

# 控制与决策

Control and Decision

基于低秩矩阵恢复的视觉显著性目标检测与细化

周静波, 黄伟

引用本文:

周静波, 黄伟. 基于低秩矩阵恢复的视觉显著性目标检测与细化[J]. *控制与决策*, 2021, 36(7): 1707–1713.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2019.1795>

---

## 您可能感兴趣的其他文章

Articles you may be interested in

[基于前景优化和概率估计的显著性检测](#)

Saliency detection based on foreground optimization and probability estimation  
*控制与决策*. 2021, 36(4): 917–924 <https://doi.org/10.13195/j.kzyjc.2019.1101>

[基于前景优化和概率估计的显著性检测](#)

Saliency detection based on foreground optimization and probability estimation  
*控制与决策*. 2021, 36(4): 917–924 <https://doi.org/10.13195/j.kzyjc.2019.1101>

[基于矩阵的双论域模糊概率粗糙集增量更新算法](#)

Incremental updating of fuzzy probability rough sets over two universes based on matrix method  
*控制与决策*. 2021, 36(3): 553–564 <https://doi.org/10.13195/j.kzyjc.2019.0692>

[复杂背景下全景视频运动小目标检测算法](#)

Panoramic video motion small target detection algorithm in complex background  
*控制与决策*. 2021, 36(1): 249–256 <https://doi.org/10.13195/j.kzyjc.2019.0686>

[基于稀疏度阶数优化的杂波密度估计算法](#)

A clutter density estimation algorithm by optimized sparsity order  
*控制与决策*. 2020, 35(12): 2923–2930 <https://doi.org/10.13195/j.kzyjc.2019.0429>

# 基于低秩矩阵恢复的视觉显著性目标检测与细化

周静波<sup>1†</sup>, 黄伟<sup>2</sup>

(1. 南京工程学院 计算机工程学院, 南京 211167;  
2. 韩山师范学院 计算机与信息工程学院, 广东 潮州 521041)

**摘要:** 基于低秩矩阵恢复(low-rank matrix recovery, LRMR)的显著性目标检测模型将图像特征分解为与背景关联的低秩分量和与显著性目标相关联的稀疏分量,并从稀疏分量中获得显著性目标. 现有的显著性检测方法很少考虑低秩分量与稀疏分量之间的相互关系,导致检测的显著性目标零散或不完整. 为此,提出基于低秩矩阵恢复的显著性目标检测与细化方法来规避该限制. 首先,所提方法采用  $\ell_1$  范数稀疏约束和拉普拉斯正则项对初始显著图进行计算;在显著性细化阶段,由于非局部的  $\ell_0$  优化可以有效地对显著性区域及其邻接区域之间的相互关系进行建模,结合初始显著图,采用非局部  $\ell_0$  梯度优化,最小化显著性区域中显著值的变化,从而保证显著性目标的完整性. 在 4 个显著性目标检测数据集上进行实验,通过实验结果验证所提算法的优越性.

**关键词:** 显著性目标检测; 低秩矩阵恢复;  $\ell_0$  优化; 显著性细化; 稀疏矩阵

中图分类号: TP391.4

文献标志码: A

DOI: 10.13195/j.kzyjc.2019.1795

开放科学(资源服务)标识码(OSID):



**引用格式:** 周静波,黄伟. 基于低秩矩阵恢复的视觉显著性目标检测与细化[J]. 控制与决策, 2021, 36(7): 1707-1713.

## Saliency object detection and refinement based on low rank matrix recovery

ZHOU Jing-bo<sup>1†</sup>, HUANG Wei<sup>2</sup>

(1. School of Computer Engineering, Nanjing Institute of Technology, Nanjing 211167, China; 2. School of Computer and Information Engineering, Hanshan Normal University, Chaozhou 521041, China)

**Abstract:** Low-rank matrix recovery (LRMR) based saliency object detection models decompose image features into a low-rank component associated with background and a sparse component associated with visual salient regions. Then, a saliency map can be generated from the sparse matrix. Existing LRMR-based saliency detection methods are prone to generating scattered or incomplete saliency maps which seldom considers inter-relationship among elements within these two components. A novel LRMR-based saliency detection algorithm is proposed to circumvent this limitation. Firstly, the proposed algorithm generates an initial map by exploiting the LRMR-based model that integrates a  $\ell_1$  norm sparsity constraint and a Laplacian regularization term. On the stage of saliency refinement, nonlocal  $\ell_0$  optimization is adopted to improve saliency map quality since it models not only the characteristics of an individual saliency but the interaction between neighbors. Based on the initial saliency map, the nonlocal  $\ell_0$  gradient is utilized to minimize the saliency variation in the salient object efficiently, thereby ensuring the integrity of the salient object. Experimental results on four public datasets of saliency object detection validate the proposed algorithm superiority.

**Keywords:** saliency object detection; low-rank matrix recovery;  $\ell_0$  optimization; saliency refinement; sparse matrix

## 0 引言

视觉显著性检测是神经科学、心理学和计算机视觉的研究热点,主要研究如何确定原始图像中包含的重要视觉信息<sup>[1]</sup>. 通过关注图像或视频中显著性目标位置而忽略大量不相关背景,使目标检测和识别更加高效和可靠<sup>[2]</sup>.

为提高检测精度,越来越多显著性检测模型利用先验信息对图像中目标进行检测<sup>[3-5]</sup>. 基于低秩矩阵恢复(low-rank matrix recovery, LRMR)模型<sup>[6-15]</sup>假定图像由视觉上一致的背景区域(对应于具有低秩结构的高度冗余信息分量)与突出的前景区域(对应于具有稀疏结构的视觉显著性分量)组成. 文献[6]提出

收稿日期: 2019-12-23; 修回日期: 2020-03-17.

基金项目: 南京工程学院科研基金项目(YKJ201722, JCYJ201825); 广东省自然科学基金项目(2016A030307050); 广东省公益能力研究项目(2016A020225008, 2017A040405062).

责任编辑: 张国山.

<sup>†</sup>通讯作者. E-mail: jbzhou2013@aliyun.com.

了基于LRMR的显著性检测模型,采用图像块学习字典,并用该字典的稀疏表示作为输入;文献[8]提出了多任务稀疏追踪显著性算法,将多个特征矩阵联合分解为成对的低秩和稀疏矩阵,并从这些矩阵中寻找一致的稀疏元素;文献[9]提出将不同显著性标签的预测模型聚合为一个矩阵,并通过低秩矩阵恢复问题解决显著性排序问题;文献[10]引入3类分割先验,结合该先验与低秩矩阵分解获取图像显著性;文献[11]采用双低秩矩阵恢复以融合不同显著图;文献[12]提出了加权低秩矩阵恢复模型,利用高层次背景先验图合并成加权矩阵,该加权矩阵指示每个图像区域属于背景的可能性;文献[13]在基于LRMR的显著性模型中,采用谱图作为权值获得更合理的高阶先验。

基于LRMR的模型仍面临两个问题:一方面,稀疏分量间的关联性被忽略,使检测的目标不完整;另一方面,当背景与目标具有相似外观时,模型很难从背景中分离出显著性目标.文献[14]提出了结构化矩阵分解(structured matrix decomposition, SMD),即采用基于树结构的稀疏约束和拉普拉斯正则化解决上述问题;文献[15]利用LRMR的基线模型对图像区域的显著性进行了粗略的度量并学习一种投影,该投影将图像特征映射到精确显著值,锐化对象边界并保持对象的完整性。

本文提出基于低秩矩阵恢复的显著性目标检测与细化方法来检测图像中显著性目标并增强前景与背景之间的差异.所提算法的计算流程如图1所示。

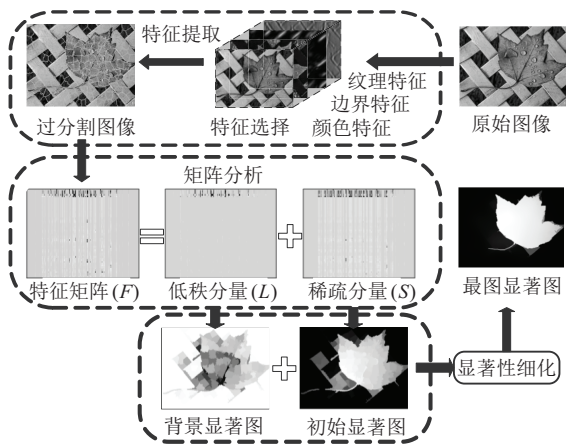


图1 本文算法计算流程

首先,所提方法对原始图像进行过分割,建立特征矩阵.然后,在计算图像初始显著图时采用 $l_1$ 范数稀疏约束和拉普拉斯正则项对初始显著图进行计算,低秩分量可估计背景显著图而稀疏分量可对初始显著图进行估计;在显著性目标细化阶段,结合初始显著图,采用非局部 $l_0$ 梯度优化,最小化显著性目标区域中显著值的变化,从而保证显著性目标完整性。

与其他LRMR模型仅依赖稀疏矩阵不同,所提

算法采用低秩矩阵和稀疏矩阵分别估计背景显著性和目标显著性,并结合二者计算最终显著性;同时,显著性细化阶段采用非局部梯度优化加强图像各分量的空间关系,增加显著性目标的完整性。

## 1 本文算法

下面介绍如何从图像中提取特征,如何根据特征获取初始显著图,如何根据初始显著图进行细化。

### 1.1 图像特征提取

在图像特征提取过程中,首先将图像分割为紧凑且均衡感知的元素.类似于文献[7],在图像中提取低级特征,如RGB颜色特征、可控金字塔和Gabor滤镜,构建图像的53维特征表示,如图2所示.然后采用简单线性迭代聚类算法<sup>[16]</sup>将图像过分割为 $N$ 个超像素 $P = \{P_1, P_2, \dots, P_N\}$ .每个图像块均由特征向量 $f_i$ 表示.所有的特征向量形成特征矩阵 $F = [f_1, f_2, \dots, f_N] \in R^{D \times N}$ ,其中 $D = 53$ .




图2 图像53维特征表示(第1张为原始图像)

### 1.2 初始显著图

由于树结构稀疏不能保持图像区域间的空间关系<sup>[15]</sup>,所提方法采用 $l_1$ 范数稀疏约束和拉普拉斯正则项,形成初始显著图.针对特征矩阵 $F$ ,考虑优化

$$(L, S) = \underset{L, S}{\operatorname{argmin}} \|L\|_* + \lambda \|S\|_1 + \gamma \operatorname{tr}(SQS^T);$$

$$\text{s.t. } F = L + S.$$

其中: $F, L, S \in R^{D \times N}$ , $Q$ 为未规范化的图拉普拉斯矩阵, $\|\cdot\|_*$ 和 $\|\cdot\|_1$ 分别为核范数和1-范数, $\operatorname{tr}(\cdot)$ 为矩阵的迹,参数 $\lambda$ 和 $\gamma$ 控制稀疏分量和拉普拉斯矩阵所占权重.该优化问题可通过交替方向乘子法<sup>[17]</sup>(alternating direction method of multipliers, ADMM)进行计算.为简化计算,引入辅助变量 $Z$ ,即

$$(L, S) = \underset{L, S}{\operatorname{argmin}} \|L\|_* + \lambda \|S\|_1 + \gamma \operatorname{tr}(ZQZ^T);$$

$$\text{s.t. } F = L + S, S = Z. \quad (1)$$

引入拉格朗日乘子 $Y_1$ 和 $Y_2$ 以消除等价约束,并构造增广的拉格朗日函数

$$\mathcal{L}(L, S, Z, Y_1, Y_2, \mu) =$$

$$\|L\|_* + \lambda \|S\|_1 + \gamma \operatorname{tr}(ZQZ^T) +$$

$$\begin{aligned} & \text{tr}(Y_1^T(F - L - S)) + \text{tr}(Y_2^T(S - Z)) + \\ & \frac{\mu}{2}(\|F - L - S\|_F^2 + \|S - Z\|_F^2), \end{aligned} \quad (2)$$

其中  $\mu \geq 0$  为惩罚参数. 采用迭代求解最小化公式(2)中函数, 每个变量均有闭合形式的解. 对于  $L$  和  $S$ , 可以按照以下方式进行更新:

$$\begin{aligned} L^{k+1} = & \operatorname{argmin}_L \frac{1}{\mu^k} \|L\|_* + \frac{1}{2} \left\| L - \left( F - S^k + \frac{Y_1^k}{\mu} \right) \right\|_F^2, \\ S^{k+1} = & \operatorname{argmin}_S \mathcal{L}(L^{k+1}, S, Z^k, Y_1^k, Y_2^k, \mu^k) = \\ & \operatorname{argmin}_S \lambda \|S\|_1 + \text{tr}((Y_1^k)^T(F - L^k - S^k)) + \\ & \text{tr}((Y_2^k)^T(S - Z^k)) + \\ & \frac{\mu^k}{2} (\|F^k - L^{k+1} - S^k\|_F^2 + \|S - Z^k\|_F^2) = \\ & \operatorname{argmin}_S \frac{\lambda}{2\mu^k} \|S\|_1 + \\ & \frac{1}{2} \left\| S - \left( F - L^{k+1} + Z^k - \frac{Y_2^k - Y_1^k}{\mu^k} \right) \right\|_F^2. \end{aligned}$$

考虑  $Z, Y_1, Y_2$  和  $\mu$ , 可以按照以下方式更新:

$$\begin{aligned} Z^{k+1} &= (\mu^k S^{k+1} + Y_2^k)(\mu^k I + 2\gamma Q)^{-1}, \\ Y_1^{k+1} &= Y_1^k + \mu^k (F - L^{k+1} - S^{k+1}), \\ Y_2^{k+1} &= Y_2^k + \mu^k (S^{k+1} - Z^{k+1}), \\ \mu^{k+1} &= \min(\theta \mu^k, \mu_{\max}). \end{aligned}$$

其中:  $I$  为单位矩阵, 参数  $\theta > 0$  控制收敛速度.

若确定了矩阵  $L$  和  $S$ , 则可以定义各超像素的显著值. 根据稀疏矩阵  $S$ , 各超像素  $P_i$  的显著值可以定义为  $s_i^{\mathcal{F}} = \|s_i\|_1$ . 其中:  $\|\cdot\|_1$  为 1-范数;  $s_i^{\mathcal{F}} \in [0, 1]$  为超像素  $P_i$  属于显著性目标的概率, 因此定义  $s^{\mathcal{F}}$  为初始显著图. 类似地, 定义基于低秩矩阵  $L$  的显著值为  $s_i^{\mathcal{B}} = \|l_i\|_1$ ,  $s_i^{\mathcal{B}} \in [0, 1]$  为超像素  $P_i$  属于背景的概率, 因此  $s^{\mathcal{B}}$  称为背景显著图. 下面主要描述对两类显著图融合细化, 得到最优显著图.

### 1.3 显著性细化

由于  $\ell_0$  优化可用来度量图像区域显著性<sup>[18]</sup>, 但该方法容易将背景区域标记为显著性区域. 对文献<sup>[18]</sup>中的目标函数进行修改, 并结合背景显著图  $s^{\mathcal{B}}$  和初始显著图  $s^{\mathcal{F}}$  获取更可靠的显著性目标  $s$ .

结合两类显著性, 优化问题目标函数如下:

$$\min_s \sum_{i=1}^N \left\{ \frac{\alpha}{2} s_i^{\mathcal{F}} (s_i - 1)^2 + \frac{\beta}{2} s_i^{\mathcal{B}} s_i^2 + \|\nabla_{NL} s_i\|_0 \right\}. \quad (3)$$

其中:  $\alpha$  和  $\beta$  控制  $s_i^{\mathcal{F}}$  和  $s_i^{\mathcal{B}}$  的权重参数,  $\|\nabla_{NL} s_i\|_0$  为  $s_i$  的非局部梯度的  $\ell_0$  范数, 计算  $s_i$  对应的显著性区域的非局部非零梯度个数. 与图像网格梯度不同, 超像

素的非局部梯度被定义为超像素和其他超像素显著值加权差异向量. 如  $s_i$  的非局部梯度表示为

$$\nabla_{NL} s_i = \{G_1(s_i), \dots, G_j(s_i), \dots, G_N(s_i)\}. \quad (4)$$

其中:  $G_j(s_i) = (s_i - s_j) \sqrt{w_{ij}}$ ,  $w_{ij}$  为第  $i$  个与第  $j$  个超像素之间的相似性, 且有

$$w_{ij} = \exp\left(-\frac{\|f_i - f_j\|_2^2}{2\sigma^2}\right).$$

这里:  $f_i$  为对应第  $i$  个超像素的 53 维特征向量;  $\sigma^2$  控制相似性度量邻域大小, 该值设置为  $4 \times 10^{-2}$ .

由于式(3)不连续且非凸, 采用梯度下降或其他离散优化不能获得最优解. 类似于求解式(1), 采用交替方向乘子法 (ADMM) 解决式(3)的优化问题. 对应  $\nabla_{NL} s$  引入辅助变量  $b$ , 重写式(3)可得

$$\begin{aligned} & \min_{s,b} \sum_{i=1}^N \left\{ \frac{\alpha}{2} s_i^{\mathcal{F}} (s_i - 1)^2 + \frac{\beta}{2} s_i^{\mathcal{B}} s_i^2 + \|b_i\|_0 \right\}; \\ & \text{s.t. } b_i = \nabla_{NL} s_i, \quad i = 1, 2, \dots, N. \end{aligned} \quad (5)$$

对应于式(5)的增强拉格朗日函数为

$$\begin{aligned} \mathcal{L}_\rho(s, b, y) = & \sum_{i=1}^N \left\{ \frac{\alpha}{2} s_i^{\mathcal{F}} (s_i - 1)^2 + \frac{\beta}{2} s_i^{\mathcal{B}} s_i^2 + \right. \\ & \left. \frac{\rho}{2} \left\| b_i - \nabla_{NL} s_i + \frac{1}{\rho} y_i \right\|_2^2 + \|b_i\|_0 \right\}. \end{aligned} \quad (6)$$

其中:  $y$  为拉格朗日乘数矩阵,  $\rho > 0$  为惩罚参数;  $y_i$  和  $b_i$  分别为  $y$  和  $b$  的第  $i$  列. ADMM 将最小化  $\mathcal{L}$  分解为两个子问题, 即交替最小化  $s$  和  $b$ , 然后更新  $y$ , 即

$$\begin{aligned} s^{k+1} = & \operatorname{argmin}_s \sum_{i=1}^N \left\{ \frac{\alpha}{2} s_i^{\mathcal{F}} (s_i - 1)^2 + \frac{\beta}{2} s_i^{\mathcal{B}} s_i^2 + \right. \\ & \left. \frac{\rho}{2} \left\| b_i^k - \nabla_{NL} s_i + \frac{1}{\rho} y_i^k \right\|_2^2 \right\}, \end{aligned} \quad (7)$$

$$\begin{aligned} b^{k+1} = & \operatorname{argmin}_b \sum_{i=1}^N \left\{ \frac{\rho}{2} \left\| b_i - \nabla_{NL} s_i^{k+1} + \frac{1}{\rho} y_i^k \right\|_2^2 + \|b_i\|_0 \right\}, \end{aligned} \quad (8)$$

$$y_i^{k+1} = y_i^k + \rho(b_i^{k+1} - \nabla_{NL} s_i^{k+1}). \quad (9)$$

下面求解  $s$  子问题.  $s^{k+1}$  的计算方式为

$$\begin{aligned} s_i^{k+1} = & \frac{1}{\alpha s_i^{\mathcal{F}} + \beta s_i^{\mathcal{B}}} \left\{ \alpha s_i^{\mathcal{F}} - \rho \operatorname{div}_{NL} (b_i^k - \nabla_{NL} s_i + \frac{1}{\rho} y_i^k) \right\}, \\ \operatorname{div}_{NL} u_i = & \sum_{j=1}^N (u_{ji} - u_{ij}) \sqrt{w_{ij}}. \end{aligned}$$

根据式(7)和(8), 采用 Gauss\_Seidel 迭代方法<sup>[19]</sup> 可以快速得到近似解

$$s_i^{k+1, k'+1} = \frac{1}{\alpha s_i^{\mathcal{F}} + \beta s_i^{\mathcal{B}} + 2\rho \sum_{j=1}^N w_{ij}} \left( \alpha s_i^{\mathcal{F}} - \right.$$

$$\sum_{j=1}^N \sqrt{w_{ij}} (\rho b_{ij}^k - \rho b_{ji}^k + y_{ij}^k - y_{ji}^k) + \sum_{j=1}^N 2\rho w_{ij} s_j^{k+1, k'}$$

实验中  $s^{k+1,0} = s^k, k'$  两次迭代就可以得到最小化的近似值, 从而降低算法计算复杂度.

下面求  $b$  子问题. 求解  $b$  的子问题可以分解为对每个元素  $b_{ij}^{k+1}$  的独立估计:  $\sum_{i=1}^N \sum_{j=1}^N \min \left\{ \frac{\rho}{2} (b_{ij} - G_j(s_i^{k+1}) + \frac{1}{\rho} y_{ij}^k)^2 + H(b_{ij}) \right\}$ . 其中: 如果  $b_{ij} \neq 0$ , 则  $H(b_{ij}) = 1$ ; 如果  $b_{ij} = 0$ , 则  $H(b_{ij}) = 0$ . 重写单个元素  $b_{ij}$  的能量为

$$E = \frac{\rho}{2} \left( b_{ij} - G_j(s_i^{k+1}) - \frac{1}{\rho} y_{ij}^k \right)^2 + H(b_{ij}). \quad (10)$$

式(10)在条件(11)下可以达到最小化

$$b_{ij} = \begin{cases} 0, & \frac{\rho}{2} \left( G_j(s_i^{k+1}) - \frac{1}{\rho} y_{ij}^k \right)^2 \leq 1; \\ G_j(s_i^{k+1}) - \frac{1}{\rho} y_{ij}^k, & \text{otherwise.} \end{cases} \quad (11)$$

下面更新  $y$ . 解决  $s$  和  $b$  的两个子问题后, 拉格朗日乘子  $y$  可通过  $s^{k+1}$  和  $b^{k+1}$  按式(9)进行更新.

## 2 实验结果与分析

为了评价所提算法在显著性目标检测上的性能, 本文在 MSRA<sup>[20]</sup>、ECSSD<sup>[21]</sup>、DUT-OMRON<sup>[22]</sup> 和 iCoSeg<sup>[23]</sup> 四个基准图像数据集上进行实验. 同时, 将所提算法与经典显著性检测算法进行比较, 例如: 基于LRMR的ULR(unified low rank)<sup>[7]</sup>、HLR(hierarchical low rank)<sup>[15]</sup> 和 SMD(structured matrix decomposition)<sup>[14]</sup>, 基于流形排序的LPS(label propagation saliency)<sup>[24]</sup> 和RS(ranking saliency)<sup>[22]</sup>, 基于优化的GP(generic promotion)<sup>[25]</sup> 和基于双层稀疏图的SDP(salient detection using diffusion process)<sup>[26]</sup> 等. 所有参与比较的算法均用原作者提供的实验代码和参数, 并在 Intel Core i5-7500 CPU 3.40 GHz, 8 GB RAM 计算机上采用 Matlab 2019a 平台进行实验比较. 所有评价指标请参考文献[14].

### 2.1 参数设置

在计算图像初始显著图时, 本文算法需要确定超像素个数  $N$ , 正则化参数  $\lambda$  和  $\gamma$  等3个参数. 以 DUT-OMRON 库为例, 讨论模型对这3个参数的敏感性. 对于超像素个数  $N$  选择在 200, 300, 400, 500 中变化, 其 WF(weighted  $F$ -measure)、OR(overlapping ratio)、AUC(area under the ROC curve) 和 MAE(mean absolute error) 性能比较如图3所示. 选择较大的  $N$  时性能提升有限, 且超像素个数越多算法运行时间越

长. 因此实验中设置  $N = 200$ . 对于参数  $\lambda$  和  $\gamma$ , 通过调整其中一个参数而变化另一个, 其性能变化如图3所示.

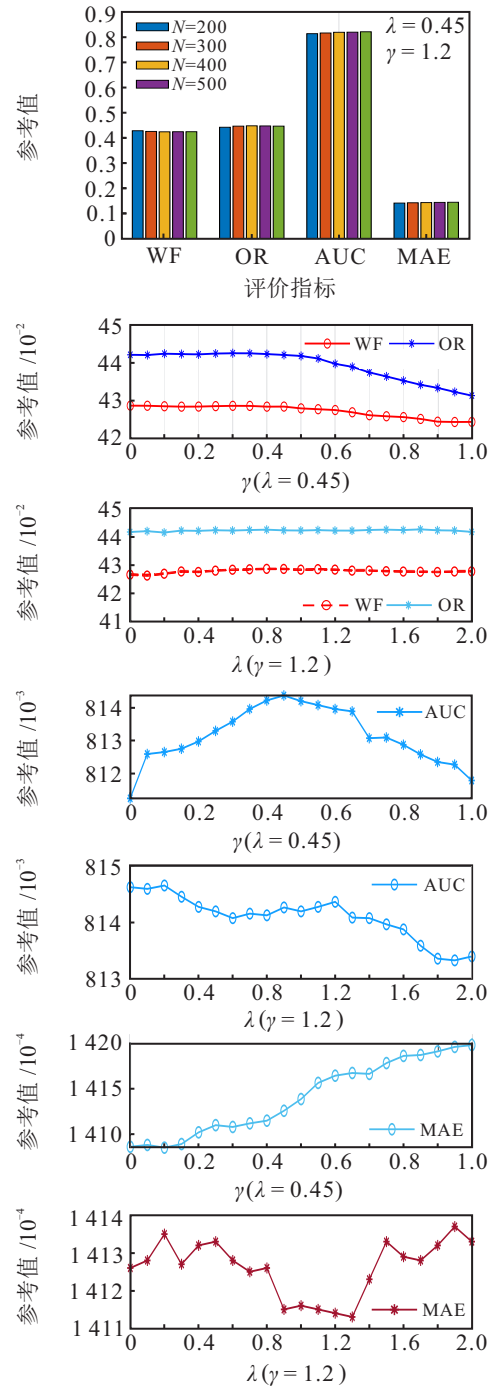


图3 参数敏感性分析

根据图3, 实验中选择  $\lambda = 0.45$  和  $\gamma = 1.2$ . 在该阶段中, 其他变量的初始化直接进行设置, 如  $L^0 = S^0 = Z^0 = Y_1^0 = Y_2^0 = 0, \mu^0 = 0.1, \mu_{\max} = 1.0 \times 10^5, \theta = 1.1$ .

类似于第1阶段, 在显著图细化过程中, 需要设置  $\alpha, \beta$  和  $\rho$ . 实验中设置  $\alpha = 1.5 \times 10^{-3}, \beta = 4.5 \times 10^{-3}$  和  $\rho = 1.0 \times 10^{-4}$ . 为了使算法尽快收敛, 在式(9)迭代过程中, 设置最大迭代次数为100.

2.2 与其他显著性算法的比较

本文算法与7种显著性算法在MSRA、ECSSD、DUT-OMRON和iCoSeg数据集上进行比较,如图4和表1所示。

图4中给出了本文算法和经典显著性算法的定量比较结果,表1中列出了不同算法在4类数据库上的WF、OR、AUC和MAE指标值。其中:↑表示值越大检测结果越好,↓表示越小越好。

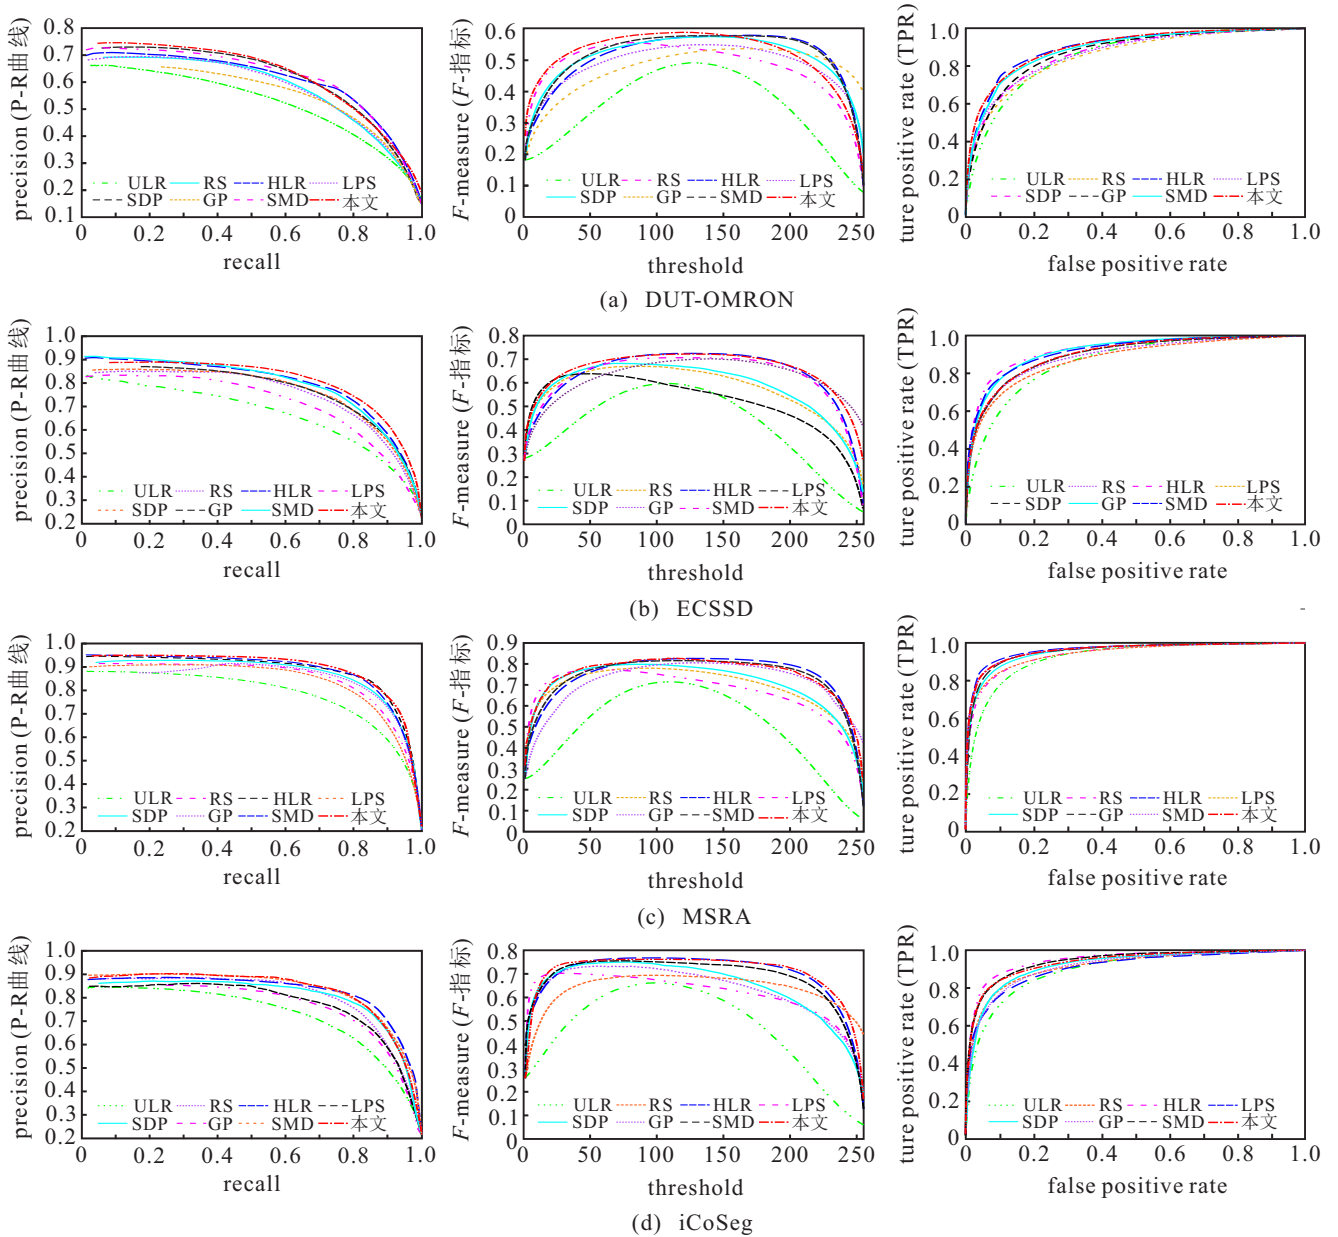


图4 不同算法在不同指标上的比较

表1 不同算法在不同数据集上的性能

算法	MSRA				DUT-OMRON				ECSSD				iCoSeg			
	WF↑	OR↑	AUC↑	MAE↓	WF↑	OR↑	AUC↑	MAE↓	WF↑	OR↑	AUC↑	MAE↓	WF↑	OR↑	AUC↑	MAE↓
ULR	0.406	0.517	0.837	0.222	0.253	0.317	0.805	0.26	0.35	0.369	0.788	0.274	0.378	0.443	0.814	0.222
RS	0.613	0.672	0.828	0.129	0.378	0.419	0.781	0.187	0.493	0.52	0.789	0.19	0.545	0.59	0.806	0.16
SDP	0.635	0.705	0.84	0.118	0.406	<b>0.452</b>	0.795	0.177	0.507	0.539	0.794	0.183	0.577	0.598	0.813	0.15
LPS	0.606	0.64	0.809	0.121	0.401	0.418	0.768	0.145	0.456	0.469	0.752	0.186	0.55	0.531	0.764	0.145
HLR	0.662	<b>0.719</b>	<b>0.856</b>	0.112	0.419	0.441	0.81	0.17	0.541	<b>0.57</b>	0.818	<b>0.171</b>	<b>0.629</b>	0.618	<b>0.833</b>	0.138
GP	0.60	0.674	0.853	0.137	0.372	0.401	0.806	0.209	0.515	0.531	0.817	0.191	0.521	0.537	0.819	0.174
SMD	0.659	0.715	0.851	0.111	0.423	0.443	0.812	0.167	0.539	0.562	0.812	0.173	0.61	0.595	0.822	0.138
本文	<b>0.663</b>	<b>0.719</b>	0.852	<b>0.110</b>	<b>0.429</b>	0.443	<b>0.815</b>	<b>0.141</b>	<b>0.542</b>	0.558	<b>0.819</b>	0.172	0.616	<b>0.63</b>	0.822	<b>0.137</b>

### 2.2.1 单一目标图像比较

根据图像数据集的特点,在MSRA和ECSSD库上完成对单一目标的检测和对比.在MSRA数据集上,本文提出的算法在WF(0.663)、OR(0.719)以及MAE(0.11)指标上取得了最优的结果,在AUC指标上,HLR模型达到最优(0.856),GP算法得到次优(0.853).由于MSRA中图像种类繁多,但包含的图像背景光滑、目标相对简单,并且与前景在语义(外貌)上有非常大的区别,算法能较好地检测出显著性目标.在ECSSD库中,由于图像语义丰富,结构复杂,几乎所有指标值都差于MSRA.本文算法在WF和AUC指标上达到最优,而HLR算法在OR和MAE指标上取得最优(0.57和0.171).

就检测的显著图而言,如图5所示,所提算法能够将目标完整地检测出来,同时抑制背景噪声.在MSRA数据库上,绝大多数算法均能检测出显著性目标,但大部分算法不能抑制背景噪声.在ECSSD库上,ULR不能整体突出显著性目标,而SMD则不能有效抑制背景噪声,显著性目标边界不清晰.

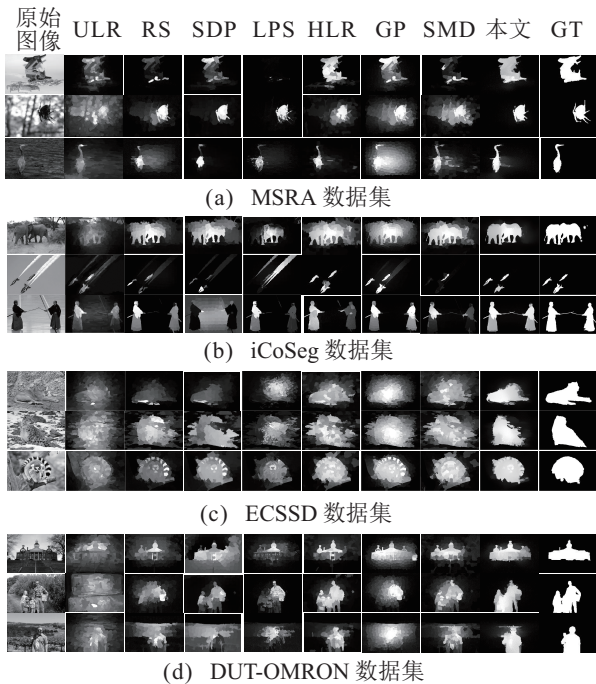


图5 不同算法在部分图像上的效果对比

### 2.2.2 多目标图像对比

本文将所有算法在iCoSeg数据库上进行实验,以验证算法检测图像中多个目标性能.iCoSeg是一个公共的联合图像数据库,包含38组共643张图像,每张图像包含一个或者多个显著性目标.

根据图4,本文算法在P-R曲线和F-指标上具有较好的结果.其中F-指标要明显高于SMD,说明相对于SMD,所提算法中F-指标对参数选择不敏感.而在FPR(false positive rate)和TPR上略逊于SMD和

HLR.表1中,所提算法在AUC(0.822)指标上低于HLR(0.833),而高于其他算法.对于显著图,所提算法能够有效地检测图像中多个目标,并对背景噪声进行抑制.SMD在检测多目标时容易丢失部分目标,如只能检测到其他目标的一部分.算法HLR能将目标检测出来,但噪声背景同时被检测出来,影响显著图的后续分割.

### 2.2.3 复杂场景图像比较

为验证在复杂场景下算法的性能,将算法在DUT-OMRON库和ECSSD库上进行对比.在单一目标检测比较中已经对ECSSD库进行过分析,这里不再赘述.由于DUT-OMRON中大部分图像的目标和背景均是不同质的,每幅图像含有一个或多个显著目标,目标大小不一,背景相对复杂,因此对测试算法有很大的挑战性.

就P-R曲线、F-指标而言,本文算法与SMD和HLR算法的性能接近,但优于其他算法.在WF、OR和MAE指标上,所提算法在WF(0.429)、AUC(0.815)和MAE(0.141)上达到最优,SDP算法在OR(0.452)指标上取得最优.

在图5中,选取了DUT-OMRON库和ECSSD库中部分图片进行效果对比.ECSSD中显著性目标与背景相似,大部分算法并不能有效检测出显著性目标,其中SMD和GP能够检测到目标位置,但不能区分背景与前景的边界.在DUT-OMRON数据集上,HLR和SDP的显著图中将部分背景噪声当成显著性目标,而ULR算法根本不能检测到显著性目标.所提算法在两类库中能够较好地突出整体目标,但是在靠近目标边缘部分,由于背景与目标非常相似,存在一些背景噪声被误检为显著性目标.

### 2.2.4 运行时间比较

为比较本文所提算法和其他算法的运行时间,将所有算法在MSRA上的运行时间罗列在表2中.

表2 不同算法在MSRA库中运行时间 单位: s

算法	ULR	RS	SDP	LPS	HLR	GP	SMD	本文
时间	8.28	0.16	0.48	1.31	0.87	0.32	0.67	0.85

从表2中可以看到:ULR算法比其他算法慢得多,平均检测一张图片需要8.28 s.而LPS算法则需要1.31 s.本文算法虽然快于ULR和LPS,但是平均检测一张图像需要0.85 s.这与算法需要做两次优化,每次均用ADMM算法求解有关.

## 3 结论

基于低秩矩阵恢复的显著性目标检测与细化方法检测图像中显著性目标和增强前景与背景之间的

差异. 本文所提方法在计算图像初始显著图时采用  $\ell_1$  范数稀疏约束和拉普拉斯正则项计算初始显著图; 在显著性目标细化阶段, 采用非局部的  $\ell_0$  优化对显著性目标区域及其邻接区域之间的相互关系进行建模. 结合初始显著图, 该阶段采用非局部  $\ell_0$  梯度优化, 最小化显著性目标区域中显著值的变化, 从而保证显著性目标完整性. 最后的测试实验表明, 所提算法具有较好的分割性能.

#### 参考文献(References)

- [1] Borji A, Cheng M M, Hou Q, et al. Salient object detection: A survey[J]. *Computational Visual Media*, 2019, 5(2): 117-150.
- [2] Gao Y, Yu X S, Wu C, et al. Automatic optic disc boundary extraction based on saliency object detection and modified local gaussian distribution fitting model in retinal images[J]. *Control and Decision*, 2019, 34(1): 154-159.
- [3] Xia C Q, Li J, Chen X W, et al. What is and what is not a salient object? Learning salient object detector by ensembling linear exemplar regressors[C]. *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Puerto Rico: IEEE, 2017: 4399-4407.
- [4] Hou Q B, Cheng M M, Hu X W, et al. Deeply supervised salient object detection with short connections[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2019, 41(4): 815-828.
- [5] Wang L Z, Wang L J, Lu H C, et al. Salient object detection with recurrent fully convolutional networks[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2019, 41(7): 1734-1746.
- [6] Yan J C, Zhu M Y, Liu H X, et al. Visual saliency detection via sparsity pursuit[J]. *IEEE Signal Processing Letters*, 2010, 17(8): 739-742.
- [7] Shen X H, Wu Y. A unified approach to salient object detection via low rank matrix recovery[C]. *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Puerto Rico: IEEE, 2012: 853-860.
- [8] Lang C Y, Liu G C, Yu J, et al. Saliency detection by multitask sparsity pursuit[J]. *IEEE Transactions on Image Processing*, 2012, 21(3): 1327-1338.
- [9] Li Z, Lang C Y, Feng S H, et al. Saliency ranker: A new salient object detection method[J]. *Journal of Visual Communication and Image Representation*, 2018, 50: 16-26.
- [10] Zou W, Kpalma K, Liu Z, et al. Segmentation driven low-rank matrix recovery for saliency detection[C]. *Proceedings of British Machine Vision Conference*. Bristol: IEEE, 2013: 1-11.
- [11] Li J X, Luo L, Zhang F L, et al. Double low rank matrix recovery for saliency fusion[J]. *IEEE Transactions on Image Processing*, 2016, 25(9): 4421-4432.
- [12] Tang C, Wang P C, Zhang C Q, et al. Salient object detection via weighted low rank matrix recovery[J]. *IEEE Signal Processing Letters*, 2017, 24(4): 490-494.
- [13] Chen J Z, Chen J, Ling H F, et al. Salient object detection via spectral graph weighted low rank matrix recovery[J]. *Journal of Visual Communication and Image Representation*, 2018, 50: 270-279.
- [14] Peng H W, Li B, Ling H B, et al. Salient object detection via structured matrix decomposition[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(4): 818-832.
- [15] Zheng Q, Yu S J, You X G. Coarse-to-fine salient object detection with low-rank matrix recovery[J]. *Neurocomputing*, 2020, 376: 232-243.
- [16] 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.
- [17] Lu C Y, Feng J S, Yan S C, et al. A unified alternating direction method of multipliers by majorization minimization[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2018, 40(3): 527-541.
- [18] Wang Y, Liu R, Song X, et al. Saliency detection via nonlocal  $\ell_0$  minimization[C]. *Proceedings of Asian Conference on Computer Vision*. Singapore: Springer, 2014: 521-535.
- [19] Bresson X. A short note for nonlocal TV minimization[R]. State College: The Pennsylvania State University, 2009: 1-7.
- [20] 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*, 2014, 37(3): 569-582.
- [21] Shi J, Yan Q, Xu L, et al. Hierarchical image saliency detection on extended CSSD[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2016, 38(4): 717-729.
- [22] Zhang L H, Yang C, Lu H C, et al. Ranking saliency[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(9): 1892-1904.
- [23] 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.
- [24] Li H, Lu H C, Lin Z, et al. Inner and inter label propagation: Salient object detection in the wild[J]. *IEEE Transactions on Image Processing*, 2015, 24(10): 3176-3186.
- [25] Jiang P, Vasconcelos N, Peng J. Generic promotion of diffusion-based salient object detection[C]. *Proceedings of IEEE International Conference on Computer Vision*. Santiago: IEEE, 2015: 217-225.
- [26] Zhou L, Yang Z, Zhou Z, et al. Salient region detection using diffusion process on a two-layer sparse graph[J]. *IEEE Transactions on Image Processing*, 2017, 26(12): 5882-5894.

#### 作者简介

周静波(1983—), 男, 副教授, 博士, 从事图像处理、模式识别等研究, E-mail: jbzhou2013@aliyun.com;

黄伟(1979—), 男, 副教授, 博士, 从事图像处理、人脸识别和机器学习等研究, E-mail: weihuang.china@qq.com.

(责任编辑: 闫妍)