

# 基于稀疏恢复与优化的显著性目标检测算法

王 军<sup>1</sup> 吴泽民<sup>1</sup> 杨 巍<sup>2</sup> 胡 磊<sup>1</sup> 张兆丰<sup>3</sup> 姜青竹<sup>4</sup>

(中国人民解放军陆军工程大学通信工程学院 南京 210007)<sup>1</sup>

(中船重工集团公司第七二二研究所 武汉 430079)<sup>2</sup> (中国人民解放军 61428 部队 北京 100071)<sup>3</sup>

(中国人民解放军 95980 部队 湖北 襄阳 442101)<sup>4</sup>

**摘 要** 针对目前基于稀疏表示的显著性检测算法中存在的边界显著性检测不足、字典表达能力不够等问题,提出一种基于稀疏恢复与优化的检测算法。首先对图像进行滤波平滑和超像素分割,并从边界与内部超像素中挑选可靠的背景种子构建稀疏字典;然后基于该字典对整幅图像进行稀疏恢复,根据稀疏恢复误差生成初始显著图;再运用改进的基于聚类的二次优化模型对初始显著图进行优化;最后经过多尺度融合得到最终显著图。在三大公开测试数据集上的实验结果表明,所提算法能够保持高效快速、无训练等优点,同时性能优于目前主流的非训练类算法,在处理边界显著性方面表现优异,具有较强的鲁棒性。

**关键词** 显著性检测,稀疏恢复,显著性优化

**中图分类号** TP393 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2018.08.046

## Salient Object Detection Algorithm Based on Sparse Recovery and Optimization

WANG Jun<sup>1</sup> WU Ze-min<sup>1</sup> YANG Wei<sup>2</sup> HU Lei<sup>1</sup> ZHANG Zhao-feng<sup>3</sup> JIANG Qing-zhu<sup>4</sup>

(College of Communications Engineering, Army Engineering University of PLA, Nanjing 210007, China)<sup>1</sup>

(No. 722 Research Institute, China Shipbuilding Industry Corporation, Wuhan 430079, China)<sup>2</sup>

(The 61428th Troops of the PLA, Beijing 100071, China)<sup>3</sup> (The 95980th Troops of the PLA, Xiangyang, Hubei 442101, China)<sup>4</sup>

**Abstract** In view of the issues of boundary ambiguity and low detection accuracy in current saliency detection algorithms which employ sparse representation, this paper proposed a new saliency detection algorithm based on sparse recovery and optimization. Firstly, the RG filter is used to smooth the image. Then, the SLIC algorithm is used to segment the image, and the reliable background seed is selected from the boundary and the inside super pixel block is chosen to construct the dictionary. Based on the dictionary, the sparse recovery of the whole image is achieved, and the initial saliency map is generated according to the sparse recovery error. After that, the modified optimization model is used to optimize the initial saliency map. Finally, the final saliency map is obtained through multiscale fusion. Experimental results on three public benchmark datasets show that the performance of the proposed algorithm is superior to the current state-of-the-art methods. Meanwhile, it performs well in dealing with boundary saliency and has strong robustness.

**Keywords** Saliency detection, Sparse recovery, Saliency optimization

## 1 引言

随着信息技术的不断发展和多媒体数据的快速增长,人们已经拥有大量的文档、图像、视频等丰富的数据资源。现在人们对数码设备以及大容量存储设备比以往有更加迫切的需求,图像数据也因此出现了前所未有的增长速度。在人们搜索大量信息的同时,信息冗余成为了一个难题。因此,快速、

准确地在大量的数字图像信息中找到与任务相关的图像信息成为计算机信息处理领域的一个热门研究方向。研究者很早就发现了人类视觉系统的选择性注意机制,即在观看大量图像、视频时,人类视觉系统(Human Visual System, HVS)通常只会重点关注整个场景中的一部分,而对其余部分几乎不作处理<sup>[1]</sup>。这些被重点关注的部分就是显著性区域。人们试图构建有效的显著性检测方法来模拟这种机制,以从图像、视频

到稿日期:2017-10-19 返修日期:2018-01-21

王 军(1995—),男,硕士生,主要研究方向为图像与视频的显著性检测;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, E-mail: wuzemin\_ice@163.com(通信作者);杨 巍(1983—),男,博士,主要研究方向为数据链消息处理;胡 磊(1987—),男,博士,讲师,主要研究方向为压缩感知、目标跟踪;张兆丰(1991—),男,硕士,主要研究方向为图像处理;姜青竹(1987—),男,硕士,主要研究方向为视频传输保障。

中提取关键信息,从而简洁、有效地表达图像内容。显著性检测作为一种预处理方法,在计算机视觉领域得到了广泛的应用,包括图像分割<sup>[2]</sup>、图像检索<sup>[3]</sup>、目标识别<sup>[4]</sup>、图像分类<sup>[5]</sup>、图像和视频压缩<sup>[6]</sup>等领域。

## 2 研究现状及存在问题

从观察者的角度来看,显著性刻画了一个场景中某些部分(完整的目标或局部的区域)区别于其他部分的程度。显著性检测算法通常分为眼动点预测和显著性目标检测两种。从 Itti 于 1998 年提出第一个可计算的显著性模型<sup>[7]</sup>到 2007 年是显著性检测算法的第一个发展阶段,重点研究眼动点预测模型,其中包括经典的 FG<sup>[8]</sup>, LC<sup>[9]</sup>, GB<sup>[10]</sup> 以及 SR<sup>[11]</sup> 算法。相对于眼动点预测模型,显著目标检测通常要计算出目标的轮廓形状,也就是将整个显著的目标都检测出来。自 Liu 等<sup>[12]</sup>提出一种学习型的算法来进行显著性目标检测并给出第一个测试数据集以来,涌现出了大批有效的检测算法。

稀疏表示作为图像信息表达的有力工具,在计算机视觉领域中得到了广泛的应用。如何把稀疏表示理论有效地应用到显著性检测问题中的关键是字典的表达,即如何表示字典中的基。字典中的基能否包含足以表达样本的信息,关系到稀疏表示的精度与稀疏度。按照稀疏表示理论,要求字典中的基满足一定的不相关条件,在计算机视觉应用中,常根据图像样本构造基于特殊任务的字典,通常认为字典的基可以具有一定的冗余性。

在基于稀疏表示的显著性检测算法中,字典的构造方法一般有两种:1)基于训练的方法。如文献[13-15]从大量的自然图像块中学习到一个完备字典,然后用该字典来表达任意一幅图像,再基于编码系数或者重构误差来度量显著性的大小。但是该方法没有将图像表示灵活地运用到显著性估计的模型框架中,也没有合理且有效地运用待测图像本身的视觉信息。2)针对待检测显著目标的图像自身构建字典的方法。文献[16-17]首先在一个局部范围内用周围图像块作为字典来重构中心图像块,然后用重构误差或者重构误差联合稀疏编码系数的长度来定义图像的显著性。但是,一个块与其字典周围的块往往很相似,这导致较大目标的内部区域不能够被检测为显著区域。文献[18-20]利用图像的边界超像素块构建字典以对图像进行稀疏重构,再基于重构误差计算图像的显著性,但是如果显著性目标位于图像边界,会导致检测失效。

另一方面,为了提高检测精度,保留较好的轮廓信息,很多算法都引入了显著图优化模型,如 Lu 等人提出的二次优化模型<sup>[26]</sup>、Jiang 等人提出的随机游走模型<sup>[39]</sup>、Yang 等人提出的流形排序模型<sup>[40]</sup>等。但在较复杂场景下,这些优化模型的性能往往有限。

针对上述问题,本文提出了一种新的基于稀疏恢复与优化的显著性目标检测算法。为了构造能更好表达图像显著性的字典,本文基于边界连通度(Boundary Connectivity, BC)<sup>[21]</sup>这一评价指标来挑选可靠的背景种子作为字典中的原子。基于该字典对整幅图像进行稀疏恢复,并以稀疏恢复误差来预测每个图像块的显著性。为了使最终显著图更加平滑与连

续,本文对 Lu 等的二次优化模型加以改进,对初始显著图进行优化,最后经过多尺度融合得到最终的显著图。实验结果表明,本文所构建的字典能更好地表达图像的显著性信息,改进后的优化模型具有更好的优化性能。所提算法在三大公开数据集上均有优异的表现,具有较强的鲁棒性。

## 3 字典的构建

### 3.1 图像预处理及其表示

为了提高计算效率,目前很多算法<sup>[18-20]</sup>都基于超像素块对图像进行处理。本文借鉴其思路,继续采用 SLIC 算法<sup>[23]</sup>对图像进行分割以形成紧密的超像素块。但是为了抑制和弱化原图中的纹理细节,克服由噪声或纹理产生的局部灰度级细微变化对超像素分割的影响,本文在超像素分割之前,先对原图进行 RG 滤波<sup>[24]</sup>,然后用每一个超像素内所包含的所有像素点在 CIE-Lab 空间的平均颜色特征  $c_i$  与平均位置特征  $p_i$  上来表示该图像块:

$$c_i = [L, a, b] \quad (1)$$

$$p_i = [x_i, y_i] \quad (2)$$

其中,  $L, a, b$  表示超像素块所含像素点在 CIE-Lab 颜色空间的平均颜色特征;  $x_i$  和  $y_i$  表示超像素块所含像素点的平均位置。这样,每个超像素块可以表示为:  $x_i = [c_i, p_i]$ , 图像  $I$  可以表示为:

$$I = [x_1, x_2, \dots, x_N] \in R^{D \times N} \quad (3)$$

其中,  $D$  表示特征的维度,  $N$  表示分割后形成的超像素块的个数。

### 3.2 字典原子的选择

与传统的基于大量自然图像训练字典或者直接以图像边界上所有超像素块作为字典的做法不同,在构建字典之前,本文首先对每个超像素块的背景概率进行预测:

$$p_b(x_i) = 1 - \exp\left(-\frac{BC^2(x_i)}{2\sigma^2}\right) \quad (4)$$

其中,  $\sigma$  为控制参数,根据经验  $\sigma$  取 1;  $BC(x_i)$  表示超像素块  $x_i$  的边界连通度,被定义为:

$$BC(x_i) = \frac{Len_{bnd}(x_i)}{\sqrt{Area(x_i)}} \quad (5)$$

其中,  $Area(x_i)$  表示与超像素  $x_i$  特征相近的连通区域的面积,  $Len_{bnd}(x_i)$  表示连通区域与边界相交的长度。式(5)表示,一个超像素块的边界连通度越大,其属于背景的概率就越高。

我们从以下两条线索出发选择构建字典的原子:1)以图像边界为线索。根据图像边界大多属于背景这一先验知识,同时考虑到部分图像的显著目标会与边界接触,本文对所有边界超像素块的背景概率大小进行平均,取背景概率大于均值二分之一的边界超像素作为字典的原子。2)以图像内部为线索。在一幅图像中,背景并不是一成不变的,因此仅仅以边界处的超像素块作为背景字典是不够的,有必要从图像内部挑选元素以构建背景字典。在实验中,从图像内部选择背景概率较高的 15% 的超像素块与线索 1) 中边界处的超像素块一起构成用于显著性检测的字典  $D$ 。构建字典的示意图如图 1 所示,图中用灰度点标注的部分为选中作为字典原子的超像素块。




图 1 字典构造示意图

Fig. 1 Dictionary construction

### 4 显著性计算

#### 4.1 基于稀疏恢复误差的初始显著性计算

基于背景字典  $D$ , 本文可以运用 Lasso 算法<sup>[25]</sup> 求得图像  $I$  中每个超像素  $x_i$  的稀疏恢复系数向量  $\alpha_i$ :

$$\alpha_i = \arg \min_{\alpha_i} \|x_i - D\alpha_i\|_2 + \lambda \|\alpha_i\|_1 \quad (6)$$

其中,  $\alpha_i$  为超像素块  $x_i$  在字典  $D$  上的稀疏恢复系数向量。式 (6) 第一项表示图像块的稀疏恢复误差, 第二项表示稀疏约束项, 要求稀疏恢复系数尽可能有较多的元素接近于 0。  $\lambda$  为平衡因子, 文中取 0.01。可以求得该超像素在背景字典上的稀疏恢复误差为:

$$\epsilon_i = \|x_i - D\alpha_i\|_2 \quad (7)$$

最终可以得到整幅图像的稀疏恢复误差:

$$E_i = [\epsilon_{i_1}, \epsilon_{i_2}, \dots, \epsilon_{i_N}] \quad (8)$$

根据稀疏表示的相关理论可知, 对于图像  $I$  中属于显著性目标的元素, 其特征与背景字典中的原子相差较大, 因此稀疏恢复误差较大。而背景部分的特征与字典中的原子相对一致, 其恢复误差较小。因此, 我们通过稀疏恢复误差来计算每个超像素块的显著性大小, 从而得到整幅图像的显著性:

$$S = [\epsilon_{i_1}^*, \epsilon_{i_2}^*, \dots, \epsilon_{i_N}^*] \quad (9)$$

$$\epsilon_{i_j}^* = \frac{\epsilon_{i_j} - \epsilon_{i_{\min}}}{\epsilon_{i_{\max}} - \epsilon_{i_{\min}}} \quad (10)$$

其中,  $\epsilon_{i_{\min}}$  表示稀疏恢复误差  $E_i$  中的最小值,  $\epsilon_{i_{\max}}$  表示  $E_i$  中的最大值。

#### 4.2 基于二次能量模型的显著性优化

由于重构误差的计算是基于超像素块进行的, 因此误差结果容易受到图像过分割的影响, 导致显著图不连续。文献 [26] 提出一种二次能量模型来对显著图进行优化, 能量函数的定义为:

$$F = \beta \sum_{i \in N} (y_i - s_i)^2 + \sum_{i, j \in N} \omega_{i, j} (y_i - y_j)^2 \quad (11)$$

其中,  $s_i$  为超像素块的初始显著度; 参数  $\beta$  用于权衡两者的影响, 文中取 0.5;  $\omega_{i, j}$  为相邻区域的相似度权重, 定义如下:


$$\omega_{i, j} = \begin{cases} \exp\left(-\frac{\|c_i - c_j\|^2}{2\sigma^2}\right), & j \in N(i) \\ 0, & i = j \text{ or } j \notin N(i) \end{cases} \quad (12)$$

其中,  $N(i)$  的范围包括空间直接相邻、二阶相邻, 如图 2 所示。但是式 (11) 优化模型本身具有一定的局限性, 当背景较为复杂或者显著性目标与背景区域的颜色特征比较相似时, 优化效果不是很理想。为了提高优化效果, 本文运用中层聚类算法<sup>[31]</sup> 对原始超像素块做进一步的聚类; 然后在计算超像素块之间的相似度权重时, 将原来的颜色空间扩展到了颜色和

距离两个空间。改进后的优化模型的相似度权重的定义如下:

$$\omega_{i, j}^* = \begin{cases} \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right) + \eta\delta, & i, j \in \Omega, j \in N(i) \\ 0, & i = j \text{ or } j \notin N(i) \end{cases} \quad (13)$$

其中,  $\Omega$  表示一个子类,  $\delta(i, j \in \Omega)$  表示超像素块  $x_i$  和  $x_j$  是否属于同一个子类。  $\eta$  为控制权重, 文中取 1。改进后的优化模型使得在显著性传播时, 属于同一个子类的超像素块之间的影响变大, 而不属于同一个子类之间的超像素块的影响变小。改进的优化模型相似度权重的可视化示例如图 2 所示, 图 2(a) 为原优化模型, 图 2(b) 为改进后的优化模型。其中一阶相邻点和二阶相邻点分别以浅色圆点和深色圆点标出。改进后的优化模型影响权值变大的地方用加粗标记。



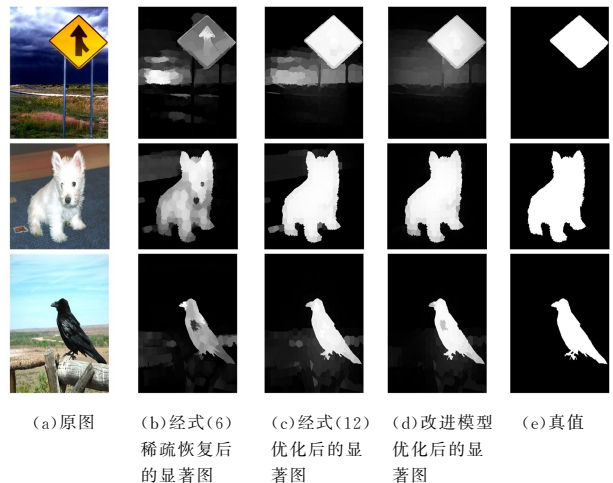
(a) 原优化模型

(b) 改进后的优化模型

图 2 改进的优化模型相似度权重的可视化示例

Fig. 2 Illustration of similarity weight in new optimization model

为进一步说明改进后的优化模型的有效性, 图 3 给出了几个示例。其中图 3(a) 表示待检测图像; 图 3(b) 表示经过稀疏恢复计算的初始显著图; 图 3(c) 表示由原始优化模型优化后的结果; 图 3(d) 表示本文改进后的优化模型的优化结果; 图 3(e) 表示人工标注的真值。由此可见, 改进后的优化模型所产生的显著图中背景噪声更小, 与真值图更加接近。



(a) 原图

(b) 经式 (6) 稀疏恢复后的显著图

(c) 经式 (12) 优化后的显著图

(d) 改进模型优化后的显著图

(e) 真值

图 3 显著图优化结果对比示例

Fig. 3 Comparison of saliency optimization results

#### 4.3 多尺度融合

显著性目标往往具有不同的尺度规模, 为了提高检测精度, 我们对原始图像在  $M$  个尺度下进行超像素分割, 在每个分割尺度下分别计算显著性, 一共得到  $M$  个子显著图  $\{S_i\}_{i=1}^M$ 。最后, 经过线性加权融合得到最终的显著图:

$$S = \sum_{i=1}^M \alpha_i \cdot S_i \quad (14)$$

其中,  $\alpha_i$  为融合系数, 文中取  $\alpha_i = 1/M$ 。图 4 分别给出了 3 个

不同分割尺度([100,10],[200,20],[300,30])下得到的显著图(见图 4(b)、图 4(c)、图 4(d))以及经过融合后得到的最终显著图(见图 4(e))。可以看出,由于受到图像过分割的影响,单一尺度下的显著图在局部区域内的显著性表现得不是很连续。而经过多尺度融合后,每个区域的显著性都得到了强化,从而使得整体显著图更加平滑连续。实验部分将进一步说明本文所采用的线性加权融合方法的有效性。




图 4 单一分割尺度下的显著图与多尺度融合的结果对比  
Fig. 4 Comparison between saliency maps under different segmentation scales and results after multiscale's fusion

本文算法的流程如算法 1 所示。

**算法 1** 基于稀疏恢复与优化的显著性目标检测算法

输入: 图像 I

输出: 显著图 S

1. 对图像 I 进行 RG 滤波;
2. 使用 SLIC 算法将图像 I 分割为超像素块集  $X = \{x_i\}_{i=1}^N$ ;
3. 预测每个超像素块属于背景的概率大小;
4. 从图像边界与内部线索出发, 挑选背景概率较高的超像素构建背景字典 D;
5. 基于背景字典对超像素集  $X = \{x_i\}_{i=1}^N$  进行稀疏恢复;
6. 根据稀疏恢复误差预测每个超像素块的显著值;
7. 基于改进的二次能量模型对初始显著性进行优化, 得到子显著图  $S_i$ ;
8. 分别在 M 个分割尺度下重复步骤 2-步骤 7, 得到 M 个子显著图  $\{S_i\}_{i=1}^M$ ;
9. 多尺度加权融合得到最终显著图 S;
10. end.

**5 实验结果与分析**

**5.1 实验设置**

测试数据集: 本文在 3 个数据集 ASD<sup>[32]</sup>, MSRA 5000<sup>[33]</sup>, SED2<sup>[34]</sup> 上测试各算法。ASD 包含 1000 张图片, 大部分图像为单一目标, 其使用最为广泛, 且相对简单; MSRA5000 包含 5000 张图片, 有很多复杂的背景和位于边界的目标, 具有一定的挑战性; SED2 包含 100 张图片, 每张图片有两个目标, 并且大多数目标位于边界上, 挑战难度很大。

比较算法: 主要包括经典算法 GB<sup>[10]</sup>, SR<sup>[11]</sup>, PCA<sup>[12]</sup>; 基于稀疏表示的典型算法 DSR<sup>[13]</sup>; 基于稀疏矩阵分解的典型算法 LR<sup>[28]</sup>, RPCA<sup>[29]</sup> 以及近年来优秀的基于背景优先的算法 BFS<sup>[20]</sup>, RBD<sup>[21]</sup>, BSCA<sup>[22]</sup>。

需要注意的是, 近年来也出现了很多优秀的基于深度学习的显著性目标检测算法, 如 MDF<sup>[35]</sup>, DCL<sup>[36]</sup>, DHSNet<sup>[37]</sup>, AMUlet<sup>[38]</sup> 等, 但是这些算法往往需要在大数据库上进行训练才能得到可靠的模型, 而且有的深度模型往往在某些特定

的数据库上的表现很好, 而在其他数据库上的表现不是很理想。本文所提算法是一种基于非训练类的检测算法, 因此对比算法只列举了本领域内比较经典的几种算法和近年来比较优秀的基于非训练类的算法。

评估指标: 本文采用 P-R 曲线(精度-召回率)、F-measure, ROC 曲线下的面积(Area Under ROC Curve, AUC)和平均绝对误差(Mean Absolute Error, MAE)进行算法评估。P-R 曲线通过 [0, 255] 滑动阈值对每个显著图进行二值化, 与真值进行对比求得相应的精度(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来对图像进行二值化, 然后求得精度和召回率。

$$F\text{-measure} = \frac{(1 + \beta^2) \cdot \text{Precision} \cdot \text{Recall}}{\beta^2 \cdot \text{Precision} + \text{Recall}} \quad (15)$$

F-measure 实质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, 因此一般取  $\beta^2 = 0.3$  以强调精度。

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:


$$MAE = \frac{1}{W \times H} \sum_{x=1}^W \sum_{y=1}^H |S(x, y) - G(x, y)| \quad (16)$$

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, 而没有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 则对这些区域比较敏感, 更加强调与目标真值的接近程度。在实验中, 为使算法简洁高效, 设置多尺度融合中的 M 值为 3。

**5.2 本文优化算法的性能分析**

由于本文算法涉及稀疏恢复与优化两个主要步骤, 因此分析了本文算法每一步的性能。图 5 和表 1 给出了本文的稀疏恢复算法(本文算法的第一步), 以及改进的优化算法在 ASD 数据集上的 P-R 曲线和 F-measure 值。为了说明本文改进模型的有效性, 与文献[26]中优化算法的性能进行对比。

可以看出, 改进后的优化算法在精度上有较大提升, 整体 F-measure 值相对于原始优化算法有较大提高。



注: SPR 为基于稀疏恢复的算法的 P-R 曲线图, 1 为经原始优化模型<sup>[26]</sup>优化后的 P-R 曲线图, 2 为经改进模型优化后的 P-R 曲线图

图 5 ASD 数据集上算法性能对比

Fig. 5 Comparison of algorithms performance on ASD dataset

表 1 优化算法改进前后的性能对比

Table 1 Performance comparison between modified model and original model

	Precision	Recall	F-measure
SPR	0.8739	0.8279	0.8500
1	0.8854	0.9090	0.8795
2	0.9031	0.9018	0.8936

为了说明本文提出的多尺度融合的有效性,图 6 给出了单一分割尺度下以及多尺度融合后的算法在 ASD 图库上的性能对比。





图 6 多尺度融合算法性能比较

Fig. 6 Performance comparison of multi-scale fusion algorithms under different segmentation scales


图 6 分别给出了算法在 [100, 10], [200, 20], [300, 30] 3 个分割尺度下的性能以及经过加权融合后算法的性能。其中,Scale1 为 [100, 10] 分割尺度下的算法性能;Scale2 为 [200, 20] 分割尺度下的算法性能;Scale3 为 [300, 30] 分割尺度下的算法性能;MultiS 为多尺度融合后的算法性能。由图 6 可知,随着分割尺度变细,算法性能有所提升,经过多尺度融合后,算法性能得到进一步提升。

5.3 与其他算法的性能对比

图 7—图 9 给出了本文算法和其他算法在三大数据集上的 P-R 曲线与 F-measure 直方图的对比。




(a)P-R 曲线




(b)F-measure 直方图

图 7 各算法在 ASD 数据集上的性能对比

Fig. 7 Performance comparison of different algorithms on ASD datasets




(a)P-R 曲线




(b)F-measure 直方图

图 8 各算法在 MSRA5000 数据集上的性能对比

Fig. 8 Performance comparison of different algorithms on MSRA5000 datasets



(a)P-R 曲线



(b)F-measure 直方图

图 9 各算法在 SED2 数据集上的性能对比

Fig. 9 Performance comparison of different algorithms on SED2 datasets

表 2 不同算法的 MAE 值比较

Table 2 Comparison of MAE values of different algorithms

	SR	GB	RPCA	PCA	LR	BFS	DSR	BSCA	RBD	Ours
ASD	0.2299	0.2289	0.2090	0.1552	0.1885	0.1285	0.0809	0.0855	<b>0.0659</b>	<b>0.0549</b>
MSRA	0.2422	0.2411	0.2265	0.1889	0.2215	0.1666	0.1204	0.1312	<b>0.1106</b>	0.1201
SED2	0.2250	0.2436	0.2284	0.2015	0.2374	0.1699	0.1388	0.1632	<b>0.1301</b>	<b>0.1307</b>

注:最好的两种算法分别用加粗与下划线标记

表 3 不同算法的 AUC 值比较

Table 3 Comparison of AUC values of different algorithms

	SR	GB	RPCA	PCA	LR	BFS	DSR	BSCA	RBD	Ours
ASD	0.7651	0.8858	0.8994	0.9702	0.9584	0.9702	<b>0.9792</b>	0.9783	0.9702	<b>0.9810</b>
MSRA	0.7553	0.8711	0.8724	0.9481	0.9238	0.9481	<b>0.9530</b>	<b>0.9533</b>	0.9481	0.9527
SED2	0.8193	0.8441	0.8536	0.9157	0.8869	0.9157	<b>0.9172</b>	0.8965	0.9157	<b>0.9441</b>

注:最好的两种算法分别用加粗与下划线标记

图 10 展示了上述 10 种检测模型最终生成的显著图。我们选择其中比较典型的样本加以说明。对于第 2 个检测样本,背景较复杂,图像边界存在干扰目标,LR,PCA,RBD,BSCA 算法的检测结果均存在不同程度的背景噪声,而 BFS,DSR 等算法的检测结果不全。对于第 4 个和第 5 个检测样本,显著性目标与图像的两个边界均有接触,部分基于背景优先的算法出现了检测失效或检测结果不明显等问题。第 6—9 个检测样本均存在两个显著性目标,而且与图像边界有不同程度的接触。尤其是第 9 个检测样本,光线较暗,显著性目标与背景区别不是很大,BSCA,RBD,DSR 等优秀的检测算法均检测失效。而本文检测模型在上述几个场景中均成功检测出完整的显著性目标且噪声极小,表现出了较强的鲁棒性。




图 10 各种算法的检测结果对比

Fig. 10 Comparison of detection results of different algorithms

**结束语** 针对目前基于稀疏表示的显著性检测算法中存在的边界显著性检测不足、字典表达显著性能力不够等问题,本文基于边界连通度这一指标从图像边界与内部两条线索出发选择可靠的背景元素构建字典,有效地解决了边界显著性检测不足的问题。同时本文所提出的字典构建方法无需训练,简单高效。为了使最终显著图更加平滑与连续,提升检测效果,本文在现有的优化模型的基础上进行了改进,实验结果表明,改进后的优化模型在目标背景复杂等情况下能够取得更好的效果。在三大公开数据集上的测试结果表明,本文所提算法在不同场景下均具有优异的表现,鲁棒性较强。

### 参 考 文 献

[1] RENSINK R, O' REGAN K, CLARK J. To see or not to see: The need for attention to perceive changes in scene[J]. *Psychological Science*, 1997, 8(5): 368-373.

[2] DONOSER M, URSCHLER M, HIRZER M, et al. Saliency driven total variation segmentation[C]// *IEEE International Conference on Computer Vision (ICCV)*. Xi'an, China, 2009: 817-824.

[3] GAO Y, SHI M, DACHENG T F, et al. Database saliency for fast image retrieval[J]. *IEEE Transactions on Multimedia*, 2015, 17(3): 359-369.

[4] RUTISHAUSER U, WALTHER D, KOCH C, et al. Is bottom-

up attention useful for object recognition? [C]// *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Washington DC, USA: IEEE, 2004: 37-44.

[5] SHARMA G, JURIE F, SCHMID C. Discriminative spatial saliency for image classification[C]// *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Rhode Island, USA, 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] ITTI L, KOCH C, NIEBUR E. A model of saliency-based visual attention for rapid scene analysis[J]. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 1998, 20(11): 1254-1259.

[8] MA Y, ZHANG H. Contrast-based image attention analysis by using fuzzy growing[C]// *Proceedings of ACM Multimedia*. 2003: 374-379.

[9] ZHAI Y, SHAH M. Visual attention detection in video sequences using spatiotemporal cues[C]// *Proceedings of ACM Multimedia*. 2006: 815-824.

[10] HAREL J, KOCH C, PERONA P. Graph-based visual saliency [C]// *Proceedings of Neural Information Processing Systems*. 2006: 545-552.

[11] HOU X, ZHANG L. Saliency detection: a spectral residual approach[C]// *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Portland, USA, 2007: 801-808.

[12] LIU T, SUN J, ZHENG N, et al. Learning to detect a salient object[C]// *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Minneapolis, USA, 2007: 1-8.

[13] HOU X, ZHANG L. Dynamic visual attention: Searching for coding length increments[J]. *Advances in Neural Processing System*, 2008, 21: 681-688.

[14] LAI J, MAI X. Saliency detection: Image Saliency detection with sparse representation of learnt texture atoms[C]// *IEEE International Conference on Computer Vision Workshop*. 2015.

[15] BORJI A, ITTI L. Exploiting Local and Global Patch Rarities for Saliency Detection[C]// *Proceeding of IEEE Conference on Computer Vision and Patter Recognition*. 2012: 478-485.

[16] LI Y, ZHOU Y, XU L, et al. Incremental sparse saliency detection[C]// *Proceedings of IEEE International Conference on Image Processing*. 2009: 3093-3096.

[17] HAN B, ZHU H, DING Y D. Bottom-up Saliency based on weighted sparse coding residual[C]// *Proceeding of ACM International Conference on Multimedia*. 2011: 1117-1120.

[18] LI X, LU H, ZHANG X, et al. Saliency detection via dense and sparse reconstruction[C]// *IEEE International Conference on Computer Vision*. 2013: 2976-2983.

[19] JIA C, QI J, LI X, et al. Saliency detection via a unified generative and discriminative model[J]. *Neurocomputing*, 2016, 173 (P2): 406-417.

[20] WANG J, LU H, TONG N, et al. Saliency Detection via Background and Foreground Seed Selection [J]. *Neurocomputing*, 2015, 152(C): 359-268.

- [8] YU G F, ZOU S W, QIN C. Application Research of Image Gray Information in Automatic Separation of Coal and Gangue[J]. *Industry and Mine Automation*, 2012, 38(2): 36-39. (in Chinese)  
于国防, 邹士威, 秦聪. 图像灰度信息在煤矸石自动分选中的应用[J]. *工矿自动化*, 2012, 38(2): 36-39.
- [9] ZHANG F Z, ZHAO R Z, CEN Y G, et al. Adaptive Sparse Recovery Based on Difference Algorithm [J]. *Journal of Computer-Aided Design and Computer Graphics*, 2015, 27(6): 1047-1052. (in Chinese)  
张凤珍, 赵瑞珍, 岑翼刚, 等. 基于差分的稀疏度自适应重构算法[J]. *计算机辅助设计与图形学学报*, 2015, 27(6): 1047-1052.
- [10] WANG Y, ZHOU C, XIONG C Y, et al. Enhanced Block Compressed Sensing of Images Based on Total Variation Using Texture Information[J]. *Computer Science*, 2016, 43(2): 307-315. (in Chinese)  
王玥, 周城, 熊承义, 等. 基于纹理自适应全变分滤波的图像分块压缩感知优化算法[J]. *计算机科学*, 2016, 43(2): 307-315.
- [11] CAI X, XIE Z G, HUANG H W, et al. An Adaptive Reconstruction Algorithm for Image Block Compressed Sensing Under Low Sampling Rate [J]. *Journal of Chinese Mini-Micro Computer Systems*, 2016, 37(3): 612-616. (in Chinese)  
蔡旭, 谢正光, 黄宏伟, 等. 一种自适应低采样率图像分块压缩感知算法[J]. *小型微型计算机系统*, 2016, 37(3): 612-616.
- [12] LI Z T, XIE J X, ZHU G M, et al. Block-Based Projection Matrix Design for Compressed Sensing[J]. *Chinese Journal of Electronics*, 2016, 25(3): 551-555.
- [13] GAO C C, HUI X W. GLCM-Based Texture Feature Extraction [J]. *Computer Systems and Applications*, 2010, 19(6): 195-198. (in Chinese)  
高程程, 惠晓威. 基于灰度共生矩阵的纹理特征提取[J]. *计算机系统应用*, 2010, 19(6): 195-198.
- [14] FENG J H, YANG Y J. Research on Extracting Texture Feature Image Based on Co-occurrence Matrix[J]. *Beijing Surveying and Mapping*, 2007(3): 19-22. (in Chinese)  
冯建辉, 杨玉静. 基于灰度共生矩阵提取纹理特征图像的研究[J]. *北京测绘*, 2007(3): 19-22.
- [15] WANG R F, JIAO L C, LIU F, et al. Block-Based Adaptive Compressed Sensing of Image Using Texture Information [J]. *Electronic Journal*, 2013, 41(8): 1506-1514. (in Chinese)  
王蓉芳, 焦李成, 刘芳, 等. 利用纹理信息的图像分块自适应压缩感知[J]. *电子学报*, 2013, 41(8): 1506-1514.
- [16] LANG L Y, WANG Y, LI S Q. Image Reconstruction Based on Improved OMP Algorithm in Compressive Sensing [J]. *Video Engineering*, 2015, 39(6): 8-12. (in Chinese)  
郎利影, 王勇, 李思骞. 基于压缩感知 OMP 改进算法的图像重构[J]. *电视技术*, 2015, 39(6): 8-12.
- (上接第 263 页)
- [21] 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: IEEE, 2014: 2814-2821.
- [22] LU S, MAHADEVAN V, VASCONCELOS N. Learning Optimal Seeds for Diffusion-Based Salient Object Detection [C]// *Computer Vision and Pattern Recognition*. IEEE, 2014: 2790-2797.
- [23] 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.
- [24] ZHANG Q, SHEN X, XU L, et al. Rolling Guidance Filter [M]// *Computer Vision-ECCV 2014*. 2014: 815-830.
- [25] TIBSHIRANI R. Regression shrinkage and selection via the lasso: A retrospective[J]. *Journal of the Royal Statistical Society*, 2011, 73(3): 267-288.
- [26] LU S, MAHADEVAN V, VASCONCELOS N. Learning Optimal Seeds for Diffusion-Based Salient Object Detection [C]// *Computer Vision and Pattern Recognition*. IEEE, 2014: 2790-2797.
- [27] 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.
- [28] SHEN X, WU Y. A Unified Approach to Salient Object Detection via Low Rank Matrix Recovery[J]. *Computer Vision and Pattern Recognition*, 2012, 23(10): 853-860.
- [29] YAN J, ZHU M, LIU H, et al. Visual Saliency Detection via Sparse Pursuit [J]. *IEEE Signal Processing Letters*, 2010, 17(8): 739-742.
- [30] 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.
- [31] KIM T H, LEE K M, SANG U L. Learning Full Pairwise Affinities for Spectral Segmentation[J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2013, 35(7): 1690-1703.
- [32] ACHANTA R, HEMAMI S, ESTRADA F, et al. Frequency-tuned salient region detection[C]// *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Miami, USA: IEEE, 2009: 1597-1604.
- [33] 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.
- [34] 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.
- [35] LI G, YU Y. Visual Saliency Detection Based on Multiscale Deep CNN Features[J]. *IEEE Transactions on Image Processing A Publication of the IEEE Signal Processing Society*, 2016, 25(11): 5012-5024.
- [36] LI G, YU Y. Deep Contrast Learning for Salient Object Detection [C]// *Computer Vision and Pattern Recognition*. IEEE, 2016: 478-487.
- [37] LIU N, HAN J. DHSNet: Deep Hierarchical Saliency Network for Salient Object Detection [C]// *Computer Vision and Pattern Recognition*. IEEE, 2016: 678-686.
- [38] ZHANG P, WANG D, LU H, et al. Amulet: Aggregating Multi-level Convolutional Features for Salient Object Detection [J]. eprint arXiv:1708.02001.
- [39] GOPALAKRISHNAN V, HU Y, RAJAN D. Random Walks on Graphs for Salient Object Detection in Images [J]. *IEEE Transactions on Image Processing A Publication of the IEEE Signal Processing Society*, 2010, 19(12): 3232-3242.
- [40] YANG C, ZHANG L, LU H, et al. Saliency Detection via Graph-Based Manifold Ranking [C]// *Computer Vision and Pattern Recognition*. IEEE, 2013: 3166-3173.