

基于低秩背景约束与多线索传播的图像显著性检测

唐红梅* 白梦月 韩力英 梁春阳

(河北工业大学电子信息工程学院 天津 300401)

摘要: 针对当前基于流形排序的显著性检测算法缺乏子空间信息的挖掘和节点间传播不准确的问题, 该文提出一种基于低秩背景约束与多线索传播的图像显著性检测算法。融合颜色、位置和边界连通度等初级视觉先验形成背景高级先验, 约束图像特征矩阵的分解, 强化低秩矩阵与稀疏矩阵的差异, 充分描述子空间结构信息, 从而有效地将前景与背景分离; 引入稀疏感知和局部平滑等线索改进传播矩阵的构建, 增强颜色特征出现概率低的节点的传播能力, 加强局部区域内节点的关联性, 准确凸显节点的属性, 得到紧密且连续的显著区域。在3个基准数据集上的实验结果与图像检索领域的应用证明了该文算法的有效性和鲁棒性。

关键词: 显著性检测; 低秩背景约束; 多线索传播; 稀疏感知

中图分类号: TN911.73; TP391.41

文献标识码: A

文章编号: 1009-5896(2021)05-1432-09

DOI: 10.11999/JEIT200193

Image Saliency Detection Based on Background Constraint of Low Rank and Multi-cue Propagation

TANG Hongmei BAI Mengyue HAN Liying LIANG Chunyang

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

Abstract: Considering the lack of subspace information digging and inaccurate propagation between nodes in existing saliency detection algorithm based on manifold ranking, an image saliency detection algorithm based on background constraint of low rank and multi-cue propagation is proposed. Primary visual priors such as color, location and boundary connectivity prior are fused to form a background high-level prior, which restrains the low rank decomposition of feature matrix and strengthens the difference between low rank matrix and spares matrix, describes structural information of subspace fully to separate foreground and background efficiently. Cues of rareness perception and local smoothing are introduced for improving the reconstruction of propagation matrix, which improves the node's propagation capacity that has low probability of color feature occurrence, enhances the relevance of local region, strengthens the properties of nodes accurately to obtain the compact and continuous salient regions. The experimental results on three benchmark datasets and the application to image retrieval demonstrate the efficiency and robustness of the proposed algorithm.

Key words: Saliency detection; Background constraint of low rank; Multi-cue propagation; Rareness perception

1 引言

人类的视觉注意机制能够从复杂的场景中排除琐碎的信息并筛选出最有吸引力的区域。显著性检测的目的是定位最能吸引人注意的区域, 同时忽略非重要的视觉信息^[1,2]。显著性检测作为图像的预处理过程, 被应用到图像检索等领域^[3,4]。按照数据处理方式, 显著性检测的方法分为两类: 自下而

上模型和自上而下模型^[5]。自下而上模型在数据驱动下, 采用纹理、边界等线索完成显著性检测。自上而下模型以任务驱动的方式对带有类标签的模型进行训练, 从而实现显著性检测, 耗费时间较长^[6]。本文专注于自下而上模型。

近些年, 图像的显著性检测算法在不断进步。测地显著性(Geodesic Saliency, GS)算法^[7]从背景线索出发, 通过测量像素到边界的最短路径距离来计算每个区域的显著值; 加权低秩恢复(Weighted Low Rank Recovery, WLRR)算法^[8]采用背景高级先验引导特征矩阵分解的方式得到显著图。文献^[9]改进VGG-16网络以优化显著性检测, 模型训练成本较高。显著性的传播机制具有高效性, 成为了显

收稿日期: 2020-03-20; 改回日期: 2020-09-13; 网络出版: 2020-09-22

*通信作者: 唐红梅 hmtang2005@163.com

基金项目: 河北省自然科学基金(F2019202387)

Foundation Item: The Natural Science Foundation of Hebei Province (F2019202387)

显著性检测的重要策略之一。基于图的流形排序(Graph Based Manifold Ranking, GBMR)算法^[10]采用图排序检测显著目标,依据背景先验选取种子节点,导致显著目标在边界时检测效果差;流形保持扩散(Manifold-Preserving Diffusion, MPD)算法^[11]探索了平滑项和局部重建误差项两个假设,以保持显著性检测的流形结构;基于流形排序的矩阵分解(Manifold Ranking based Matrix Factorization, MRMF)算法^[12]在矩阵分解中对排序问题建模,合并空间信息、嵌入标签,赋予相邻超像素相似的显著性值。Teaching-to-Learn and Learning-to-Teach, TLLT)算法^[13]采用教与学相结合的策略,从简单性学习到高难度学习传播显著值,耗费时间较长。

基于流形排序的显著性检测已经取得了不错的进展,但在指示向量筛选和传播矩阵的构建方面仍存在不足:(1)指示向量的选择通常依赖图像背景信息,缺乏对图像子空间信息的挖掘;(2)传播矩阵的构建缺乏感知线索的运用,导致显著图的前景背景之间边界不明显;(3)传播矩阵采用标准平滑约束,忽视了局部区域的平滑性,造成部分区域信息的丢失,使得丢失信息区域的节点与周围区域连接较强的节点不能可靠传播。为解决上述问题,提出基于低秩背景约束与多线索传播的图像显著性检测算法。本文的创新点如下:

(1) 兼顾图像子空间结构信息和节点间潜在关系,提出基于低秩背景约束与多线索传播的显著性检测算法。利用高级背景先验约束特征矩阵的分解,挖掘子空间的结构信息,增强低秩矩阵与稀疏矩阵的差异,提高前景与背景的辨别度;联合多

个线索探究节点间的冗余性和关联性,优化传播机制。

(2) 在细化过程中,重新构建传播矩阵,将提出的稀疏感知项与局部平滑项嵌入其中。从稀疏感知的角度出发,合理抑制颜色特征出现概率高的节点传播,着重突出颜色特征出现概率低的节点传播,从而达到突出前景抑制背景的效果。设计局部平滑策略,加强局部区域内节点间的关联性,准确地呈现出局部区域内各个节点的属性,促进同类别节点的可靠传播。

2 提出算法整体框架

为解决基于流形排序的显著性检测算法缺乏子空间信息挖掘和节点间传播不准确的问题,本文提出基于低秩背景约束与多线索传播的图像显著性检测算法,算法框架如图1所示。首先,将图像分割成均匀的超像素块,全面地捕捉像素的结构信息;其次,提取每个超像素块的特征矩阵,使用高级背景先验约束特征矩阵分解,突出低秩矩阵与稀疏矩阵的差异性,得到前景背景分离的低秩背景约束显著图;进一步,为探索超像素节点间的潜在联系,构建契合人类感知系统的局部信息图结构,借助低秩背景约束显著图筛选可靠的指示向量,重构传播矩阵,嵌入稀疏感知特性与局部平滑约束作为正则项,实现显著值的多线索传播,获得精细的显著图。

3 基于低秩背景约束与多线索传播的显著性检测

3.1 基于低秩背景约束的显著性检测

3.1.1 构建低秩背景约束模型

为降低算法复杂度,使用简单线性迭代聚类

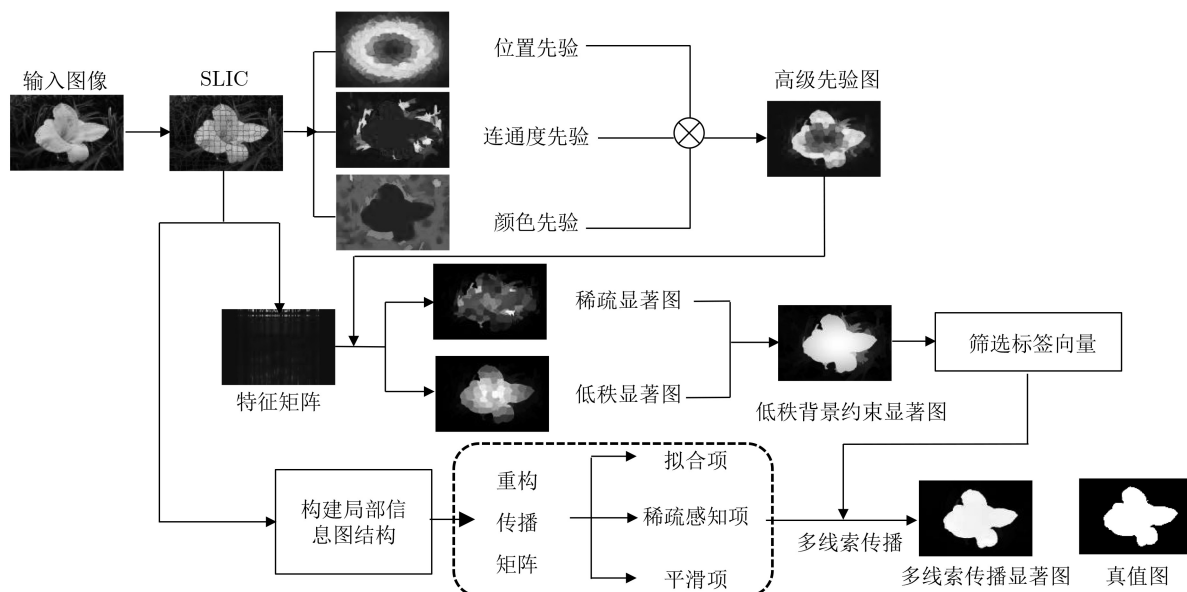


图1 基于低秩背景约束与多线索传播的显著性检测算法框架

(Simple Linear Iterative Clustering, SLIC)算法^[14]将输入图像分割成 n 个超像素块 $\mathbf{K} = [\mathbf{k}_1 \mathbf{k}_2 \cdots \mathbf{k}_n]$, 提取超像素特征, 构成53维特征向量 \mathbf{a}_i , 特征矩阵 $\mathbf{A} = [\mathbf{a}_1 \mathbf{a}_2 \cdots \mathbf{a}_n]$ 。图像显著区域通常是稀疏的, 而背景区域位于低维特征子空间中, 低秩表示能够充分挖掘图像子空间关系, 因此显著性检测问题可转化为低秩分解, 即将特征矩阵分解为低秩矩阵 \mathbf{L} 和稀疏矩阵 \mathbf{E} , 如式(1)

$$\min_{\mathbf{L}, \mathbf{E}} \text{rank}(\mathbf{L}) + \lambda \|\mathbf{E}\|_0, \quad \text{s.t. } \mathbf{A} = \mathbf{L} + \mathbf{E} \quad (1)$$

其中, rank 代表 \mathbf{L} 的秩, $\|\cdot\|_0$ 表示 l_0 范数, λ 是权衡 \mathbf{L} 和 \mathbf{E} 的参数。将上式的稀疏矩阵 \mathbf{E} 进行 l_1 范数约束, 改写为

$$\min_{\mathbf{L}, \mathbf{E}} \|\mathbf{L}\|_* + \lambda \|\mathbf{E}\|_1, \quad \text{s.t. } \mathbf{A} = \mathbf{L} + \mathbf{E} \quad (2)$$

其中, $\|\cdot\|_*$ 表示矩阵奇异值的和, $\|\cdot\|_1$ 表示 l_1 范数。为提高特征矩阵的分解能力, 深入探究图像的子空间结构, 严格分解出低秩矩阵与稀疏矩阵, 扩展经典的低秩分解模型, 使用背景高级先验约束低秩分解^[11]

$$\min_{\mathbf{L}, \mathbf{E}} \|\mathbf{L}\|_* + \lambda \|\mathbf{E}\|_1, \quad \text{s.t. } \mathbf{P}_w \circ \mathbf{A} = \mathbf{P}_w \circ \mathbf{L} + \mathbf{E} \quad (3)$$

其中, \circ 表示矩阵元素对应相乘, \mathbf{P}_w 是背景先验加权矩阵。加权矩阵分配给显著目标很小的权重, 使得分解出的稀疏矩阵对应向量的 l_1 范数较小, 进而更加有效地突出显著目标。

3.1.2 建立背景加权约束矩阵

位置、颜色、边界连通度先验等视觉先验可以在特征空间中提供相关性, 背景视觉先验约束图像特征矩阵的分解, 提高低秩矩阵和稀疏矩阵的辨别度, 特别是当低秩矩阵与稀疏矩阵存在高度一致性时, 也能较好地实现两者的分离。

(1) 背景位置先验: 人类容易被位于图像中心的目标吸引, 而远离图像中心的目标更可能属于背景。对于超像素 \mathbf{k}_i , 背景位置先验可以表示为

$$\text{LP}(i) = 1 - e^{-\frac{d(\mathbf{p}_i, \mathbf{c})}{\sigma}} \quad (4)$$

其中, $d(\mathbf{p}_i, \mathbf{c})$ 表示超像素的中心位置 \mathbf{p}_i 与图像中心位置 \mathbf{c} 的平均距离, σ 是控制两者间平均距离的常量。

(2) 背景颜色先验: 依据文献^[15], 人眼具有对暖色调较为敏感的特点, 该特性称为颜色先验, 将颜色先验 \mathbf{C}_i 取反得到背景颜色先验值

$$\text{CP}(i) = 1 - \mathbf{C}_i \quad (5)$$

(3) 背景边界连通度先验: 背景区域与图像边界相连接的概率更大, 使用超像素与边界超像素集合的交集长度量化背景边界连通度 $\text{BP}(i)$

$$\text{BP}(i) = \frac{1}{1 + \exp\left(-\frac{|\mathbf{k}_i \cap \mathbf{B}|}{\mathbf{R}(i)}\right)} \quad (6)$$

其中 \mathbf{B} 表示边界超像素的集合, $|\cdot|$ 表示交集的长度, $\mathbf{R}(i)$ 表示超像素 \mathbf{k}_i 的像素数。将上述的初级背景先验融合, 获得背景高级先验 $\mathbf{P}_w(i) = \text{LP}(i) \times \text{CP}(i) \times \text{BP}(i)$, 图2展示了4种先验图的可视化结果。为了提高表达和计算的便捷性, 将高级先验集合成加权矩阵 \mathbf{P}_w , 如式(7)所示, 矩阵的每个元素分布在 $[0,1]$ 之间。

$$\mathbf{P}_w = \begin{bmatrix} \mathbf{P}_w(1) & \mathbf{P}_w(2) & \cdots & \mathbf{P}_w(N) \\ \mathbf{P}_w(1) & \mathbf{P}_w(2) & \cdots & \mathbf{P}_w(N) \\ \vdots & \ddots & \ddots & \vdots \\ \mathbf{P}_w(1) & \cdots & \mathbf{P}_w(N) \end{bmatrix} \quad (7)$$

求解式(3)得到稀疏矩阵 \mathbf{E} , 其第 i 列的 l_1 范数表示 \mathbf{k}_i 的显著值 $\text{SM}(\mathbf{k}_i)$, 对其平滑处理得到初始显著图 $\mathbf{S}_{\text{stage1}}$ 。

$$\text{SM}(\mathbf{k}_i) = \|\mathbf{E}_i\|_1 \quad (8)$$

3.2 基于多线索传播机制的显著性检测

基于低秩背景约束的显著性检测算法充分挖掘了图像的空间结构信息, 其假设稀疏矩阵中每个节点之间是独立的, 为了避免生成的显著区域不均匀, 深入探究节点之间的关系, 提出稀疏感知与局部平滑相结合的多线索传播机制, 进一步增强前景背景的差异, 提高显著性检测的准确率。

3.2.1 建立局部信息图结构

特征矩阵存储了图像的主要信息, 但无法揭示超像素对之间的邻接关系。为了探索超像素对之间的关系, 建立局部信息图结构 $\mathbf{G}(\mathbf{V}, \mathbf{E}_1)$, 其节点为 $\mathbf{V} = [\mathbf{v}_1 \mathbf{v}_2 \cdots \mathbf{v}_n]$, \mathbf{E}_1 为节点间的边界。相邻节点最有可能共享相似的显著值, 将每个节点都与其相邻节点相连; 为减少节点间的测地距离, 将边界区域的每对节点彼此连接。该局部信息图结构将局部邻域节点约束在相同范围内, 鼓励局部近邻的节点分组。每对节点之间的权重 w_{ij} 如式(9), \mathbf{c}_i 和 \mathbf{c}_j 分别是 \mathbf{v}_i 和 \mathbf{v}_j 在Lab颜色空间的平均值, σ_1 为控制颜色相似性强度的参数



(a) 原图 (b) 位置先验图 (c) 连通度先验图 (d) 颜色先验图 (e) 高级先验图

图2 先验图可视化结果

$$w_{ij} = \exp\left(-\frac{\|c_i - c_j\|}{\sigma_1}\right) \quad (9)$$

3.2.2 构建多线索传播机制

传统的流形排序包含拟合项 $\sum_{i,j=1}^n (s_i - y_i)^2$ 和标准平滑项 $\frac{1}{2} \sum_{i,j=1}^n w_{ij}(s_i - s_j)^2$ ，其中 $s = [s_1 s_2 \dots s_n]^T$ 表示节点的排序值， $y = [y_1 y_2 \dots y_n]^T$ 为指示向量，其忽视了感知线索的运用，有时不能将前景与背景准确地分离开，同时仅使用标准的平滑项导致孤立节点从其他节点中获取的显著信息极少，造成图像显著信息的缺失，影响显著信息的传播，因此引入稀疏感知项和局部平滑项，提出多线索的传播机制。

节点的稀疏性主要取决于与节点相连的边界数量，而图模型边界构建的准则恰能契合稀疏感知的原则：(1)背景区域通常面积大且具有同质性，背景节点中颜色相似的数量多于显著目标，进而背景节点中的边界数量要多于显著目标；(2)构建的图模型边界将所有的图像边界节点连接起来，与背景相关的边界数量要多于显著目标。稀疏感知特性专注颜色空间中节点的独特性，尽可能突出颜色特征出现概率低的节点，进而突出前景节点。利用节点间的颜色相似性衡量节点的稀疏性大小，稀疏值表示为 $R_p = \text{diag}(r_{11} r_{22} \dots r_{nn})$ ，式(10)展示了节点 v_i 的稀疏值 r_{ii} ，由于背景节点分配到的稀疏值较大，提出稀疏感知项 $\sum_{i=1}^n r_{ii} s_i^2$

$$r_{ii} = \begin{cases} \sum_{j=1}^n \exp\left(-\frac{\|c_i - c_j\|}{\sigma_1}\right), & (v_i, v_j) \in E_1 \\ 0, & \text{其他} \end{cases} \quad (10)$$

为了提高图像中孤立节点分类的准确率，设计局部平滑项 $\sum_{i=1}^n \left(1 - \frac{d_{ii}}{z}\right) s_i^2$ ，评估节点 v_i 与其相

邻节点之间的平滑度，使得与局部区域内其他节点连接强度较大的节点可以获得可靠的排序值， $d_{ii} = \sum_j w_{ij}$ 记录节点 v_i 与其邻域的连接强度， $z = \sum_{i=1}^n d_{ii}$ 。将节点 v_i 与其邻域作为一个整体，加强对局部区域内节点间关系的探索，有效防止不同类节点过度传播。改进的局部平滑传播机制相关节点的处理如图3所示，局部平滑项的引入能够加强局部区域内的关联性，使“滑雪者”两腿之间的局部节点正确分类，提高了检测的准确性。

将稀疏感知和局部平滑约束融入流形排序算法中，提出多线索传播机制，如式(11)

$$s = \arg \min_s \left\{ \eta s^T M S + \theta s^T \left(I - \frac{D}{z} \right) s + \varepsilon (s - y)^T \cdot (s - y) + \gamma s^T R_p s \right\} \quad (11)$$

其中， η 和 θ 是控制全局和局部平滑项比重的参数， ε 和 γ 是控制拟合项和稀疏感知项的权重， M 为拉普拉斯矩阵， $D = \text{diag}(d_{11} d_{22} \dots d_{nn})$ 为置信度矩阵， I 为单位阵。经化简，得式(12)

$$s = \left[\eta M + \theta \left(I - \frac{D}{z} \right)^{-1} + \varepsilon I + \gamma R_p \right]^{-1} y \quad (12)$$

其实质是重构传播矩阵 $A^* = \left(\eta M + \theta \left(I - \frac{D}{z} \right)^{-1} + \varepsilon I + \gamma R_p \right)^{-1}$ ，最大程度地凸显节点的属性。指示向量 y 的确定需借助初始显著值，筛选大于阈值 th 的超像素作为前景节点。图4展示了算法重要步骤的结果

$$th = 0.7 \max(S_{\text{stage1}}(k_i)) \quad (13)$$

4 实验结果与分析

4.1 数据集与评价指标

为评估算法的性能，在ECSSD, MSRA-10K,




图3 改进的局部平滑传播机制相关节点处理




图4 基于低秩背景约束与多线索传播的图像显著性检测算法重要步骤结果图

DUT-OMRON等3个数据集进行实验, 这3个数据集均配有人工标注的真值图(Ground Truth, GT)。引入准确率(Precision, P)、召回率(Recall, R)、 F_β 测度(F-measure)以及平均绝对误差(Mean Absolute Error, MAE)等指标, 分别利用多阈值和自适应阈值分割得到二值图, 与真值图进行比较得到 P 和 R , 绘制 P - R 曲线和 P, R, F 柱状图, 其中 F_β 为

$$F_\beta = \frac{(1 + \beta^2)P \times R}{\beta^2 \times P + R} \quad (14)$$

其中, $\beta^2 = 0.3$, 平均绝对误差MAE衡量显著图 S 与真值图GT之间的差距

$$\text{MAE} = \frac{1}{N_W \times N_H} \sum_{x=1}^{N_W} \sum_{y=1}^{N_H} |S(x, y) - \text{GT}(x, y)| \quad (15)$$

其中, N_W 和 N_H 分别表示显著图的宽度和高度。

4.2 性能比较

所有算法均在Intel Core i5-5300U 2.3 GHz处理器、8 GB内存、64 bit Windows8环境下的MATLAB R2015a实现。

4.2.1 定性比较

图5展示了本文算法与GS, WLRR, GBMR, MPD, TLLT的可视化比较。第1行是单目标图像, 第2行是背景复杂的图像, 第3行是前景背景对比度低的图像, 第4行是多目标图像, 第5行是显著目标接触边界的图像。GS算法能检测出显著目标的大致轮廓, 却难以抑制背景, WLRR算法在前景背景对比度较低时, 易受背景干扰。GBMR, MPD, TLLT算法在检测多目标图像时存在虚影现象。本文算法能有效处理背景复杂的场景, 原因在于子空间关系的挖掘增强了前景与背景的差异性; 对小显著区域


的检测效果良好, 如第1行的图像不仅能使显著目标高亮一致, 还能准确处理胳膊与头之间的缝隙, 这是由于局部平滑项的引入加强了局部区域内节点的联系; 借助于提出的稀疏感知线索, 可以检测出前景背景对比度低的情景, 还可以检测图像中的多个显著目标。总之, 本文算法能更好地突出所有显著目标, 具有优越性能。

4.2.2 定量比较

图6—图8从 P - R 曲线、 F 曲线、自适应阈值下的 P, R, F 值和MAE等方面, 在3个数据集上进行了定量比较。在ECSSD数据集和MSRA-10K数据集, 本文算法的 P - R 曲线在召回率较高时保持较高的准确率, F 曲线在很大阈值跨度上具有最大值, 且平均绝对误差均最小, 更接近真值图; 在DUT-OMRON数据集, 本文算法的 P - R 曲线包围大部分对比算法的 P - R 曲线, 分割阈值大于150时, 具有最大的 F 值, 且MAE最小。自适应阈值分割时, ECSSD, DUT-OMRON数据集的平均召回率最高。综上所述, 本文所提算法凭借子空间结构信息和稀疏感知与局部平滑策略重构的传播矩阵, 获得了较好的检测结果。

4.2.3 验证稀疏感知项和局部平滑约束的有效性

为验证所提稀疏感知项和局部平滑约束的有效性, 在ECSSD数据集依次进行了WLRR算法、传统流形排序细化算法、改进的稀疏感知传播机制、改进的局部平滑传播机制、本文算法等5个实验, 不同方案下的 P - R 曲线如图9所示。WLRR算法的检测能力最差, 其次是传统流形排序细化算法, 改进的稀疏传播机制和改进的局部平滑传播机制的 P - R 曲线均高于前两种算法。融合稀疏感知与局部平



(a) 输入图像 (b) GS (c) GBMR (d) MPD (e) TLLT (f) WLRR (g) 本文算法 (h) GT

图5 各算法视觉对比示例

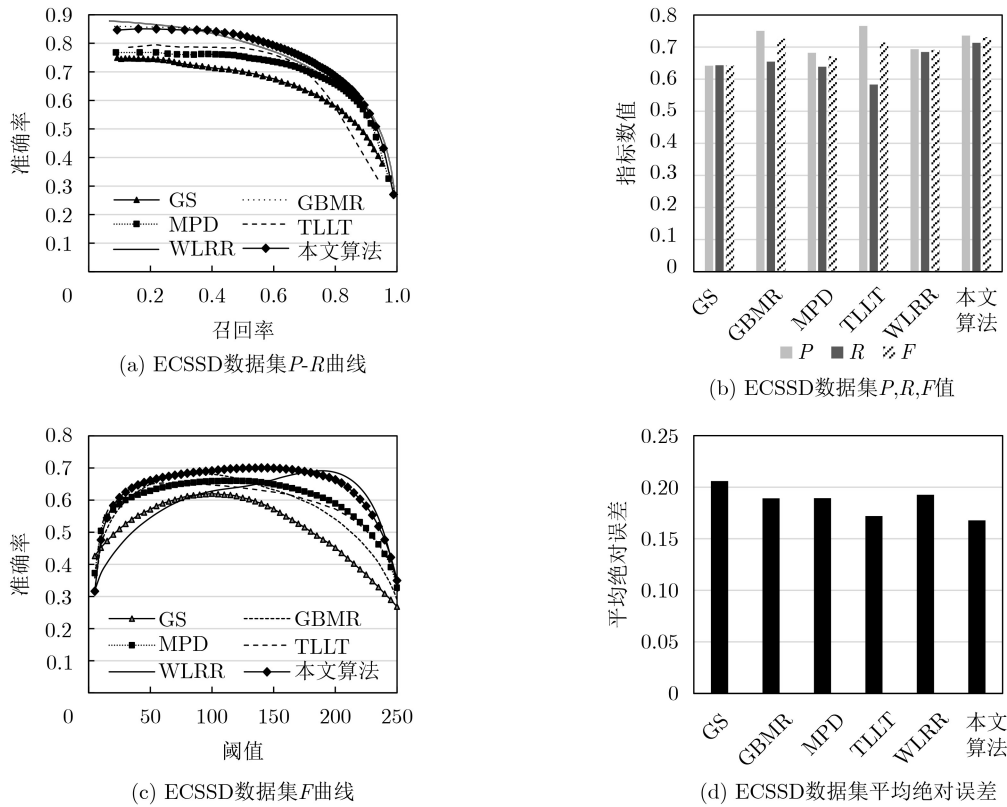


图6 ECSSD数据集定量评价对比

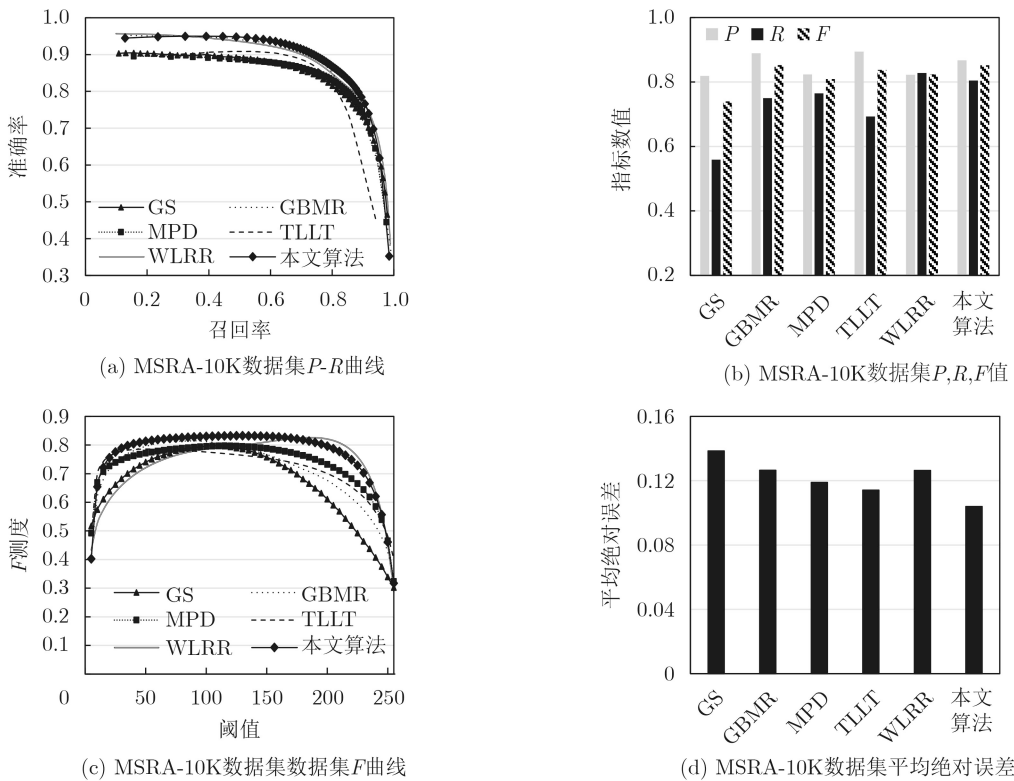


图7 MSRA-10K数据集定量评价对比

滑策略的多线索传播机制的P-R曲线下下降较缓慢，左侧顶端较高，包围其他4个实验的大部分曲线，兼顾了准确率和召回率。

4.3 时间比较

将本文算法在ECSSD数据集的平均运行时间与5种算法对比，如表1所示。本文算法在执行背景

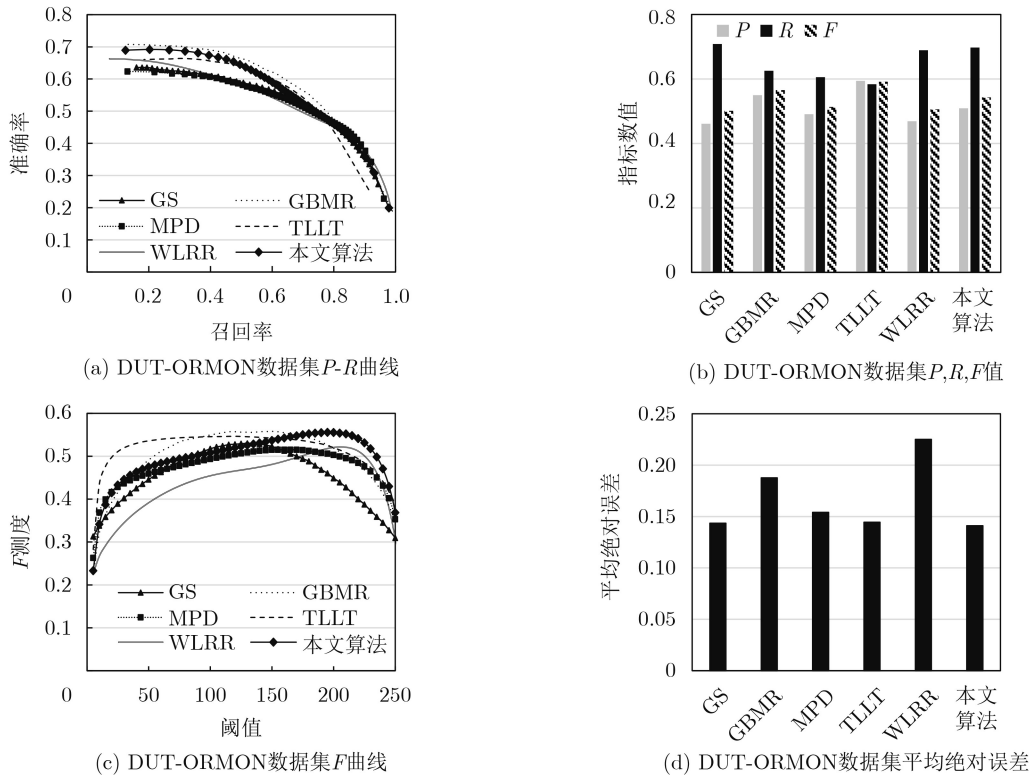


图8 DUT-ORMON数据集定量评价对比

约束、特征矩阵分解、重构传播矩阵后，运行时间仍比MPD,TLLT算法少，综合比较，本文算法性能优越。

4.4 应用于图像检索的性能分析

将所提算法应用于图像检索技术，在具有1000张图像、10个类别的Corel数据集进行图像检索。图10、图11分别展示了基于整体图像和基于显著

图的检索结果，其中每一行的第1列图像为待检索图像，按顺序返回与待检索图像最相似的9张图像。基于显著图的检索不仅能够凸出图像的显著特征，降低背景的干扰，提高了图像检索的准确率，在运行时间方面表现仍然突出，表2对比了两种检索方法的平均运行时间。

5 结束语

本文提出了一种低秩背景约束与多线索传播的显著性检测算法，兼顾了图像子空间结构和图节点间的关系。利用低秩背景约束有效地区分了前景和背景，筛选出优质的指示向量，在改进的传播矩阵中嵌入稀疏感知特性与局部平滑约束，提高了颜色特征出现概率低的节点的传播能力，探索了局部区




图9 ECSSD数据集不同方案下的P-R曲线


表1 不同算法运行时间对比

方法	GS	GBMR	MPD	TLLT	WLRR	本文算法
时间(s)	0.24	0.33	3.29	2.73	1.98	2.18



(a) 待检索图像 (b) 排序1 (c) 排序2 (d) 排序3 (e) 排序4 (f) 排序5 (g) 排序6 (h) 排序7 (i) 排序8 (j) 排序9

图10 基于整体图像的图像检索结果



(a) 待检索图像 (b) 排序1 (c) 排序2 (d) 排序3 (e) 排序4 (f) 排序5 (g) 排序6 (h) 排序7 (i) 排序8 (j) 排序9

图 11 基于显著图的图像检索结果

表 2 两种图像检索方法的平均运行时间(s)

类别	基于整体图像的检索运行时间	基于显著图的检索运行时间
花朵	167.59	92.68
美食	140.15	83.42

域内节点的关联性, 改善了节点间传播不准确的问题。实验证明本文算法在3个数据集上均具有优势, 尤其是图像中有多个显著目标时, 检测能力更为突出。未来考虑其他感知线索优化传播机制, 进一步改善节点的传播效果。

参考文献

- [1] DENG Cheng, YANG Xu, NIE Feiping, *et al.* Saliency detection via a multiple self-weighted graph-based manifold ranking[J]. *IEEE Transactions on Multimedia*, 2020, 22(4): 885–896. doi: [10.1109/TMM.2019.2934833](https://doi.org/10.1109/TMM.2019.2934833).
- [2] JAEMSIRI J, TITIJARONROJ T, and RUNGRATTANAUBOL J. Modified scale-space analysis in frequency domain based on adaptive multiscale Gaussian filter for saliency detection[C]. The 2019 16th International Joint Conference on Computer Science and Software Engineering, Chonburi, Thailand, 2019: 218–223. doi: [10.1109/JCSSE.2019.8864211](https://doi.org/10.1109/JCSSE.2019.8864211).
- [3] WANG Chengjia, DONG Shizhou, ZHAO Xiaofeng, *et al.* SaliencyGAN: Deep learning semisupervised salient object detection in the fog of IoT[J]. *IEEE Transactions on Industrial Informatics*, 2020, 16(4): 2667–2676. doi: [10.1109/TII.2019.2945362](https://doi.org/10.1109/TII.2019.2945362).
- [4] SRIVASTAVA G and SRIVASTAVA R. An efficient modification of generalized gradient vector flow using directional contrast for salient object detection and intelligent scene analysis[J]. *Multimedia Tools and Applications*, 2020, 79(19): 13599–13619. doi: [10.1007/s11042-020-08609-y](https://doi.org/10.1007/s11042-020-08609-y).
- [5] HUO Shuwei, ZHOU Yuan, XIANG Wei, *et al.* Semisupervised learning based on a novel iterative optimization model for saliency detection[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2019, 30(1): 225–241. doi: [10.1109/TNNLS.2018.2809702](https://doi.org/10.1109/TNNLS.2018.2809702).
- [6] 李炜, 李全龙, 刘政怡. 基于加权的K近邻线性混合显著性目标检测[J]. *电子与信息学报*, 2019, 41(10): 2442–2449. doi: [10.11999/JEIT190093](https://doi.org/10.11999/JEIT190093).
- [7] LI Wei, LI Quanlong, LIU Zhengyi, *et al.* Salient object detection using weighted k-nearest neighbor linear blending[J]. *Journal of Electronics and Information Technology*, 2019, 41(10): 2442–2449. doi: [10.11999/JEIT190093](https://doi.org/10.11999/JEIT190093).
- [8] WEI Yichen, WEN Fang, ZHU Wangjiang, *et al.* Geodesic saliency using background priors[C]. The 12th European Conference on Computer Vision, Florence, Italy, 2012: 29–42. doi: [10.1007/978-3-642-33712-3_3](https://doi.org/10.1007/978-3-642-33712-3_3).
- [9] TANG Chang, WANG Pichao, ZHANG Changqing, *et al.* Salient object detection via weighted low rank matrix recovery[J]. *IEEE Signal Processing Letters*, 2017, 24(4): 490–494. doi: [10.1109/lsp.2016.2620162](https://doi.org/10.1109/lsp.2016.2620162).
- [10] 张文明, 姚振飞, 高雅昆, 等. 一种平衡准确性以及高效性的显著性目标检测深度卷积神经网络模型[J]. *电子与信息学报*, 2020, 42(5): 1201–1208. doi: [10.11999/JEIT190229](https://doi.org/10.11999/JEIT190229).
- [11] ZHANG Wenming, YAO Zhenfei, GAO Yakun, *et al.* A deep convolutional network for saliency object detection with balanced accuracy and high efficiency[J]. *Journal of Electronics & Information Technology*, 2020, 42(5): 1201–1208. doi: [10.11999/JEIT190229](https://doi.org/10.11999/JEIT190229).
- [12] YANG Chuan, ZHANG Lihe, LU Huchuan, *et al.* Saliency detection via graph-based manifold ranking[C]. 2013 IEEE Conference on Computer Vision and Pattern Recognition, Portland, USA, 2013: 3166–3173. doi: [10.1109/CVPR.2013.407](https://doi.org/10.1109/CVPR.2013.407).
- [13] FU Keren, GU I Y H, GONG Chen, *et al.* Robust manifold-preserving diffusion-based saliency detection by adaptive weight construction[J]. *Neurocomputing*, 2016, 175: 336–347. doi: [10.1016/j.neucom.2015.10.066](https://doi.org/10.1016/j.neucom.2015.10.066).
- [14] TAO Dapeng, CHENG Jun, SONG Mingli, *et al.* Manifold ranking-based matrix factorization for saliency detection[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2016, 27(6): 1122–1134. doi: [10.1109/TNNLS.2015.2461554](https://doi.org/10.1109/TNNLS.2015.2461554).
- [15] GONG Chen, TAO Dacheng, LIU Wei, *et al.* Saliency propagation from simple to difficult[C]. 2015 IEEE Conference on Computer Vision and Pattern Recognition, Boston, USA, 2015: 2531–2539. doi: [10.1109/cvpr.2015.7298868](https://doi.org/10.1109/cvpr.2015.7298868).

- [14] 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. doi: [10.1109/tpami.2012.120](https://doi.org/10.1109/tpami.2012.120).
- [15] ZHANG Jun, WANG Meng, ZHANG Shengping, *et al*. Spatiochromatic context modeling for color saliency analysis[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2016, 27(6): 1177–1189. doi: [10.1109/tnnls.2015.2464316](https://doi.org/10.1109/tnnls.2015.2464316).
- 唐红梅: 女, 1968年生, 副教授, 研究方向为数字图像处理、模式识别.
- 白梦月: 女, 1995年生, 硕士生, 研究方向为数字图像处理、模式识别.
- 韩力英: 女, 1977年生, 讲师, 研究方向为图像处理、机器学习.
- 梁春阳: 男, 1996年生, 硕士生, 研究方向为数字图像处理、模式识别.

责任编辑: 余 蓉