

# 基于元胞自动机的显著性检测（中文翻译版）

秦瑶 卢湖川 徐逸群 王贺  
大连理工大学

## Abstract

本文我们应用元胞自动机——一种动态更新机制直观地检测显著目标。首先，我们构建了一个基于背景的显著性图。这个显著性图是通过和分类的边缘种子进行颜色空间和距离空间上的对比得到的。然后我们提出了一种基于元胞自动机的新型传播机制，并通过邻居间的相互交流来探索相似区域之间的固有关联。我们通过构建影响因子矩阵和置信度矩阵来平衡不同元胞对每个元胞下一状态的影响力。所有元胞的显著性值会依据所提出的更新原则同步更新。我们发现无论现有算法的原始结果怎样，同步更新机制都可以将他们的结果优化提高到一个相似的水平。最后，我们提出了一种基于贝叶斯理论的融合算法去利用不同算法得到的显著性图的优点。在六个公开数据库上的大量实验表明我们所提出的算法要优于迄今为止最先进的方法。

## 1. 引言

最近，致力于找到图像中最重要部分的显著性检测已经在计算机视觉领域越来越普及 [1, 14]。作为图像预处理过程，显著性检测可以被应用于很多视觉工作，比如视觉跟踪 [26]，目标重定位 [11, 39]，图像分类 [37] 和图像分割 [35]。

通常，显著性检测的方法可以被分为自上而下或者自下而上两种。自上而下的方法 [3, 27, 31, 50] 是任务驱使型，需要人工标注的真值图并进行监督训练。为了更好地从背景中辨别显著物体，我们需要应用高级信息和监督方法来提高显著性图的准确率。相反，自下而上的方法 [15, 18, 22, 40, 41, 48] 通常利用低级线索，比如特征，颜色和空间距离来构建显著性图。一种应用最多的原则是对比度优先原则。这种原则主要是通过计算一个区域和周围环境的颜色对比度和空间对比度来得到该区域的显著性值 [7, 8, 18, 21, 22, 33, 43]。另外，还有一些方法是基于边缘优先性。它们假设图像边缘的区域更加有可能成为背景 [19, 23, 44, 49]。诚然，图像的边缘有很大的可能成为背景，这在引文 [5, 36] 中有所证明。但是，像之前大多数方法那样，将图像边缘上所有的点都归为背景点并不合理。如果目标物体出现在图像的边缘，被选作背景的种子就会不准确并直接导致结果的错误。

在这篇文章中，我们提出有效的方法来解决上述

的问题。首先，我们应用 K-means 算法将图像的边缘分为不同的类别。由于每一个边缘类的紧密度，我们可以产生不同却互补的颜色差异图，并利用空间距离将它们结合在一起。然后，我们引入基于元胞自动机 [42] 的传播机制来加强相似图像区域间的显著性值的一致性。通过邻居间的相互影响，错误地被选为背景种子的元胞将会自动调整它们的显著性值。最后，我们应用单层元胞自动机去优化现有的算法以产生更好的结果。

在显著性检测领域已有很多有效的算法，每种算法都有他们各自的优点 [7, 17, 23, 33, 52]。为了结合不同方法的优点，我们提出了一种名为多层元胞自动机的融合模型。多层元胞自动机将不同的显著性图作为输入，融合后得到的结果优于至今最先进的方法。

简而言之，本文的主要贡献包括：

- 1)、我们提出一种有效的算法来融合全局差异矩阵，并应用元胞自动机去利用局部相似性来优化初始的显著性图。
- 2)、单层元胞自动机可以极大地提高现有算法得到的结果。并且无论原来的显著性图的准确率如何，都可以将其提高到一个相似的准确率水平。
- 3)、基于贝叶斯理论的多层元胞自动机可以融合多幅显著性图并得到一个更好的结果。

## 2. 相关工作

近来，越来越多的自下而上的方法偏向于通过选择图像的边缘作为背景种子来构建显著性图。考虑到背景区域的联系性，Wei 等人 [44] 将每一个区域与图像边缘的最短距离定义为它们的显著性值。在 [19] 中，与图像边缘的对比构成了一个新的区域特征向量。该向量被用来表示背景的特征。在 [49] 中，Yang 等人通过流形排序计算每个图像区域与图像边缘的相关性，并以此作为每个区域的显著性值。在 [52] 中，一个更加稳定的基于边缘的算法考虑了图像区域的空间分布。

另外，一些有效的算法是基于贝叶斯理论提出的。在 [34] 中，Rahtu 等人最先应用贝叶斯理论来优化显著性图并取得了很好的结果。在 [46, 47] 中，Xie 等人应用从凸包中得到的低级图像线索来计算观测似然度。在 [51] 中，鉴于视觉特征的自信息，在贝叶斯理论的框架下，显著性目标会自然出现。另外，Li 等人 [23] 通过密集和稀疏重建得到了显著性图，并提出了用贝叶斯算法来融合不同的显著性图。以上所有算

法都表明贝叶斯理论在显著性检测方面的有效性。

元胞自动机，最先在 [42] 中被提出，是一种有着简单的结构但是复杂的自组织行为的动态系统。这个模型由一个方形格子组成，格子上的元胞有着离散的状态。根据相应的规则，元胞可以在离散的时间步里不断更新自己的状态。每个元胞下一时刻的状态由它自己的当前状态和它邻居的当前状态共同决定。元胞自动机被应用于模拟很多复杂的动态系统的演化过程 [4, 9, 10, 28, 29]。考虑到显著物体总是倾向于聚集的，我们应用元胞自动机来探索邻居间的本质联系并减少相似区域间的差异性。结合贝叶斯理论，元胞自动机作为一种传播机制被引入这一领域，并可以很好地优化显著性图。

### 3. 算法

在这部分，基于分类的边缘种子，我们首先构建了全局颜色差异矩阵和空间距离矩阵，并将它们融合成一幅基于背景的显著性图。然后，我们利用基于元胞自动机的新型传播算法去探索相似区域间的本质联系。我们也更深入地讨论了这一算法在优化现有方法上的有效性和鲁棒性。

#### 3.1. 全局差异矩阵的融合

为了更好地获得图像固有的结构信息并提高计算效率，我们应用 SLIC 算法 [2] 将一幅图分割成  $N$  个小的超像素点，并应用像素点的平均颜色特征和平均坐标来描述每一个超像素点。为了获得更优化的背景种子，基于图像边缘点的 CIE LAB 色彩特征，我们运用 K-means 算法将图像的边缘分成  $K$  类。在这篇文章中，我们以经验为主地将边缘的种类数设置为  $K = 3$ 。属于第  $k$  类的超像素点的总数用  $p^k$  表示，其中  $k = 1, 2, \dots, K$ 。基于  $K$  个不同的类，我们可以构建  $K$  个不同的全局颜色差异图 (GCD)。在 GCD 矩阵  $\mathbf{S} = [s_{k,i}]_{K \times N}$  中，元素  $s_{k,i}$  表示在第  $k$  个 GCD 图中，元胞  $i$  的显著性值，可由以下公式计算得到：

$$s_{k,i} = \frac{1}{p^k} \sum_{j=1}^{p^k} \frac{1}{e^{-\frac{\|\mathbf{c}_i, \mathbf{c}_j\|}{2\sigma_1^2}} + \beta} \quad (1)$$

其中  $\|\mathbf{c}_i, \mathbf{c}_j\|$  是超像素点  $i$  和  $j$  在 CIE LAB 色彩空间中的欧式距离。我们将平衡权重值设置为  $\sigma_1 = 0.2$  和  $\beta = 10$ 。当  $\beta \in [7, 15]$  时，结果基本不变。

从图 1 中我们可以看出虽然基于边缘聚类得到的 GCD 图，结果并不让人满意，但是每幅图中都有一些高准确度的超像素点。由于优化后的每个边缘类里的超像素点有非常大的相似性， $K$  个 GCD 图之间相互互补。当一个超像素点的显著性值是基于离他最近的背景类计算时，它的显著性值就越准确。因此，我们构建了全局空间距离 (GSD) 矩阵  $\mathbf{W} = [w_{k,i}]_{K \times N}$  来权衡不同 GCD 图之间的重要性。 $w_{k,i}$  代表超像素点  $i$  和所有第  $k$  类背景点之间的空间距离。它可由下式计算得到：

$$w_{k,i} = \frac{1}{p^k} \sum_{j=1}^{p^k} e^{-\frac{\|\mathbf{r}_i, \mathbf{r}_j\|^2}{2\sigma_2^2}} \quad (2)$$

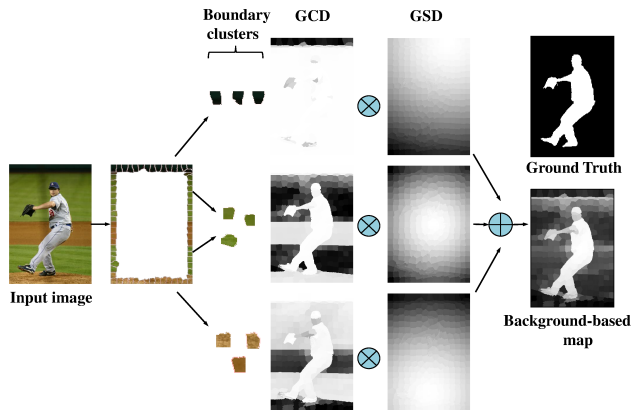


Figure 1. 公式 1 中全局颜色差异图 (GCD) 和公式 2 中全局空间距离差异图 (GSD) 的融合。

其中  $\mathbf{r}_i$  和  $\mathbf{r}_j$  是超像素点  $i$  和  $j$  的坐标， $\sigma_2$  是一个控制权重的常量。当  $\sigma_2 \in [1.1, 1.5]$  时，结果稳定不变。在这篇文章中，我们设置  $\sigma_2 = 1.3$ 。基于背景得到的显著性图  $\mathbf{S}^{bg} = [S_1^{bg}, \dots, S_N^{bg}]^T$  可以通过结合空间信息  $w_{k,i}$  和颜色信息  $s_{k,i}$  来计算：

$$S_i^{bg} = \sum_{k=1}^K w_{k,i} \times s_{k,i} \quad (3)$$

图 1 表明，用空间距离来约束 GCD 图，可以加强局部区域的对比，从而显著提高显著性值的准确性。通过有效地利用不同 GCD 图的优势，基于背景得到的显著性图就会更加的准确和令人信服。

#### 3.2. 基于元胞自动机的同步更新机制

在单层元胞自动机 (SCA) 中，每一个通过 SLIC 算法得到的超像素点代表一个元胞。我们对之前的模型 [38, 42] 主要做了三点修改。首先，在现有的元胞自动机模型中，元胞的状态都是离散的 [30, 45]。然而，在这篇文章中，我们用每一个超像素点的显著性值作为它的状态，这个值是 0 到 1 之间的连续值。其次，我们给邻居作了一个更为广泛的定义，这和图论中的  $z$  层邻居相似（在这里  $z = 2$ ）。一个元胞新定义的邻居包括它相邻的元胞以及和它相邻的邻居共有同一边缘的元胞。同时我们认为在图像边缘的超像素点是彼此相连的，因为他们都被当作背景种子。最后，不同于已有的元胞自动机模型，邻居的影响力并不是固定不变的。任何一对元胞之间的影响力与他们在色彩空间中的相似度紧密联系。

##### 3.2.1 影响因子矩阵

直观上，我们会认为如果一个邻居与某元胞有更相似的颜色特征，就会对该元胞下一时刻的状态产生更大的影响。任何一对超像素点的相似性是由 CIE LAB 色彩空间中所定义的距离来衡量的。我们通过定义超




Figure 2. 单层元胞自动机的作用。(a) 输入的图片 (b) 基于背景得到的显著性图 (c) 经过元胞自动机优化后的基于背景的显著性图 (d) 真值图。

像素点  $i$  对于超像素点  $j$  的影响因子  $f_{ij}$  来建立影响因子矩阵  $\mathbf{F} = [f_{ij}]_{N \times N}$ :

$$f_{ij} = \begin{cases} \exp\left(\frac{-\|\mathbf{c}_i, \mathbf{c}_j\|}{\sigma_3^2}\right) & j \in NB(i) \\ 0 & i = j \text{ or otherwise} \end{cases} \quad (4)$$

其中  $\|\mathbf{c}_i, \mathbf{c}_j\|$  代表 CIE LAB 色彩空间中超像素点  $i$  和  $j$  之间的欧式距离,  $\sigma_3$  是一个控制相似性力度的参数。我们像 [49] 一样, 设置  $\sigma_3^2 = 0.1$ 。  $NB(i)$  是元胞  $i$  的邻居的集合。为了归一化影响因子矩阵, 我们定义了度矩阵  $\mathbf{D} = \text{diag}\{d_1, d_2, \dots, d_N\}$ , 其中,  $d_i = \sum_j f_{ij}$ 。最后, 我们可以根据下式对影响因子矩阵进行行归一化:

$$\mathbf{F}^* = \mathbf{D}^{-1} \cdot \mathbf{F} \quad (5)$$

### 3.2.2 置信度矩阵

考虑到每个元胞下一时刻的状态是由它自己和它的邻居当前时刻的状态共同决定, 因此我们需要平衡这两个决定性的因素。一方面, 如果在颜色空间中, 一个超像素点和他的邻居有很大的差异, 那么它下一时刻的状态将会主要由它自己当前时刻的状态决定。另一方面, 如果一个元胞和它的邻居很相似, 那么它很有可能被局部的环境同化。因此, 我们建立了一个置信度矩阵  $\mathbf{C} = \text{diag}\{c_1, c_2, \dots, c_N\}$  去更好地促进所有元胞的更新演化。每个元胞对它自己当前时刻状态的置信度可由下式计算:

$$c_i = \frac{1}{\max(f_{ij})} \quad (6)$$

为了保证  $c_i \in [b, a + b]$ , 我们通过下式计算置信度矩阵  $\mathbf{C}^* = \text{diag}\{c_1^*, c_2^*, \dots, c_N^*\}$ :

$$c_i^* = a \cdot \frac{c_i - \min(c_j)}{\max(c_j) - \min(c_j)} + b \quad (7)$$

其中  $j = 1, 2, \dots, N$ 。我们分别将常数  $a$  和  $b$  设置为 0.6 和 0.2。如果  $a$  值固定为 0.6, 当  $b \in [0.1, 0.3]$  时,

结果基本不变。有了置信度矩阵  $\mathbf{C}^*$ , 每个元胞将会自动更新演化到一个更加准确和稳定的状态。在邻居的影响下, 显著目标将更容易被检测出来。

### 3.2.3 同步更新原则

在单层元胞自动机中, 所有的元胞根据更新原则同步更新他们的状态。给出影响因子矩阵和置信度矩阵后, 同步更新原则  $f: S^{NB} \rightarrow S$  即可定义如下:

$$\mathbf{S}^{t+1} = \mathbf{C}^* \cdot \mathbf{S}^t + (\mathbf{I} - \mathbf{C}^*) \cdot \mathbf{F}^* \cdot \mathbf{S}^t \quad (8)$$

其中  $\mathbf{I}$  是单位矩阵,  $\mathbf{C}^*$  和  $\mathbf{F}^*$  分别是置信度矩阵和影响因子矩阵。当  $t = 0$  时,  $\mathbf{S}^0$  就是公式 3 中的  $\mathbf{S}^{\text{bg}}$ 。经过  $N_1$  个时间步 (一个时间步被定义为对所有元胞的一次遍历更新), 我们可以得到最终的显著性图, 用  $\mathbf{S}^{N_1}$  表示。

基于大多数图像的本质特点, 我们提出了更新原则。首先, 属于前景的超像素点通常有相似的颜色特征。通过利用邻居间的固有联系, 单层元胞自动机可以加强相似区域的显著性值的一致性并形成稳定的局部环境。其次, 显著目标和其周围环境在颜色空间中有很大的差异性。通过相似邻居之间的影响, 在目标和背景之间会自然地出现一个明显的分界线。基于背景得到的显著性图被单层元胞自动机优化之后可以用 BSCA 来表示。图 2 表明单层元胞自动机可以很好地加强前景并抑制背景。

另外, 单层元胞自动机可以有效地解决在第 1 部分中提到的问题。当显著的超像素点被错误地选为背景种子时, 它们将会在局部环境的影响下自动地增加它们的显著性值。图 3 表明当目标物在图像边缘时, 本文算法仍然能够得到令人满意的结果。

### 3.2.4 优化现有算法

由于显著目标的连通性和紧密性, 经过更新演化后, 图像中显著的部分会自然地出现。不仅如此, 我们很惊奇的发现: 即使基于背景得到的显著性图的结果很差, 单层元胞自动机仍可以很准确地判断出显著物体, 正如图 4 (b) 所展现的一样。因此, 我们使用几种经典的算法得到的显著性图作为先验图, 并且依据同步更新原则不断更新每个元胞的显著性值。由不同的方法产生的显著性图被用来当作公式 8 中  $t = 0$  时的  $\mathbf{S}^t$ 。通过单层元胞自动机优化后的结果如图 4 所示。我们可以看出即使原来的显著性图并不好, 经过元胞自动机的更新演化后, 所有的结果都被提高到相似的准确度。这表明我们的模型并不依赖于先验图, 并且可以很好地优化现有的方法。

## 4. 多层元胞自动机

迄今为止, 在显著性检测领域有很多新颖的方法。不同的方法有他们各自的优点和缺点。为了利用每一种方法的优点, 我们提出了一种有效的方法去融合  $M$



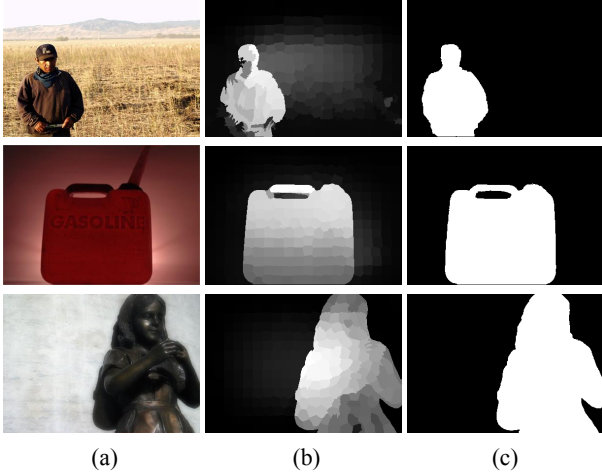


Figure 3. 当目标物体出现在图像边缘时的显著性图。(a) 输入图像 (b) 通过单层元胞自动机得到的显著性图 (c) 真值图。

种不同方法生成的  $M$  个显著性图。每一个显著性图就是一层元胞自动机。

在多层元胞自动机 (MCA) 中，每一个元胞代表一个像素点，一幅图中所有的元胞数为  $H$ 。我们用显著性值表示元胞的状态。不同于 3.2 部分中对邻居的定义，在多层元胞自动机中，不同显著性图中有着相同位置的像素点互为邻居。也就是说，对于任意一幅显著性图中的元胞，它们将有  $M-1$  个在其它显著性图上的邻居。我们假设所有的邻居对元胞下一时刻的状态有相同的影响力。像素点  $i$  的显著性值代表它成为前景  $F$  的可能性，用  $P(i \in F) = S_i$  表示，而  $1 - S_i$  表示它成为背景  $B$  的可能性，用  $P(i \in B) = 1 - S_i$  表示。我们用 OTSU [32] 算法产生的适应性阈值对每一幅图进行二值分割。阈值只和最初的显著性图有关，并且保持不变。第  $m$  幅显著性图的阈值用  $\gamma_m$  表示。如果像素点  $i$  在分割后被判断为前景，则被记为  $\eta_i = +1$ ，类似地，我们用  $\eta_i = -1$  表示像素点  $i$  二值化后被判为背景。一个像素点被判断为前景或者二值化为前景并不代表它真的属于前景，因为分割并不一定总是正确。如果一个像素点  $i$  属于前景，它的邻居  $j$ （在其它显著性图上有相同坐标的点）被判断为前景的概率为  $\lambda = P(\eta_j = +1 | i \in F)$ 。相应地， $\mu = P(\eta_j = -1 | i \in B)$  表示当像素点  $i$  属于背景时，它的邻居  $j$  被判断为背景  $B$  的概率。我们可以合理地做出假设， $\lambda$  和  $\mu$  是相等的且均为常量。后验概率  $P(i \in F | \eta_j = +1)$  可以通过下式计算：

$$P(i \in F | \eta_j = +1) \propto P(i \in F)P(\eta_j = +1 | i \in F) = S_i \cdot \lambda \quad (9)$$

为了避免归一化常数，我们将先验概率比例定义为  $\Lambda(i \in F)$ ，计算如下：

$$\Lambda(i \in F) = \frac{P(i \in F)}{P(i \in B)} = \frac{S_i}{1 - S_i} \quad (10)$$




Figure 4. 不同算法所得结果间的对比以及通过同步更新原则优化后所得结果的对比。(a) 第一行和第三行是输入图像，第二行和第四行是真值图。(b) - (e) 第一行和第三行是不同算法所得的原始结果。从左到右：基于背景得到的显著性图，通过 FT [1]，CA [13]，IT [16] 生成的显著性图。第二行和第四行是通过单层元胞自动机优化后得到的结果。

然后，后验概率比例  $\Lambda(i \in F | \eta_j = +1)$  就变成了：

$$\Lambda(i \in F | \eta_j = +1) = \frac{P(i \in F | \eta_j = +1)}{P(i \in B | \eta_j = +1)} = \frac{S_i}{1 - S_i} \cdot \frac{\lambda}{1 - \mu} \quad (11)$$

注意到第一项是先验概率比例，并且由于  $l = \ln(\Lambda)$  的变化是加法的，所以我们更容易对  $\Lambda$  进行对数运算。因此我们可以得到：

$$l(i \in F | \eta_j = +1) = l(i \in F) + \ln\left(\frac{\lambda}{1 - \mu}\right) \quad (12)$$

在这篇文章中，先验概率比例  $\Lambda(i \in F)$  和后验概率比例  $\Lambda(i \in F | \eta_j = +1)$  也被定义为：

$$\Lambda(i \in F) = \frac{S_i^t}{1 - S_i^t}, \quad \Lambda(i \in F | \eta_j = +1) = \frac{S_i^{t+1}}{1 - S_i^{t+1}} \quad (13)$$

其中  $S_i^t$  表示像素点  $i$  在  $t$  时刻的显著性值。我们将同步更新机制  $f: S^{M-1} \rightarrow S$  定义为：

$$l(\mathbf{S}_m^{t+1}) = l(\mathbf{S}_m^t) + \sum_{\substack{k=1 \\ k \neq m}}^M \text{sign}(\mathbf{S}_k^t - \gamma_k \cdot \mathbf{1}) \cdot \ln\left(\frac{\lambda}{1 - \lambda}\right) \quad (14)$$

其中  $\mathbf{S}_m^t = [S_{m1}^t, \dots, S_{mH}^t]^T$  表示  $t$  时刻时，第  $m$  幅显著性图上所有元胞的显著性值，并且矩阵  $\mathbf{1} = [1, 1, \dots, 1]^T$  共有  $H$  个元素。直观上看，如果一个像素点发现它的邻居被判为前景，它应该增加自己的显著性值。因此，公式 14 要求  $\lambda > 0.5$ ，则  $\ln(\frac{\lambda}{1-\lambda}) > 0$ 。在这篇文章中，我们经验性地设置  $\ln(\frac{\lambda}{1-\lambda}) = 0.15$ 。 $N_2$  个时间步后，我们可通过下式得到最终的显著性图  $\mathbf{S}^{N_2}$ ：

$$\mathbf{S}^{N_2} = \frac{1}{M} \sum_{m=1}^M \mathbf{S}_m^{N_2} \quad (15)$$




Figure 5. 应用贝叶斯理论得到的多层元胞自动机的效果。(a) 输入的图像。(b) - (f) 分别通过 HS [48], DSR [23], MR [49], wCO [52]和本文算法 BSCA 得到的显著性图。(g) 融合后得到的显著性图  $S^{N_2}$ 。(h) 真值。

在这篇文章中，我们应用多层元胞自动机来融合 HS [48], DSR [23], MR [49], wCO [52]和我们的算法 BSCA 得到的显著性图。通过图 5 我们可以很清楚地看到融合后的显著性图可以均匀地突出目标物，并且更加接近真值。

## 5. 实验评价

我们在六个标准数据库上对所提出的算法进行评价：ASD [1], MSRA-5000 [25], THUS [6], ECSSD [48], PASCAL-S [24] 和 DUT-OMRON [49]。ASD 是应用最广泛的数据库并且相对简单。MSRA-5000 包含了更多有着复杂背景的图片。THUS 是最大的数据库，包含了 10000 张图片。ECSSD 包含了 1000 张有不同大小且多种目标的图片。其中有一些图片取自于非常难的伯克利 300 数据库。PASCAL-S 来自于 PASCAL VOC 2010 [12]分割的数据库并包含了 850 张被复杂的背景围绕的自然图像。最后 DUT-OMRON 包含了 5168 张非常难的图片，这些图片有像素点级别的真值标注结果。

我们将本文算法和最经典的或者最先进的算法进行比较，这些算法包括 IT98 [16], FT09 [1], CA10 [13], RC11 [8], XL13 [47], LR12 [36], HS13 [48], UFO13 [20], DSR13 [23], MR13 [49], wCO14 [52]。不同方法的结果要么是由作者提供的，要么是通过运行可得到的代码和程序得到的。我们提出的算法的代码可以在我们的网站上得到。

### 5.1. 参数和评价标准

**实现细节** 在所有的实验中，我们将超像素点的总数设置为  $N = 300$ 。在单层元胞自动机中，遍历的总时间步为  $N_1 = 20$ 。在多层元胞自动机中，遍历的总时间步为  $N_2 = 5$ 。 $N_1$  和  $N_2$  分别由单层元胞自动机和多层元胞自动机的收敛时间决定。当动态系统达到稳定时，结果不再变化。

**评价标准** 我们通过标准的精确度—召回率曲线对所有的方法进行评价。通过从 0 到 255 之间设定阈值，我们可以对显著性图进行二值化，并将二值化后的结果与真值做比较。大多数时候，我们不仅需要高精度，也需要高的召回率，所以我们提出了 F-measure 作为整




Figure 6. 本文算法的效果。(a) 在 ASD 数据库上的 PR 曲线 (b) 在 MSRA-5000 数据库上的 PR 曲线。

体性能的评价机制。

$$F_{\beta} = \frac{(1 + \beta^2) \cdot \text{precision} \cdot \text{recall}}{\beta^2 \cdot \text{precision} + \text{recall}} \quad (16)$$

其中，我们根据引文 [1] 中的建议，设置  $\beta^2 = 0.3$  来突出精确度的重要性。作为对 PR 曲线的补充，我们也介绍了平均绝对误差 (MAE)。它是以像素点为单位地计算显著性图和真值  $GT$  之间的平均差异：

$$MAE = \frac{1}{H} \sum_{h=1}^H |S(h) - GT(h)| \quad (17)$$

这一评价方法可以显示出显著性图与真值之间的相似程度。它在不同的运用中起到很重要的作用，比如图像分割和图像裁剪 [33]。

### 5.2. 算法检验

为了证明本文算法的有效性，我们在 ASD 和 MSRA-5000 标准数据库上进行了测试。通过图 6 中的 PR 曲线可以看出：1) 基于背景得到的显著性图效果已经较为突出；2) 单层元胞自动机可以有效地提高基于背景的显著性图的准确度；3) 通过多层元胞自动机融合后所得到的显著性图更加准确。我们也在其他的数据库中进行了实验并得到了相似的结果，为了简洁未在此展示。

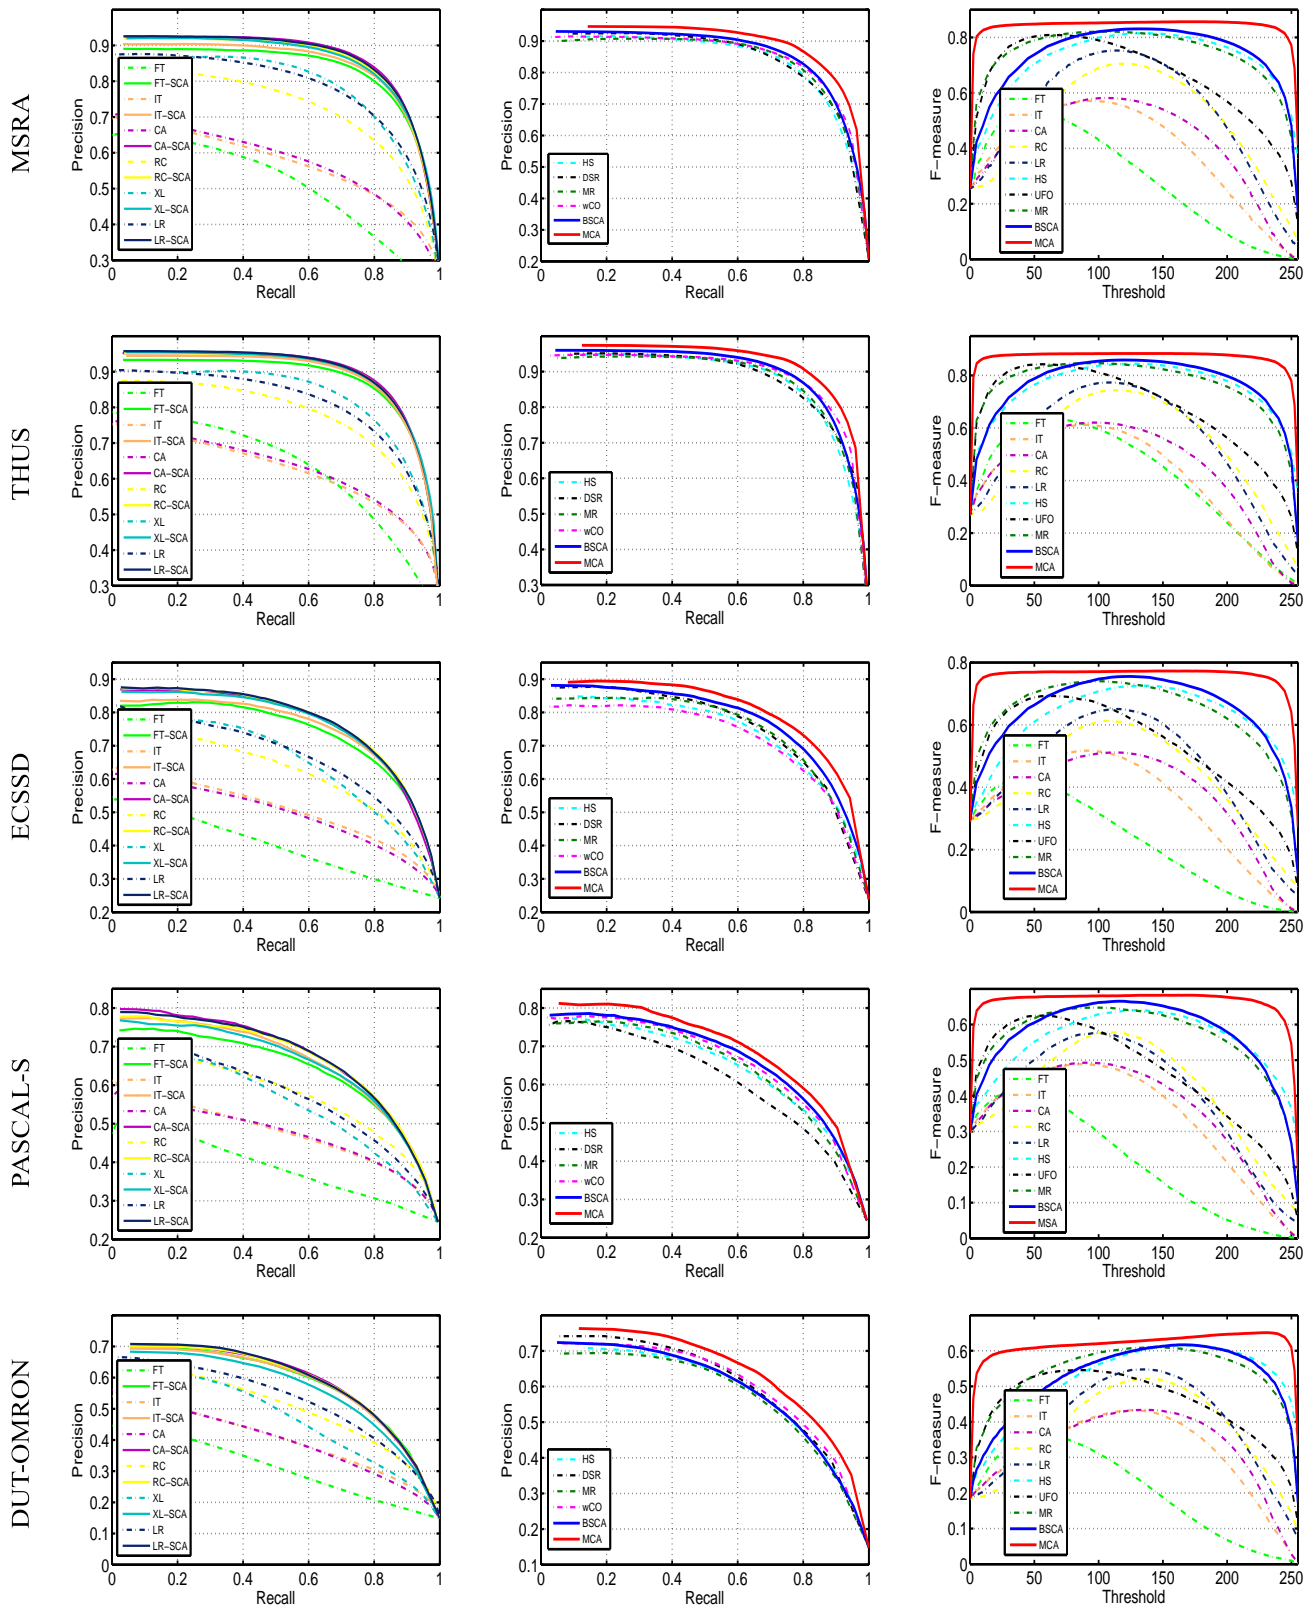



Figure 7. 不同算法的 PR 曲线和 F-measure 曲线以及它们经过单层元胞自动机优化后的 PR 曲线 (-SCA)。从上到下分别是在：MSRA, THUS, ECSSD, PASCAL-S 和 DUT-OMRON 数据库上测试。



	FT[1]	IT[16]	CA[13]	RC[8]	XL[47]	LR [36]	HS[48]	UFO [20]	BSCA	MCA
ASD	0.205	0.235	0.234	0.235	0.137	0.185	0.115	0.110	<b>0.086</b>	<b>0.039</b>
ASD*	0.083	0.098	0.093	0.084	0.082	0.083	0.073	0.073	-	-
MSRA	0.230	0.249	0.250	0.263	0.184	0.221	0.162	0.146	<b>0.131</b>	<b>0.078</b>
MSRA*	0.132	0.137	0.134	0.130	0.127	0.128	0.121	0.118	-	-
THUS	0.235	0.241	0.237	0.252	0.164	0.224	0.149	0.147	<b>0.125</b>	<b>0.076</b>
THUS*	0.128	0.125	0.129	0.125	0.121	0.126	0.117	0.116	-	-
ECSSD	0.272	0.291	0.310	0.302	0.259	0.276	0.228	0.205	<b>0.183</b>	<b>0.134</b>
ECSSD*	0.188	0.186	0.186	0.182	0.181	0.183	0.179	0.180	-	-
PASCAL-S	0.288	0.298	0.302	0.314	0.289	0.288	0.264	0.233	<b>0.225</b>	<b>0.180</b>
PASCAL-S*	0.227	0.225	0.225	0.220	0.226	0.223	0.220	0.215	-	-
DUT-OMRON	0.217	0.256	0.255	0.294	0.282	0.264	0.233	<b>0.180</b>	0.196	<b>0.138</b>
DUT-OMRON*	0.180	0.186	0.189	0.184	0.194	0.185	0.181	0.180	-	-

Table 1. 不同算法的 MAE 值以及他们经单层元胞自动机优化后的 MAE 值。不同算法的最初结果分别陈列在 ASD, MSRA, THUS, ECSSD, PASCAL-S 和 DUT-OMRON 行。最好的两个结果分别由红色和蓝色标注出来。不同方法优化后的结果分别陈列在 ASD\*, MSRA\*, THUS\*, ECSSD\*, PASCAL-S\* 和 DUT-OMRON\* 行。



(a) Input (b) FT (c) RC (d) LR (e) HS (f) UFO (g) wCO (h) BSCA (i) MCA (j) GT

Figure 8. 不同数据库上的显著性图的对比。BSCA: 用单层元胞自动机优化基于背景的显著性图。MCA: 通过多层元胞自动机融合不同方法得到的显著性图。GT: 真值。

### 5.3. 与现有最先进算法的比较

如图 7 所示, 相较于其他现有的算法, 在 5 个不同的数据库上, 我们提出的方法 BSCA 有着更高的精确度和召回率。并且这种方法与其他方法相比, 有更大范围的高 F-measure 值。不仅如此, 表格 1 所展示的相

当低的 MAE 值表明了我们的显著性图和真值的相似性。为了直观地进行结果间的比较, 我们在图 8 中展示了一些显著性图。

**现有算法的提高** 在 3.2.4 中我们可以看出, 通过单层元胞自动机可以有效地提高不同算法所得到的结果。

图 7 中的 PR 曲线和表格 1 中的 MAE 值比较了在不同的数据库上, 各种方法的结果以及各方法经过单层元胞自动机优化后的结果。PR 曲线和 MAE 值都表明 SCA 算法可以有效地将现有的结果提高到一个相似的准确度水平。即使输入的显著性图并不令人满意, 优化后所得结果基本可以达到现有最先进算法的水平。

**现有算法的融合** 在第 4 节中, 我们提出了一种新颖的算法来融合几种最先进的效果很好的算法。图 7 中的 PR 曲线有效地证明在 5 个数据库上, 多层元胞自动机比所有现有的算法有更高的准确度。并且, 图 7 中 MCA 的 F-measure 曲线稳定在一个很高的数值上, 并不随着阈值的变化而变化。另外, 如表 1 所示, 在不同的数据库上, 多层元胞自动机的平均绝对误差总是最低的。很低的平均绝对误差值表明融合后所得的显著性图非常接近于真值图。我们可以从图 8 中观察到由 MCA 产生的显著性图几乎与真值图一样。

#### 5.4. 运行时间

用 Matlab 在一个配置为 i7-4790k, 内存 16G-B, 4.00GHz CPU 的 PC 机上运行我们的程序, 除去划分超像素的时间, BSCA 算法处理 ASD 数据库上的一张图像平均耗时 0.470 秒。算法中的主要部分 SCA 处理一张图片平均耗时约 0.284 秒。同时, 多层元胞自动机 (MCA) 只平均耗时 0.043 秒就可以融合不同的算法并得到更好的显著性图。

## 6. 结论

在这篇文章中, 我们提出了一种新颖的自下而上的算法来构建基于背景的显著性图。该算法同时考虑了全局的色彩和空间距离矩阵。基于元胞自动机我们设计了一种直观的更新机制。该机制通过邻居间的相互交流来利用显著性目标内部的固有联系。这种基于环境的传播机制可以将任意现有的算法得到的结果提高到一个相似的准确度水平。不仅如此, 在贝叶斯理论的框架下, 我们提出了名为多层元胞自动机的融合算法。该算法可以结合不同先进的方法产生的显著性图的优点, 将他们融合成一幅具有更高准确度和召回率的显著性图。实验结果表明相较于其他现有的算法, 本文算法能够得到更好的结果。

**致谢:** 本文受到了国家自然科学基金 #61472060 和重点高校基础研究资金 DUT14YQ101 的支持。

## References

[1] R. Achanta, S. Hemami, F. Estrada, and S. Susstrunk. Frequency-tuned salient region detection. In *Computer Vision and Pattern Recognition, 2009. CVPR 2009. IEEE Conference on*, pages 1597--1604. IEEE, 2009. 1, 4, 5, 7

[2] R. Achanta, A. Shaji, K. Smith, A. Lucchi, P. Fua, and S. Susstrunk. Slic superpixels. Technical report, 2010. 2

[3] B. Alexe, T. Deselaers, and V. Ferrari. What is an object? In *Computer Vision and Pattern Recognition (CVPR), 2010 IEEE Conference on*, pages 73--80. IEEE, 2010. 1

[4] M. Batty. *Cities and complexity: understanding cities with cellular automata, agent-based models, and fractals*. The MIT press, 2007. 2

[5] A. Borji, D. N. Sihite, and L. Itti. Salient object detection: A benchmark. In *Computer Vision--ECCV 2012*, pages 414--429. Springer, 2012. 1

[6] M.-M. Cheng, N. J. Mitra, X. Huang, P. H. Torr, and S.-M. Hu. Salient object detection and segmentation. *Image*, 2(3):9, 2011. 5

[7] M.-M. Cheng, J. Warrell, W.-Y. Lin, S. Zheng, V. Vineet, and N. Crook. Efficient salient region detection with soft image abstraction. In *Computer Vision (ICCV), 2013 IEEE International Conference on*, pages 1529--1536. IEEE, 2013. 1

[8] M.-M. Cheng, G.-X. Zhang, N. J. Mitra, X. Huang, and S.-M. Hu. Global contrast based salient region detection. In *Computer Vision and Pattern Recognition (CVPR), 2011 IEEE Conference on*, pages 409--416. IEEE, 2011. 1, 5, 7

[9] B. Chopard and M. Droz. *Cellular automata modeling of physical systems*, volume 24. Cambridge University Press Cambridge, 1998. 2

[10] R. Cowburn and M. Welland. Room temperature magnetic quantum cellular automata. *Science*, 287(5457):1466--1468, 2000. 2

[11] Y. Ding, J. Xiao, and J. Yu. Importance filtering for image retargeting. In *Computer Vision and Pattern Recognition (CVPR), 2011 IEEE Conference on*, pages 89--96. IEEE, 2011. 1

[12] M. Everingham, L. Van Gool, C. K. Williams, J. Winn, and A. Zisserman. The pascal visual object classes (voc) challenge. *International journal of computer vision*, 88(2):303--338, 2010. 5

[13] S. Goferman and A. L. Tal. context-aware saliency detection. *Computer*, 2010. 4, 5, 7

[14] S. Goferman, L. Zelnik-Manor, and A. Tal. Context-aware saliency detection. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 34(10):1915--1926, 2012. 1

[15] X. Hou and L. Zhang. Saliency detection: A spectral residual approach. In *Computer Vision and Pattern Recognition, 2007. CVPR'07. IEEE Conference on*, pages 1--8. IEEE, 2007. 1

[16] L. Itti, C. Koch, and E. Niebur. A model of saliency-based visual attention for rapid scene analysis. *IEEE Transactions on pattern analysis and machine intelligence*, 20(11):1254--1259, 1998. 4, 5, 7

[17] B. Jiang, L. Zhang, H. Lu, C. Yang, and M.-H. Yang. Saliency detection via absorbing markov chain. In *Computer Vision (ICCV), 2013 IEEE International Conference on*, pages 1665--1672. IEEE, 2013. 1

[18] H. Jiang, J. Wang, Z. Yuan, T. Liu, N. Zheng, and S. Li. Automatic salient object segmentation based on context and shape prior. In *BMVC*, volume 3, page 7, 2011. 1

[19] H. Jiang, J. Wang, Z. Yuan, Y. Wu, N. Zheng, and S. Li. Salient object detection: A discriminative regional feature integration approach. In *Computer Vision and Pattern Recognition (CVPR), 2013 IEEE Conference on*, pages 2083--2090. IEEE, 2013. 1



- [20] P. Jiang, H. Ling, J. Yu, and J. Peng. Salient region detection by ufo: Uniqueness, focusness and objectness. In *Computer Vision (ICCV), 2013 IEEE International Conference on*, pages 1976--1983. IEEE, 2013. 5, 7
- [21] Z. Jiang and L. S. Davis. Submodular salient region detection. In *Computer Vision and Pattern Recognition (CVPR), 2013 IEEE Conference on*, pages 2043--2050. IEEE, 2013. 1
- [22] D. A. Klein and S. Frintrop. Center-surround divergence of feature statistics for salient object detection. In *Computer Vision (ICCV), 2011 IEEE International Conference on*, pages 2214--2219. IEEE, 2011. 1
- [23] X. Li, H. Lu, L. Zhang, X. Ruan, and M.-H. Yang. Saliency detection via dense and sparse reconstruction. In *Computer Vision (ICCV), 2013 IEEE International Conference on*, pages 2976--2983. IEEE, 2013. 1, 5
- [24] Y. Li, X. Hou, C. Koch, J. Rehg, and A. Yuille. The secrets of salient object segmentation. *CVPR*, 2014. 5
- [25] T. Liu, Z. Yuan, J. Sun, J. Wang, N. Zheng, X. Tang, and H.-Y. Shum. Learning to detect a salient object. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 33(2):353-367, 2011. 5
- [26] V. Mahadevan and N. Vasconcelos. Saliency-based discriminant tracking. In *Computer Vision and Pattern Recognition, 2009. CVPR 2009. IEEE Conference on*, pages 1007--1013. IEEE, 2009. 1
- [27] L. Marchesotti, C. Cifarelli, and G. Csurka. A framework for visual saliency detection with applications to image thumbnailing. In *Computer Vision, 2009 IEEE 12th International Conference on*, pages 2232--2239. IEEE, 2009. 1
- [28] C. Maria de Almeida, M. Batty, A. M. Vieira Monteiro, G. Câmara, B. S. Soares-Filho, G. C. Cerqueira, and C. L. Pennachin. Stochastic cellular automata modeling of urban land use dynamics: empirical development and estimation. *Computers, Environment and Urban Systems*, 27(5):481--509, 2003. 2
- [29] A. C. Martins. Continuous opinions and discrete actions in opinion dynamics problems. *International Journal of Modern Physics C*, 19(04):617--624, 2008. 2
- [30] J. v. Neumann and A. W. Burks. Theory of self-reproducing automata. 1966. 2
- [31] A. Y. Ng, M. I. Jordan, Y. Weiss, et al. On spectral clustering: Analysis and an algorithm. *Advances in neural information processing systems*, 2:849--856, 2002. 1
- [32] N. Otsu. A threshold selection method from gray-level histograms. *Automatica*, 11(285-296):23--27, 1975. 4
- [33] F. Perazzi, P. Krahenbuhl, Y. Pritch, and A. Hornung. Saliency filters: Contrast based filtering for salient region detection. In *Computer Vision and Pattern Recognition (CVPR), 2012 IEEE Conference on*, pages 733--740. IEEE, 2012. 1, 5
- [34] E. Rahtu, J. Kannala, M. Salo, and J. Heikkilä. Segmenting salient objects from images and videos. In *Computer Vision-ECCV 2010*, pages 366--379. Springer, 2010. 1
- [35] C. Rother, V. Kolmogorov, and A. Blake. Grabcut: Interactive foreground extraction using iterated graph cuts. In *ACM Transactions on Graphics (TOG)*, volume 23, pages 309--314. ACM, 2004. 1
- [36] X. Shen and Y. Wu. A unified approach to salient object detection via low rank matrix recovery. In *Computer Vision and Pattern Recognition (CVPR), 2012 IEEE Conference on*, pages 853--860. IEEE, 2012. 1, 5, 7
- [37] C. Siagian and L. Itti. Rapid biologically-inspired scene classification using features shared with visual attention. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 29(2):300--312, 2007. 1
- [38] A. R. Smith III. Real-time language recognition by one-dimensional cellular automata. *Journal of Computer and System Sciences*, 6(3):233--253, 1972. 2
- [39] J. Sun and H. Ling. Scale and object aware image retargeting for thumbnail browsing. In *Computer Vision (ICCV), 2011 IEEE International Conference on*, pages 1511--1518. IEEE, 2011. 1
- [40] J. Sun, H. Lu, and S. Li. Saliency detection based on integration of boundary and soft-segmentation. In *ICIP*, 2012. 1
- [41] N. Tong, H. Lu, Y. Zhang, and X. Ruan. Salient object detection via global and local cues. *Pattern Recognition*, doi:10.1016/j.patcog.2014.12.005, 2014. 1
- [42] J. Von Neumann. The general and logical theory of automata. *Cerebral mechanisms in behavior*, 1:41, 1951. 1, 2
- [43] L. Wang, J. Xue, N. Zheng, and G. Hua. Automatic salient object extraction with contextual cue. In *Computer Vision (ICCV), 2011 IEEE International Conference on*, pages 105--112. IEEE, 2011. 1
- [44] Y. Wei, F. Wen, W. Zhu, and J. Sun. Geodesic saliency using background priors. In *Computer Vision--ECCV 2012*, pages 29--42. Springer, 2012. 1
- [45] S. Wolfram. Statistical mechanics of cellular automata. *Reviews of modern physics*, 55(3):601, 1983. 2
- [46] Y. Xie and H. Lu. Visual saliency detection based on bayesian model. In *Image Processing (ICIP), 2011 18th IEEE International Conference on*, pages 645--648. IEEE, 2011. 1
- [47] Y. Xie, H. Lu, and M.-H. Yang. Bayesian saliency via low and mid level cues. *Image Processing, IEEE Transactions on*, 22(5):1689--1698, 2013. 1, 5, 7
- [48] Q. Yan, L. Xu, J. Shi, and J. Jia. Hierarchical saliency detection. In *Computer Vision and Pattern Recognition (CVPR), 2013 IEEE Conference on*, pages 1155--1162. IEEE, 2013. 1, 5, 7
- [49] C. Yang, L. Zhang, H. Lu, X. Ruan, and M.-H. Yang. Saliency detection via graph-based manifold ranking. In *Computer Vision and Pattern Recognition (CVPR), 2013 IEEE Conference on*, pages 3166--3173. IEEE, 2013. 1, 3, 5
- [50] J. Yang and M.-H. Yang. Top-down visual saliency via joint crf and dictionary learning. In *Computer Vision and Pattern Recognition (CVPR), 2012 IEEE Conference on*, pages 2296--2303. IEEE, 2012. 1
- [51] L. Zhang, M. H. Tong, T. K. Marks, H. Shan, and G. W. Cottrell. Sun: A bayesian framework for saliency using natural statistics. *Journal of vision*, 8(7):32, 2008. 1
- [52] W. Zhu, S. Liang, Y. Wei, and J. Sun. Saliency optimization from robust background detection. In *Computer Vision and Pattern Recognition (CVPR), 2014 IEEE Conference on*, pages 2814--2821. IEEE, 2014. 1, 5