

文章编号 1004-924X(2019)08-1845-09

基于对象性和多层线性模型的 协同显著性检测

金志刚, 李静昆*

(天津大学 电气自动化与信息工程学院, 天津 300072)

摘要:针对背景环境复杂的图像组中协同显著性检测的共显著性目标混乱不一致、准确率低的问题,提出了一种基于对象性和多层线性模型的图像协同显著性检测方法。首先通过显著性先验和对象性概率加权的背景引导因子 BGO 计算图像间显著性引导传播的显著值;然后设计了一种局部区域特征计算图像内显著值,并使用图像的 hu 矩的零、一阶和二阶矩对两阶段显著值进行整合;最后通过多层线性模型自适应地融合各个显著图得到最终结果。实验结果表明:本文算法分别在 iCoseg 和 MSRC 两个数据集上的平均精度达到了 87.80% 和 83.50%,在其它实验指标上的评估结果也有明显提高,增强了算法的适应能力。

关键词:协同显著性检测;多层线性模型;对象性;图像的矩

中图分类号:TP391 **文献标识码:**A **doi:**10.3788/OPE.20192708.1845

Co-saliency detection based on objectness and multi-layer linear model

JIN Zhi-gang, LI Jing-kun*

(School of Electrical and Information Engineering, Tianjin University, Tianjin 300072, China)

* Corresponding author, E-mail: ljk_smile_girl@163.com

Abstract: To address the confusion and low accuracy of salient objects in co-saliency detection for image groups with complex environments, we proposed a co-saliency detection model based on objectness and a multi-layer linear model. First, we calculated the inter-saliency values using the background guidance factor weighted by saliency prior and objectness probability. We then designed a local region feature to calculate the intra-saliency values. The zero, first, and second Hu moments of the image were used to integrate the two-stage saliency values. Finally, saliency subgraphs were adaptively fused using a multi-layer linear model. Experimental results reveal that the AP scores of the proposed algorithm are 87.80% on iCoseg datasets and 83.50% on the MSRC dataset. Results from the evaluation of other experimental indicators are also improved significantly. The detected salient objects are more accurate and the adaptability of the algorithm is enhanced.

Key words: co-saliency detection; multi-layer linear model; objectness; image moments

收稿日期:2018-12-11;修订日期:2019-01-28.

基金项目:国家自然科学基金资助项目(No. 61503084)

1 引言

人们的生活面对着大量的图像,这些图像通常数量巨大并且共享对象或者事件。与一些独立的图像相比,一组图像包含更加丰富和有用的信息^[1-3]。在一组图像中,出现频率高的部分或者主要的前景可以用来表示图像组的主要内容。显著性检测在计算机视觉领域内快速发展^[4-5],在许多计算机视觉任务中发挥了非常重要的作用,如图像检索、视频压缩和场景理解等。

现有的协同显著性检测算法,首先提取图像区域的有效特征,然后探索信息来表征协同显著性,最后设计有效的计算框架来表征协同显著性。Li 等^[6]提出的方法是针对两幅图像,通过使用局部描述符计算一幅图像的显著性及另一幅图像的共显性特征来检测协同显著性,然后利用多尺度分割加以优化,最终的显著图是由图像内显著图和图像间显著图加权组合生成的。此方法虽然在图像数据集上表现效果较好,但是其只在低级特征层面上进行信息的计算,探索了较少的图像间相似度信息,在面对环境复杂的图像集时表现效果较差。为了探索更多的高级语义信息,一些文献通过引入对象性概率补充显著性模型获得高级语义信息,文献^[7]利用显著性和对象性的相关性,构建图模型并利用对象性和交互项的能量函数来同时改进显著性模型。该方法中对象性的引入虽然优化了显著图,但不能有效地抑制周围的背景区域,并且对象性的引入可能会使错误的结果进一步突出显示。近年来协同显著性检测正在从自下而上的框架转变为自顶向下的框架,以视觉注意机制为例,由于对人类视觉系统中相关机制的理解有限,自上而下建模是一项艰巨的任务^[8]。文献^[9]中的方法是利用线性回归的方法,直接从训练图像上学习从低级图像特征或自下而上的显著图到固定位置的线性映射,但这种模型是一种单层线性模型,其适应任务、场景和视点等变化的能力有限。基于以上分析,提出了一种基于对象性和多层线性模型的图像协同显著性检测方法(Co-Saliency Detection Based on Objectness and Multi-layer Linear Model, OMLM)。

本文以图像间显著性传播方式为基础,设计了一种背景引导因子,从显著性先验和对象性概率两个方面选择背景种子,可以更好地抑制背景

区域以突出显著性对象;利用图像内信息对第一阶段结果进一步优化,由于图像不同区域特征不同,故设计了一种局部区域特征,利用图像内信息提供分段区域性建议以使结果更加准确,最后利用图像的矩对显著图和对象概率图进行整合的方式将两个阶段得到的显著值融合,使得显著图更加均匀、边界更清晰;最后提出一种多层线性模型,在下层自适应地融合各个协同显著性图,上层线性模型结合各个协同显著图的信息自适应调整下层的权重,将前两阶段结果有效地合并到此多层线性模型当中。本文 OMLM 算法框架如图 1 所示。

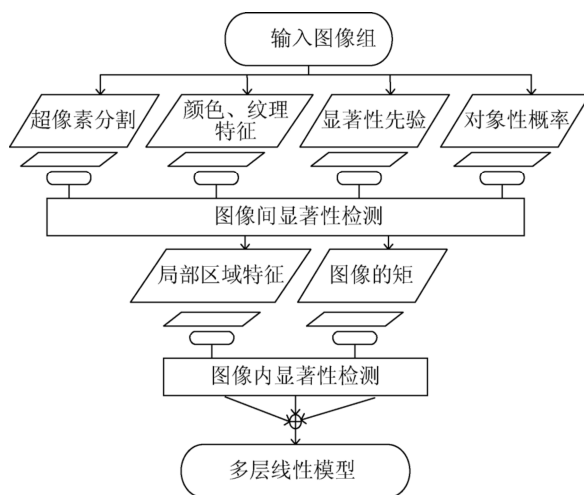


图 1 OMLM 算法框架

Fig. 1 Block diagram of OMLM algorithm

2 显著性传播

2.1 显著性先验和对象性概率优化的图像间显著性传播

将一组 N 张 RGB 图像表示为 $\{I\}_{i=1}^N$, 并把图像 I^i 通过 SLIC 算法^[10] 分割成 K_n 个超像素, 其中第 n 张图像的超像素单元定义为 $i(i=1, \dots, K_n)$ 。为了充分利用一组图像中的对比信息, 利用图像间显著性引导传播方法来整合图像组中任意两张图片的有效相似信息。即 N 张图像中任意一幅图像的显著值, 由同一组图像中其他图像进行引导对比计算。在衡量超像素之间的相似性时, 除了计算颜色和纹理等低层信息, 为了在高层语义信息层面对共显性目标进行约束, 结合了对象性算法, 对象性和显著性的结合增加了共显性目标的一致性。

当前选取的第 n 张图像中的第 i 个超像素和组内其他图像中第 $m(m=1, \dots, N, m \neq n)$ 张图像中的第 j 个超像素首先进行低层信息相似度对比计算,其计算公式如式(2)所示:

$$W(i, j) = \exp \left\{ -\frac{\lambda_c \|c_i^n - c_j^m\|_2}{\alpha_c} - \frac{\lambda_p \|p_i^n - p_j^m\|_2}{\alpha_p} \right\}, \quad (1)$$

其中: c_i^n 表示第 n 个图像中超像素 i 在 LAB 空间的平均颜色值, p_i^n 表示第 n 个图像中超像素 i 的由 Gabor 滤波器响应导出的纹理特征。 λ_c 是控制颜色信息相似度的系数, λ_p 是控制纹理信息相似度的系数, α_c 和 α_p 分别为其标准差。

在显著性传播过程中,单幅图像常采用中心位置先验提供引导作用,但是这种方法对于多图像协同显著目标作用效果并不佳,在一组图像中每幅图像中协同显著目标数量和位置都不固定,故中心先验的过约束可能导致错过某些显著目标。同时,为了优化多图间显著性传播过程,本文设计了一种背景引导算子 BGO_i ,其结合了显著性先验和对象性概率优化背景显著先验,通过两方面高级语义约束对象背景信息,从而改善单一中心先验在多图间传播的缺点,如图 2 所示。其计算公式为:

$$BGO_i = \sum_{k=1}^3 BP_i \times S_{k,i}. \quad (2)$$

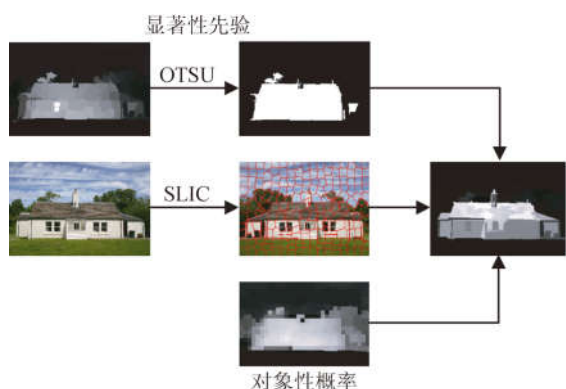


图 2 背景引导算子

Fig. 2 Background guidance factor

在计算背景引导算子 BGO_i 时,考虑到协同显著目标更有可能偏离图像中心偏向边界,传统的选取背景种子方法会引起误导,故背景种子的选择最为关键。首先利用 K-means 算法将图像边界超像素聚成 3 类,这里采用文献[11]中的背

景先验显著图中的全局对比度方法得到初始背景显著值 $S_{k,i}$,其计算公式为:

$$S_{k,i} = \frac{1}{p^k} \sum_{j=1}^{p^k} \frac{1}{e^{\frac{d(c_i, c_j)}{\sigma}} + \beta}, \quad (3)$$

其中 p^k 表示第 k 类边界超像素的数量。

$$BP_i = \begin{cases} 1, & \text{if } i \in B_k \cap B_0 \\ 0, & \text{others} \end{cases}, \quad (4)$$

其中 BP_i 为第 k 类边界的概率系数,该系数从是否显著和是否属于对象两个高级语义层级对背景种子进行约束。显著性约束表示对于图像 n 中某个边界超像素 j ,采用文献[12]中的方法计算图像 n 初始显著值 $s_0^n(j)$,其组成的初始显著图采用 OTSU 阈值法,当超像素 j 的显著值小于等于阈值 T_n 时,认为其为背景超像素,这里用 B_k 来表示。为了减小错过图像边界协同显著目标的可能性,对象性约束融入了对象性算法计算边界超像素属于对象的可能性。其计算公式如式(6)所示:

$$object(p) = \frac{1}{k} \sum_{i=1}^k [O_i I(p \in B_i) + (1 - O_i) I(p \notin B_i)], \quad (5)$$

其中: p 表示像素, B_k 表示对象性算法产生的边界框在图像中的位置, O_k 是相应的置信度分数, $I(p \in B_i)$ 为指示函数,用 0 和 1 表示像素是否在边界框内,得到每个像素根据对象性算法得到的置信度分数,最后将其归一化到 $[0, 1]$ 之间并计算平均对象得分得到超像素的对象概率。对于超像素 j ,其中超过一半像素的对象性概率得分低于平均对象得分的话,将其选择为背景超像素,这里用 B_0 来表示。

综上所述,由图像 m 引导图像 n 的图像间显著性传播的协同显著值计算公式为:

$$s_{int\sigma}^{m \rightarrow n}(i) = BGO_i \cdot \frac{\sum_{j=1}^{K_m} W(i, j) \cdot s_0^m(j)}{\sum_{j=1}^{K_m} W(i, j)}. \quad (6)$$

2.2 局部区域特征和图像的矩整合的图像内显著性检测

上述图像间显著性传播在加入了显著性先验和对象性概率优化的背景引导算子后,得到的显著值更加准确。在探索了图像间相似性关系后,本文更进一步探索了图像内本身的信息来使得显著图更加均匀、边界更加明确。考虑到可能含有多个显著性目标的图像不同区域特征不同^[13],全

局性的优化可能导致错误的效果,故在计算图像内每个超像素的特征时,设计了一种局部区域特征,针对对象性和显著性有效整合,对显著值进行进一步优化。

首先计算图像内显著性局部区域特征,其计算公式为:

$$S_{\text{int ra}}(i) = \frac{\sum_{j=1}^M \sqrt{(s_i - s_j)^2 + (o_i - o_j)^2} \cdot s(j)}{\sum_{j=1}^M \sqrt{(s_i - s_j)^2 + (o_i - o_j)^2}}, \quad (7)$$

$j \in \text{NB}(i),$

其中: $\text{NB}(i)$ 表示超像素 i 的两层局部邻域, s_i 表示超像素的初始显著值, o_i 表示超像素的对象性概率,通过局部邻域下对象性和显著性的整合使得协同显著性目标更加均匀和准确。

为合理有效整合图像 m 引导图像 n 的图像间显著值 $s_{\text{int ra}}^{m \rightarrow n}(i)$ 和图像 n 本身的图像内显著性值,本文在高级语义层级对两阶段显著值进行必要地平滑和整合。引入了一个整合因子 d ,其定义了初始显著图和对象概率图的差异,采用了图像 hu 矩^[14]的零阶矩、一阶不变矩和二阶不变矩。如表 1 所示,由于协同图像组中可能包含多个目标,即初始显著图和对象概率图可能含有多个连通区域,故用 hu 矩的零阶矩用来衡量不同轮廓或连通域的面积,hu 矩的一阶不变矩用来衡量两类图像的重心,hu 矩的二阶不变矩用来衡量两类图像的形状和方向。 d 表示初始显著图和对象概率图 3 个矩的平均差值,从 3 个方向约束显著性与目标性的统一,整合因子 d 平滑和优化了最终显著值,故最终结果为:

$$S^E(i) = e^{-d} \cdot S_{\text{int ra}}(i) + (1 - e^{-d}) \cdot s_{\text{int ra}}^{m \rightarrow n}(i). \quad (8)$$

表 1 图像的矩

Tab. 1 Moments of the image

矩	公式
标准矩	$m_{pq} = \sum_{y=1}^N \sum_{x=1}^M x^p y^q f(x, y), (p, q = 0, 1, 2, \dots)$
中心矩	$\mu_{pq} = \sum_{y=1}^N \sum_{x=1}^M (x - \bar{x})^p (y - \bar{y})^q f(x, y),$ $(p, q = 0, 1, 2, \dots)$
归一化中心矩	$\eta_{pq} = \mu_{pq} / (\mu_{00}^{\rho}), \rho = (p + q) / 2 + 1$
一阶不变矩	$M_1 = \eta_{20} + \eta_{02}$
二阶不变矩	$M_2 = (\eta_{20} - \eta_{02})^2 + 4\eta_{11}^2$

3 多层线性模型融合

通过上述阶段可以得到由图像 $m(m=1, \dots, N, m \neq n)$ 引导图像 n 的协同显著图,故对于图像 n 得到 $N-1$ 张不同的协同显著图。在融合阶段,本文提出一种多层线性模型,在下层自适应地融合第一阶段得到的一组协同显著性图,上层线性模型结合各个协同显著图的信息和当前任务的引导来调整下层的权重。即图像 n 的最终融合显著图由各个协同显著图加权和得到:

$$S_n(x) = \sum_{i=1}^{N-1} \omega_i S_{ni}(x), \quad (9)$$

其中: $S_n(x)$ 表示图像 n 的最终融合显著图, $S_{ni}(x)$ 表示第一阶段得到的图像 n 的各个协同显著性图。其中,为适应不同场景的任务, ω_i 是根据调制机制学习的自适应权重,其矩阵可以表示为:

$$\mathbf{W} = \begin{bmatrix} y_1^T \\ \vdots \\ y_N^T \end{bmatrix} \mathbf{R} = \begin{bmatrix} y_0^1 & y_1^1 & \cdots & y_{N-1}^1 \\ \vdots & \vdots & \ddots & \vdots \\ y_0^{N-1} & y_1^{N-1} & \cdots & y_{N-1}^{N-1} \end{bmatrix} \mathbf{R} = \mathbf{YR}, \quad (10)$$

其中: y 表示上层线性模型的参数,矢量矩阵 \mathbf{R} 表示从下层各个协同显著图中计算的低层信息,其值为: $r_i = \text{Dev}(S_i(x))$ 。将各个协同显著图抽取数据矩阵表示为:

$$\mathbf{X}_n = \begin{bmatrix} S_{n1}(x_1) & \cdots & S_{n(N-1)}(x_{N-1}) \\ \vdots & \ddots & \vdots \\ S_{n1}(x_M) & \cdots & S_{n(N-1)}(x_M) \end{bmatrix}, \quad (11)$$

其中 M 表示超像素。上层线性模型学习过程的输入数据表示为 $\{I_n(x), A_n(x)\}_{n=1}^N$, $I_n(x)$ 表示输入图像, $A_n(x)$ 表示真值图数据,令 $\mathbf{z}_n = [A_n(x_1), \dots, A_n(x_M)]$, 则式(9)可表示为 $\mathbf{z}_n = \mathbf{X}_n \mathbf{w}_n$ 。

利用最小二乘法进行求解,则权重矩阵可表示为:

$$\mathbf{w}_n = (\mathbf{X}_n^T \mathbf{X}_n + \alpha \mathbf{I})^{-1} \mathbf{X}_n^T \mathbf{z}_n. \quad (12)$$

上层线性模型根据学习的输入数据可表示为:

$$[\mathbf{w}_1, \dots, \mathbf{w}_N] = \mathbf{Y}[\mathbf{r}_1, \dots, \mathbf{r}_N]. \quad (13)$$

同理,用最小二乘法求解得到 \mathbf{Y} 可表示为:

$$\mathbf{Y} = \mathbf{WR}^T (\mathbf{RR}^T + \alpha \mathbf{I}). \quad (14)$$

4 实验部分

4.1 实验参数

本文算法在两个公共数据集上进行实验验证,其中,iCoseg 数据集^[15]是一个广泛用于协同显著性检测的大规模公开可用数据集。它由 38 个图像组(共 643 个图像)以及人工注释对比图组成。iCoseg 数据集中的每个图像组包含 4~42 个图像,且其中大多数图像都包含复杂的背景和多个同时显著的对象。因此,iCoseg 数据集被认为是协同显著性检测具有挑战性的数据集。MSRC 数据集^[16]由 8 个图像组(240 个图像)组成,具有手动标记的真实数据。与 iCoseg 数据集相比,MSRC 数据集的图像组中的协同显著性对象有不同的颜色和形状,更具挑战性。在第三阶段的多层线性模型调制过程中,选择 50%数据集的图像组来学习权重。

为了评估算法的性能,将本文算法和其它最先进的协同显著性检测方法进行了基于 4 个基本标准的比较,分别为:精度-召回率(Precision-Recall,P-R)曲线、F-measure 值、平均精度和运行

时间。显著性检测算法实验评估中 P-R 曲线是最常用的评价指标,计算准确率和召回率时,首先将显著图阈值化到 $[0,255]$ 之间,然后进行二值分割得到掩码图,掩码图和真值图进行比较得到准确率和召回率。

4.2 实验结果


为验证实验性能,OMLM 算法在两个数据集上与现有 6 种代表性协同显著性检测方法作对比实验。其分别为:CCS-S 算法^[17]、CCS 算法^[17]、SCS-S 算法^[18]、SCS 算法^[18]、SACS 算法^[19]、HS 算法^[20]。

图 3、图 4 和图 5 分别是 iCoseg 数据集和 MSRC 数据集上 OMLM 算法和其他算法的 P-R 曲线、F-measure 值和平均精度比较结果图,表 2 是每个图像的平均运行时间比较结果。


表 2 运行时间比较结果

Tab. 2 Comparison of running time

算法	CCS	SCS	SACS	HS	OMLM
运行时间/s	1.70	8.72	7.45	142.31	5.78



(a) iCoseg 数据集上 P-R 曲线比较
(a) Comparison of P-R curves on iCoseg



(b) MSRC 数据集上 P-R 曲线比较
(b) Comparison of P-R curves on MSRC

图 3 不同算法的 P-R 曲线比较

Fig. 3 Comparison of P-R curves of different algorithms

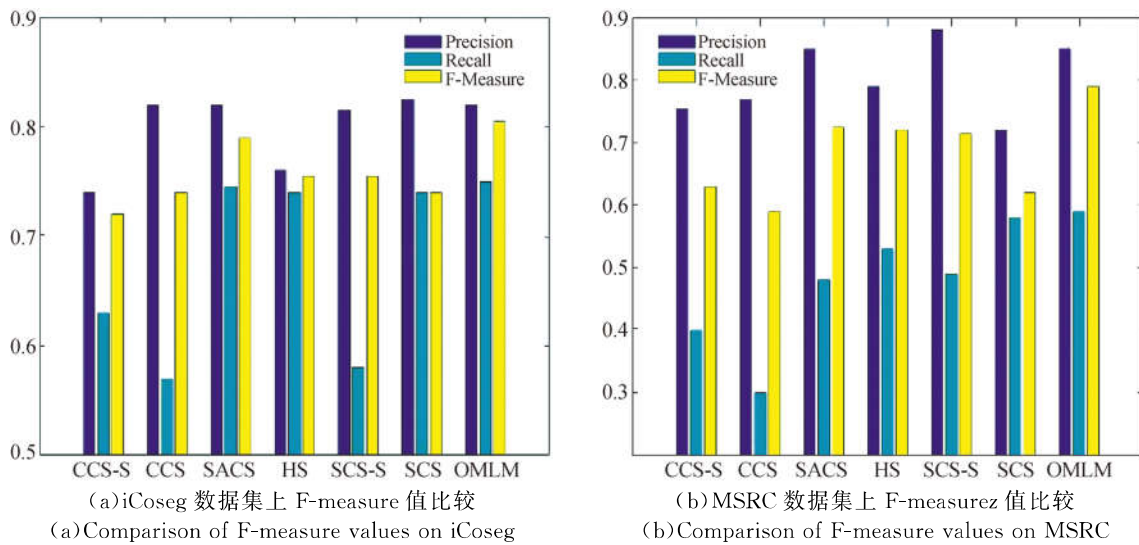


图 4 F-measure 值比较结果

Fig. 4 Comparison of F-measure values

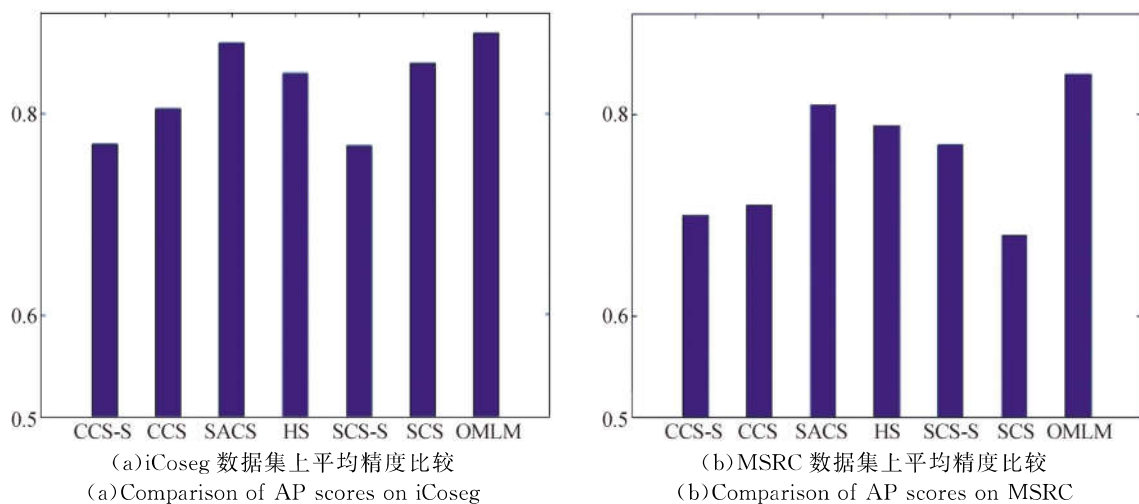


图 5 AP 分数比较结果

Fig. 5 Comparison of AP score

从上述 4 种标准的定量比较结果图中我们可以看出,在 iCoseg 数据集中的实验结果表明,OMLM 方法在保证召回率的同时提高了精度,表明 OMLM 方法能更好地权衡两者之间的关系,从 AP 得分比较结果图中也可以印证这一点。虽然在 iCoseg 数据集中 SACS 方法的表现效果也比较优异,但是在更加复杂的场景中,如第 2 个 MSRC 数据集中表现效果却有所下降。由于 MSRC 数据集中图像组所处场景更加复杂、挑战性大,算法在此数据集中的实验效果低于各种算法在 iCoseg 数据

集中的表现。OMLM 算法在此数据集中体现出了优势,在几个评价指标的评估下表现出更好的性能。从每个图像的平均运行时间比较结果来看,OMLM 算法运行时间较短、复杂度较低。

OMLM 算法在 iCoseg 数据集和 MSRC 数据集上的两组对比实验结果分别如图 6 和图 7 所示。对比实验结果中第 1~7 行分别表示:RGB 图像、CCS 算法实验结果、SACS 算法实验结果、SCS 算法实验结果、HS 算法实验结果、OMLM 算法实验结果及真值对比图。

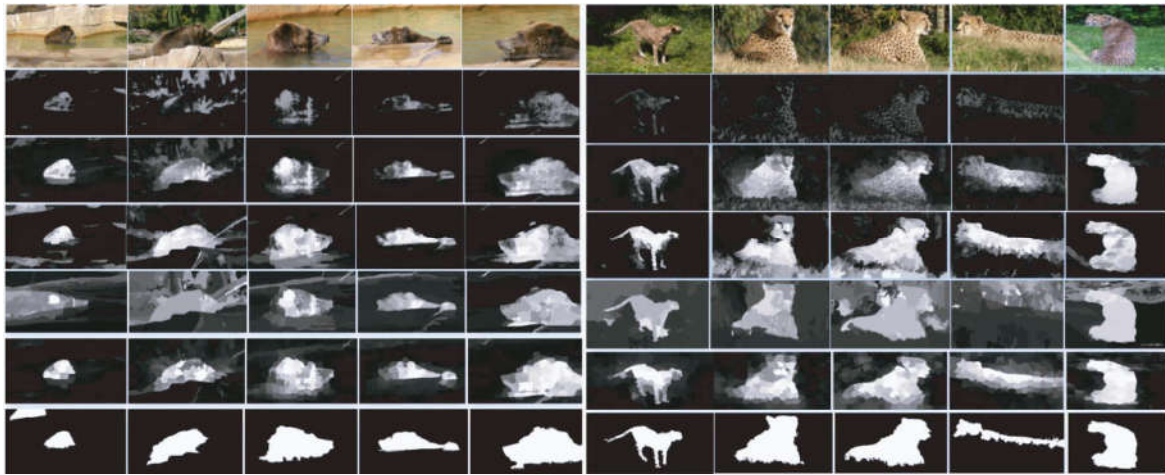


图 6 基于 iCoseg 数据集的对比实验结果

Fig. 6 Comparison experiment results based on iCoseg Dataset

图 6 展示了 iCoseg 数据集中两个图像组分别为熊和豹子的例子,熊和豹子在两组图片中展示的目标大小、形状和位置等都互不相同,图像组熊中每幅图像还存在相似的石头和水等的背景干扰,协同显著性目标检测具有挑战性。从实验结果图可以看出,CCS 方法不能很好地将显著目标的轮廓检测出来,而其他几种算法虽然能够大致地检测出熊的轮廓,但是由于背景信息太复杂,导致显著图中

检测出部分背景。本文算法在保证前景信息的同时较好地抑制了背景信息,体现出更加优异的效果。图像组豹子中表现效果与熊类似,由于每幅图像中都存在草的背景信息,且在中间 3 幅图像中枯草的颜色和豹子的身体颜色融为一体,故这几幅图像检测出的显著图中豹子轮廓不太清晰且边界稍混乱,本文算法较其他对比算法更好地突出了豹子的目标信息,抑制了复杂背景信息。

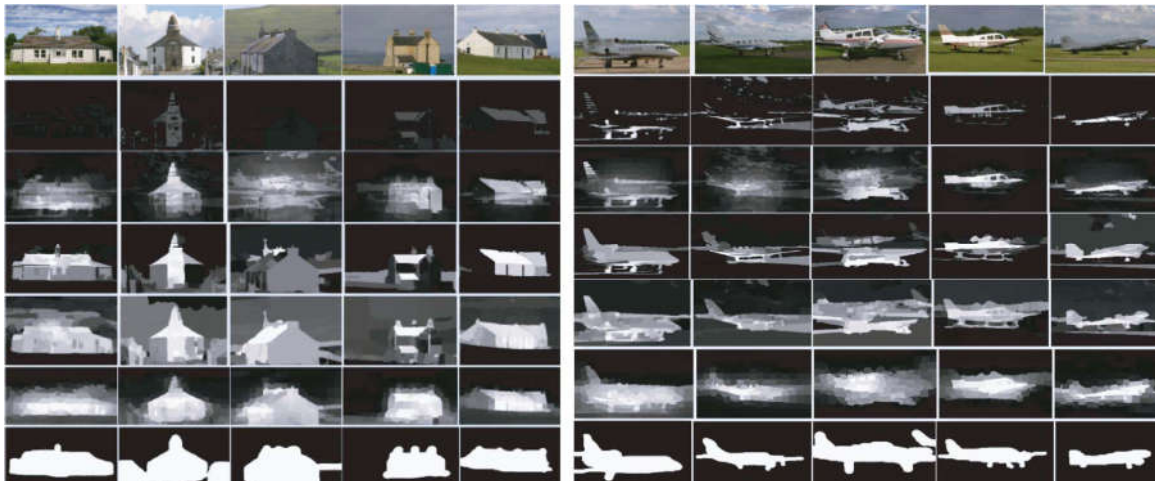


图 7 基于 MSRC 数据集的对比实验结果

Fig. 7 Comparison experiment results based on MSRC Dataset

图 7 分别展示了 MSRC 数据集中的房子和飞机两个图像组,这两个图像组中无论是房子和飞机都是不同外观、不同造型,且从拍摄的角度看房子和飞机都处于不同的尺度和视点等,图片的背景信息也更为复杂不一致,协同显著性目标检

测非常具有挑战性。从其他几种对比算法来看,几种算法都大致地高亮出了协同显著性目标,但是根据协同显著性检测算法的评价指标,显著物体本身应该一致的高亮。从显著图可以看出,飞机的窗户、框架和轮子等也都应该是高亮的,但由

于这种部位的颜色等信息属于接近背景颜色的暗色,所以几种对比算法检测的显著物体并没有一致的高亮,而本文算法检测的飞机更好地突出了整个显著性物体,更加接近真值标定结果。

5 结 论

本文提出了一种基于对象性和多层线性模型的图像协同显著性检测方法,利用显著性先验和对象性概率加权的背景引导因子来探索图像间显著性信息以突出协同显著性对象,准确检测出公

共对象。采用局部区域特征计算、图像的矩整合的方式来优化图像内显著性的检测,更好地抑制了背景信息,最后提出用多层线性模型自适应融合各个协同显著性图,增加了算法的鲁棒性,更加适应各种复杂场景。本文算法在 iCoseg 和 MSRC 两个公共数据集上验证了算法的有效性,在复杂场景的图像组中表现效果优异,但是从实验结果图来看,比如在 MSRC 数据集的飞机组例子中,检测的协同显著性对象的边界不够清晰、高亮部分不够一致,后续应该探索更多有效的信息来抑制背景信息以适应更加复杂的场景。

参考文献:

- [1] ZHANG D, FU H, HAN J, *et al.*. A review of co-saliency detection algorithms: fundamentals, applications, and challenges [J]. *Acm Transactions on Intelligent Systems & Technology*, 2018, 9(4): 1-31.
- [2] ZHANG D, MENG D, HAN J. Co-saliency detection via a self-paced multiple-instance learning framework [J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2017, 39(5): 865-878.
- [3] CHENG M M, MITRA N J, HUANG X, *et al.*. SalientShape: group saliency in image collections [J]. *The Visual Computer*, 2014, 30(4): 443-453.
- [4] 蔡强, 郝佳云, 曹健, 等. 结合局部特征及全局特征的显著性检测 [J]. *光学精密工程*, 2017, 25(3): 772-778.
CAI Q, HAO J Y, CAO J, *et al.*. Salient detection via local and global feature [J]. *Opt. Precision Eng.*, 2017, 25(3): 772-778. (in Chinese)
- [5] 丁鹏, 张叶, 贾平, 等. 基于多尺度多特征视觉显著性的海面舰船检测 [J]. *光学精密工程*, 2017, 25(9): 2461-2468.
DING P, ZHANG Y, JIA P, *et al.*. Ship detection on sea surface based on multi-feature and multi-scale visual attention [J]. *Opt. Precision Eng.*, 2017, 25(9): 2461-2468. (in Chinese)
- [6] LI H, MENG F, NGAN K N. Co-salient object detection from multiple images [J]. *IEEE Transactions on Multimedia*, 2013, 15(8): 1896-1909.
- [7] CHANG K Y, LIU T L, CHEN H T, *et al.*. Fusing generic objectness and visual saliency for salient object detection [C]. *International Conference on Computer Vision*. IEEE Computer Society, 2011: 914-921.
- [8] BORJI A, SIHITE D N, ITTI L. What/Where to look next? Modeling top-down visual attention in complex interactive environments [J]. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2014, 44(5): 523-538.
- [9] ZHAO Q, KOCH C. Learning a saliency map using fixated locations in natural scenes [J]. *Journal of vision*, 2011, 11(3): 1-9.
- [10] 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.
- [11] QIN Y, LU H, XU Y, *et al.*. Saliency detection via cellular automata [C]. *Computer Vision & Pattern Recognition*. IEEE, 2015: 110-119.
- [12] YE L, LIU Z, LI L, *et al.*. Salient object segmentation via effective integration of saliency and objectness [J]. *IEEE Transactions on Multimedia*, 2017: 1-1.
- [13] 宋策, 张葆, 宋玉龙, 等. 基于场景辅助特征的 T-S 目标跟踪 [J]. *光学精密工程*, 2018, 26(8): 2122-2131.
SONG C, ZHANG B, SONG Y L, *et al.*. T-S tracking algorithm based on context auxiliary feature [J]. *Opt. Precision Eng.*, 2018, 26(8): 2122-2131. (in Chinese)
- [14] 赵东波, 李辉. 基于中心矩特征和 GA-BP 神经网络的雷达目标识别 [J]. *红外与激光工程*, 2018, 47(8): 826005-0826005(7).
ZHAO D B, LI H. Radar target recognition based on central moment feature and GA-BP neural network [J]. *Infrared and Laser Engineering*,

- 2018, 47(8): 826005-0826005(7). (in Chinese)
- [15] BATRA D, KOWDLE A, PARIKH D, *et al.*. iCoseg: Interactive co-segmentation with intelligent scribble guidance[C]. *Computer Vision & Pattern Recognition*. IEEE, 2010: 3169-3176.
- [16] WINN J, CRIMINISI A, MINKA T. Object categorization by learned universal visual dictionary [C]. *Tenth IEEE International Conference on Computer Vision*. IEEE, 2005:1800-1807.
- [17] FU H, CAO X, TU Z. Cluster-based co-saliency detection [J]. *IEEE Transactions on Image Processing A Publication of the IEEE Signal Processing Society*, 2013, 22(10):3766-3778.
- [18] LI Y, FU K, LIU Z, *et al.*. Efficient saliency-model-guided visual co-saliency detection [J]. *IEEE Signal Processing Letters*, 2014, 22(5): 588-592.
- [19] 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.
- [20] LIU Z, ZOU W, LI L, *et al.*. Co-saliency detection based on hierarchical segmentation [J]. *IEEE Signal Processing Letters*, 2013, 21(1):88-92.

作者简介:



金志刚(1972—),男,天津人,教授,博士生导师,天津市政府决策咨询专家,曾任天津大学网络中心总工程师,天津大学计算机系副主任,主要从事机器学习、水下网络、社交网络等方面的研究。
E-mail:zgjin@tju.edu.cn



李静昆(1994—),女,河北石家庄人,硕士研究生,主要从事机器视觉、图像处理方面的研究。E-mail: ljk_smile_girl@163.com