$$F_i^{intra} = [D_i^{intra}]^{-1} \cdot \hat{F}_i^{intra} \quad (7)$$

3.2 图像间的影响因子矩阵 $F_{i,j}^{inter}$

首先使用第2节提出的超像素匹配算法来求得两个超像素的邻域超像素集的相似度 $v_{i,j}^{s,t}$;然后定义原始的图像间任意两个超像素之间的影响因子矩阵 $\hat{F}_{i,j}^{inter} = [f_{i,j}^{s,t}]_{N_i \times N_j}$:

$$f_{i,j}^{s,t} = \begin{cases} v_{i,j}^{s,t}, & v_{i,j}^{s,t} > \delta \\ 0, & \text{others} \end{cases} \quad (8)$$

其中, δ 为匹配相似度阈值,此处取 $\delta = 0.9$ 。

同样求得度矩阵 $D_{i,j}^{inter} = \text{diag}\{d_1, d_2, \dots, d_{N_i}\}$,其中 $d_i = \sum_j \sum_t f_{i,j}^{s,t}$ 。对原始矩阵 $\hat{F}_{i,j}^{inter}$ 进行归一化,同时考虑共有的其他 $n-1$ 幅图像的影响,得到最终图像间的影响因子矩阵 $F_{i,j}^{inter}$ 为:

$$F_{i,j}^{inter} = \frac{1}{n-1} \cdot [D_{i,j}^{inter}]^{-1} \cdot \hat{F}_{i,j}^{inter} \quad (9)$$

3.3 迭代终止条件

给定图像内的影响因子矩阵 F_i^{intra} 、图像间的影响因子矩阵 $F_{i,j}^{inter}$ 及初始显著图 $\{S_i^0\}_{i=1}^n$ 后,即可通过式(5)的迭代更新来进行超像素的显著值传播。文献[5]中的实验表明,元胞自动机一般迭代 20 次后,各超像素的显著值变化不太明显,系统即达到稳态。但在实验中发现,该系统有时可能会提前达到稳态,因此通过判定相邻两次更新后各个图像的显著值是否还发生明显变化来进行提前终止迭代的判定:

$$\Delta = \max_{i \in [1, n]} (\|S_i^{m+1} - S_i^m\|_2) \quad (10)$$

当 $\Delta < \epsilon$ (ϵ 为一设定的极小阈值)时,即认为各图像显著值不再发生明显变化。因此,给出式(5)迭代更新的终止条件是:各幅图像的显著值不再发生明显变化或达到最大迭代次数 m_{\max} (这里同文献[5]取 $m_{\max} = 20$)。

3.4 算法分析及流程

从式(5)、式(7)和式(9)可以看出,一个超像素首先受其所在图像内部相邻超像素显著值的影响,但若它在其他大部分图像中都具有匹配的超像素,则该超像素显著值受其他图像显著值的影响较大;若该超像素只在部分图像有匹配的超像素或者无匹配的超像素,则其显著值会在式(5)的迭代中逐渐变小。从而,通过双层元胞自动机的不断迭代,最终在所有图像中都共同存在的目标超像素将具有较高的显著值,而只在个别图像中存在的超像素的显著值将逐步降低;另外,共同存在的背景超像素由于其初始显著值的限制(基本接近于 0),仍然会得到有效抑制。因此,通过该传播模型即可完成协同显著性的检测。

算法 1 给出本文提出的协同显著性检测算法的整体流

程。其中步骤 1-步骤 6 用于构造超像素匹配和图结构影响因子矩阵,一组图只需计算一次;步骤 7-步骤 12 用于传播图像内和图像间的显著值,并根据终止条件完成迭代更新。

算法 1 基于超像素匹配的协同显著性检测

输入:图像集 $\mathbf{I}=\{I_i\}_{i=1}^n$

输出:协同显著图 $\{S_i\}_{i=1}^n$

1. 使用 SLIC 算法将每幅图像 I_i 划分为超像素集 $\mathbf{R}_i=\{r_{i,s}\}_{s=1}^{N_i}$;
 2. 计算每幅图像 I_i 的内部影响因子矩阵 $\mathbf{F}_i^{\text{intra}}$;
 3. 利用 MR 算法^[16]计算初始显著图 $\{S_i^0\}_{i=1}^n$;
 4. 构造每个超像素 $r_{i,s}$ 的邻域超像素集 $N_{i,s}^{\text{v}}$;
 5. 根据式(2)一式(4)计算任意两个超像素的匹配相似度 $v_{i,j}^{\text{v}}$;
 6. 构造图像间的影响因子矩阵 $\mathbf{F}_{i,j}^{\text{inter}}$;
 7. while $\Delta > \epsilon$ 且 $m < M$ do
 8. for $i=1:n$ do
 9. 更新每幅图像的显著图
- $$S_i^{m+1} = (1-\lambda_1-\lambda_2)S_i^m + \lambda_1 \mathbf{F}_i^{\text{intra}} S_i^m + \lambda_2 \sum_{j=1, j \neq i}^n \mathbf{F}_{i,j}^{\text{inter}} S_j^m;$$
10. end
 11. 计算显著图变化 $\Delta = \max_{i \in [1,n]} (\|S_i^{m+1} - S_i^m\|_2)$;
 12. end

4 实验结果与分析

4.1 实验设置

(1)测试数据集。需要说明的是,目前协同显著性检测仍处于初期研究阶段,可用的数据集也相对较少,比较成熟的只有 *ImgPair*^[6] 和 *iCoseg*^[30] 数据集。*ImgPair* 相对简单,且基于此数据集提出的算法已相对成熟,性能提升空间已非常有限;另一方面,其每组图像集仅有两幅图像,而本文算法较依赖于多幅图像间的显著值传播,因此适合现在的多场景传播模型。*iCoseg* 是最常用的测试协同显著性和协同分割算法的数据集,其包含 38 组图像集,每组有 5 幅以上的图像,共 634 幅图像,每一幅图像都提供了像素级的真值标注。因此,本文在 *iCoseg*^[30] 数据集上测试所有算法。

(2)比较算法。这里主要比较近年来比较典型的协同显著性检测算法:CB-C^[7] (基于颜色聚类的多图像算法),HS^[8],SA^[9],以及几个典型的单个图像显著性检测算法 CB-S^[7] (基于颜色聚类的单图像算法),MR^[16],RBD^[13]。

(3)评估指标。参照文献[31],分别采用精度-召回率 (Precision-Recall, P-R) 曲线、自适应阈值的 F-measure 值和平均绝对误差 (Mean Absolute Error, MAE) 值进行评估。

1)P-R 曲线。其是计算机视觉中比较常用的一项指标。对于一个显著图,首先按照一定阈值对其进行二值分割得到掩码图 M ,然后与真值 G 比较。分别计算精度和召回率:

$$precision = \frac{|M \cap G|}{|M|}, recall = \frac{|M \cap G|}{|G|} \quad (11)$$

2)F-measure:某种程度上,精度和召回率是一对相互矛盾的指标,高的召回率通常难以保证高的精度(如取整幅图像所有像素,召回率为 1,但精度可能非常小),因此高精度又难

以确保完整的召回率(如只取目标中的一个像素,精度为 1,但召回率则趋于 0),因此单取其中一个都不能很好地描述显著图的质量。为了综合考虑两者,常常采用 F-measure 值:

$$F\text{-measure} = \frac{(1+\beta^2) \cdot precision \cdot recall}{\beta^2 \cdot precision + recall} \quad (12)$$

其实质上就是精度和召回率的调和平均数。一般来说,精度相对召回率更加重要,因此这里一般取 $\beta^2 = 0.3$ ^[31] 来强调精度。

3)MAE:被定义为显著图 S 和真值 G (两者归一化到 $[0, 1]$ 之间)的绝对误差的平均值:


$$MAE = \frac{1}{W \times H} \sum_{x=1}^W \sum_{y=1}^H |S(x,y) - G(x,y)| \quad (13)$$

其中, W 和 H 为图像的宽和高。前两种评价指标重在强调显著性目标的标注和高亮,而未考虑被正确分类的负样本点,这里主要是一些被正确标注的非显著区域。MAE 指标则对这些区域比较敏感,更加强调和目标真值的接近程度。


(4)参数设置。设置 SLIC 超像素分割的数目 $N_i = 200$, 紧致性权值为 20。式(5)中的 λ_1 和 λ_2 分别取经验值 0.5 和 0.3,最大迭代次数 $M=20$,迭代终止阈值 $\epsilon = 10^{-3}$,匹配相似度阈值 $\delta=0.9$ 。

4.2 与其他算法的比较


图 4 分别给出了所提算法与其他算法的 P-R 曲线、F-measure 直方图以及 MAE 直方图的比较结果。



(a) P-R 曲线



(b) F-measure



(c) MAE

图 4 *iCoseg* 数据集上不同算法的性能比较

从图4中可以看出,所提算法无论在召回率还是精度方面,相对其他算法都有明显的改进,较高的 F-measure 值表明所提算法的综合性能优于其他算法,较低的 MAE 值也表明我们的结果与真值更加接近。

图5给出了 iCoseg 数据集上部分检测效果的示例。从图5中可以看出,相较于单个图像的检测算法如 CB-S, MR, RBD 等,大部分协同显著性检测算法如 HS, SA 以及所提算法的性能都有明显的提升,特别是一些共同目标区域都能得到凸显。但 CB-C 算法由于只是用到像素级的颜色聚类,算法本身存在一定的局限性。从图5(b)的示例中可以明显地看出,一方面其特别容易受光照强度导致的颜色差异的影响,另一方面其未考虑像素的结构属性,从而导致检测不够完整。HS 算法由于只是采用简单的区域级颜色匹配,未考虑邻域结构特征,因此存在很多误匹配,导致在检测中存在很多目标和背景匹配的情况,检测效果欠佳。SA 算法的整体性能较好,但其算法的核心是对多个单幅图像显著性检测算法的融合,其性能较依赖于各算法的检测效果。而本文所提算法由于采用了邻域超像素匹配算法,因此对光照差异、结构变化、复杂背景等都具有较好的检测效果。

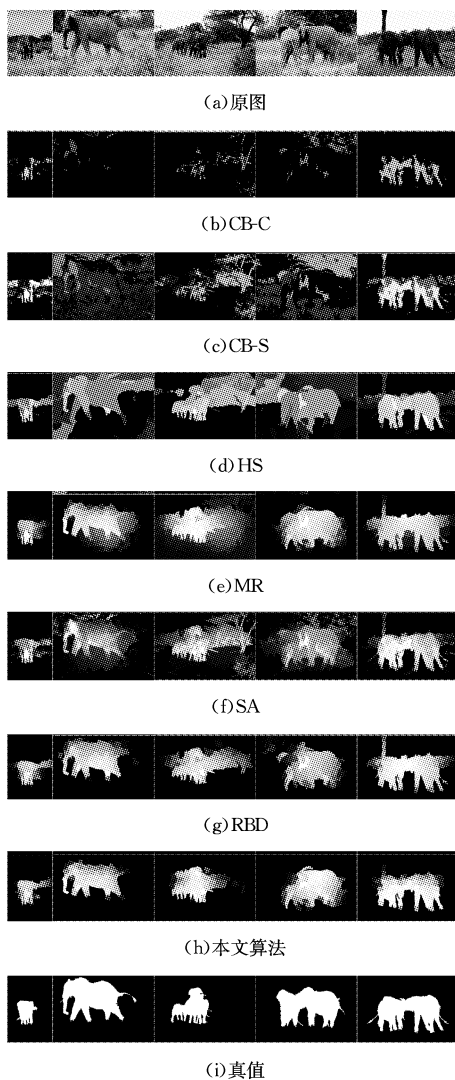


图5 iCoseg 数据集上不同算法的检测效果示例

4.3 运行时间分析

表1列出了本文算法和其他协同显著性算法的平均运算时间比较。测试环境为 Intel Xeon E5-2620 2.00GHz, RAM 16GB。所有算法都直接运行作者公布的源代码,所有代码都在 Matlab2012b 平台下运行,测试数据集为 iCoseg。需要说明的是,SA 算法由于是融合多种单幅图像显著性检测算法的结果,因此其整体运算时间取决于各算法的时间,这里只给出其融合算法的时间,故相对较低。从表1可以看出,本文所提算法的时间复杂度与 CB-C 相当,相比 HS 算法大大降低。

表1 不同协同显著性算法平均运算时间的比较/s

算法	CB-C	HS	SA	Ours
时间	5.5	24.9	1.9	6.3

结束语 本文首先基于 Hausdorff 距离提出了一种使用邻域超像素集进行超像素匹配的简单算法,从实际结果看,匹配效果优于只使用单个超像素特征进行的匹配。在此基础上,分别构建图像内和图像间的影响因子矩阵,建立双层元胞自动机传播模型进行多幅图像的协同显著性的检测。实验结果表明,所提算法无论在鲁棒性还是时间复杂度上都有明显的优势。但需要指出的是,我们只是选用了颜色特征进行超像素匹配,对复杂背景情况可采用颜色直方图、纹理特征等更复杂的特征表示。另外,区别于其他协同显著性检测模型,本文所提双层元胞自动机模型是一个统一的协同检测模型,将图像内和图像间的相似性有效地结合起来,具有较好的可扩展性。

参考文献

- [1] CHENG M, ZHANG G, MITRA N, et al. Global contrast based salient region detection[C]//IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Colorado Springs, USA, 2011:409-416.
- [2] PERAZZI F, KRAHENBUHL P, PRITICH Y, et al. Saliency filters: contrast based filtering for salient region detection[C]//IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Rhode Island, USA, 2012:733-740.
- [3] YANG C, ZHANG L, LU H, et al. Saliency detection via graph-based manifold ranking[C]//IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Portland, USA, 2013: 3166-3173.
- [4] ZHU W, LIANG S, WEI Y, et al. Saliency optimization from robust background detection[C]//IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Columbus, USA, 2014:2814-2821.
- [5] QIN Y, LU H, XU Y, et al. Saliency detection via cellular automata[C]//IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Boston, USA, 2015:111-119.
- [6] LI H, NGAN K N. A co-saliency model of image pairs[J]. IEEE Transactions on Image Processing, 2011, 20(12): 3365-3375.
- [7] FU H, CAO X, TU Z. Cluster-based co-saliency detection[J].

- IEEE Transactions on Image Processing, 2013, 22(10): 3766-3778.
- [8] LIU Z, ZOU W, LI L, et al. Co-saliency detection based on hierarchical segmentation [J]. IEEE Signal Processing Letters, 2014, 21(1): 88-92.
- [9] CAO X, TAO Z, ZHANG B, et al. Self-adaptively weighted co-saliency detection via rank constraint [J]. IEEE Transactions on Image Processing, 2014, 23(9): 4175-4186.
- [10] ZHANG D, HAN J, LI C, et al. Co-saliency detection via looking deep and wide [C] // IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Boston, USA, 2015: 2994-3002.
- [11] ZHANG D, MENG D, LI C, et al. A self-paced multiple-instance learning framework for co-saliency detection [C] // IEEE Conference on Computer Vision (ICCV). Santiago, Chile, 2015: 594-602.
- [12] 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.
- [13] KIM J, HAN D, TAI Y, et al. Salient region detection via high-dimensional color transform [C] // IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Columbus, USA, 2014: 863-890.
- [14] BROX T, MALIK J. Large displacement optical flow; descriptor matching in variational motion estimation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2010, 33(3): 500-513.
- [15] CHANG K, LIU Y, CHEN H, et al. Fusing generic objectness and visual saliency for salient object detection [C] // IEEE Conference on Computer Vision (ICCV). Barcelona, Spain, 2011: 914-921.
- [16] WEI Y, WEN F, ZHU W, et al. Geodesic saliency using background priors [C] // 12th European Conference on Computer Vision (ECCV). Florence, Italy, 2012: 29-42.
- [17] YAN Q, XU L, SHI J, et al. Hierarchical saliency detection [C] // IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Portland, USA, 2013: 1155-1162.
- [18] MARGOLIN R, TAL A, ZELNIK-MANOR L. What makes a patch distinct? [C] // IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Portland, USA, 2013: 1139-1146.
- [19] JIANG H, WANG J, YUAN Z, et al. Salient object detection: a discriminative regional feature integration approach [C] // IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Portland, USA, 2013: 2083-2090.
- [20] JIANG B, ZHANG L, LU H, et al. Saliency detection via absorbing Markov chain [C] // IEEE Conference on Computer Vision (ICCV). Sydney, Australia, 2013: 1665-1672.
- [21] LI X, LU H, ZHANG L, et al. Saliency detection via dense and sparse reconstruction [C] // IEEE Conference on Computer Vision (ICCV). Sydney, Australia, 2013: 2976-2983.
- [22] CHENG M, WARRELL J, LIN W, et al. Efficient salient region detection with soft image abstraction [C] // IEEE Conference on Computer Vision (ICCV). Sydney, Australia, 2013: 1529-1536.
- [23] JIANG P, LING H, YU J, et al. Salient region detection by UFO: uniqueness, focusness and objectness [C] // IEEE Conference on Computer Vision (ICCV). Sydney, Australia, 2013: 1976-1983.
- [24] LIU R, CAO J, LIN Z, et al. Adaptive partial differential equation learning for visual saliency detection [C] // IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Columbus, USA, 2014: 3866-3873.
- [25] LU S, MAHADEVAN V, VASCONCELOS N. Learning optimal seeds for diffusion-based salient object detection [C] // IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Columbus, USA, 2014: 2790-2797.
- [26] LI N, YE J, JI Y, et al. Saliency detection on light field [C] // IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Columbus, USA, 2014: 3866-3873.
- [27] VIG E, DORR M, COX D. Large-scale optimization of hierarchical features for saliency prediction in natural images [C] // IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Columbus, USA, 2014: 2798-2805.
- [28] LI Y, HOU X, KOCH C. The secret of salient object segmentation [C] // IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Columbus, USA, 2014: 280-287.
- [29] MARGOLIN R, ZELNIK-MANOR L, TAL A. How to evaluate foreground maps? [C] // IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Columbus, USA, 2014: 248-255.
- [30] BATRA D, KOWDLE A, PARIKH D, et al. Interactively co-segmenting topically related images with intelligent scribble guidance [J]. International Journal of Computer Vision, 2011, 93(3): 273-292.
- [31] BORJI A, CHENG M, JIANG H, et al. Salient object detection: a benchmark [J]. IEEE Transactions on Image Processing, 2015, 24(12): 5706-5722.