

基于深度学习的图像显著区域检测

纪超*, 黄新波, 曹雯, 朱永灿, 张烨

西安工程大学电子信息学院, 陕西 西安 710048

摘要 对区域的边界和物体边缘像素使用聚焦操作来计算区域显著特征,采用全局颜色显著性计算全局显著特征,基于卷积神经网络(CNN)融合区域显著特征和全局显著特征,获得最终的显著图,同时采用循环结构网络,多次参考周围环境信息,剔除噪声特点。在 MSRA 图像库和 ECSSD 图像库中测试所提算法,其平均精度和平均召回的调和平均值、平均误差均优于当前流行算法。

关键词 机器视觉; 显著性检测; 卷积神经网络; 区域边缘特征; 全局颜色特征

中图分类号 TP391.4

文献标识码 A

doi: 10.3788/LOP56.091007

Salient Region Detection of Images Based on Deep Learning

Ji Chao*, Huang Xinbo, Cao Wen, Zhu Yongcan, Zhang Ye

College of Electronics and Information, Xi'an Polytechnic University, Xi'an, Shaanxi 710048, China

Abstract The prominent features of the salient region are determined by focusing on the regional boundary and the object's edge pixels. Further, the uniqueness of the salient global color is used to calculate global features. Finally, the salient region is obtained using the convolutional neural network (CNN) model based on the regional and global salient features. Adopting a circular structure network is critical to eliminate the noise characteristics by referring to the surrounding environment information for multiple times. The proposed algorithm is tested using the image libraries of MSRA and ECSSD and it is found that its harmonic mean and average error associated with the average precision and recall are better than those of the current popular algorithms.

Key words machine vision; saliency detection; convolutional neural networks; regional boundary feature; global color feature

OCIS codes 100.2906; 100.3010; 140.6910

1 引言

视觉显著性是通过模拟人类视觉系统来判断图像中最重要和最显著的区域,可以有效地聚焦于与当前任务相关的有趣图像区域,并且广泛地用于计算机视觉,例如图像分割和裁剪^[1]、图像分类、图像检索和压缩等,近年来备受关注。

现有显著性检测方法主要通过检测图像的局部特征和全局特征反映图像的显著区域。局部特征检测方法包括计算纹理和边缘定向特征,计算颜色对

比特征等,这些方法只能突出图像的低级特征,无法捕获像素的高级和多尺度信息^[2-3]。文献[4]首先通过局部对比方法产生较模糊的显著图,然后通过突出显著对象边界的高频成分,得到整个显著对象;文献[5]基于区域的颜色直方图与其紧邻的区域之间的差异,评估显著度大小,再排序获得显著区域;文献[6]提出使用对比度的先验特征协助图像的显著性计算,缓解了全局对比方法所造成的边界模糊现象。

基于单纯的低级特征或简单特征组合方法难以

收稿日期: 2018-11-08; 修回日期: 2018-11-12; 录用日期: 2018-12-06

基金项目: 国家自然科学基金(51177115)、陕西省自然科学基金(2017JQ6054)、陕西省重点科技创新团队计划(2014KCT-16)、陕西省科学技术研究发展计划项目(2014XT-07)、陕西省工业科技攻关项目(2015GY-075)、西安工程大学博士启动基金(BS1505)

* E-mail: dachao9898@163.com

在复杂场景中检测显著对象,而有效的卷积特征可直接从原始图像中智能地提取高级和多尺度特征,增加特征的多样性,提高图像识别的准确性。由于深度学习提取特征较多,增加了算法的运行时间,如何在显著增加计算量的情况下提高特征学习的准确度和效率成为首要任务。

目前具有代表性的基于深度学习的显著检测方法有很多,如文献[7]采用多个深度卷积神经网络(CNN)提取多尺度特征,以进行显著性预测;文献[8]提出一个深度对比网络,设计了深层次网络,将像素流和分段流相结合进行显著性估计;文献[9]将多个短连接引入到整体嵌套的边缘检测架构中,用于聚合多级卷积,提高了显著性检测的稳健性和准确性。

本文提出了一种结合图像区域边缘特征和全局颜色特征的显著性检测方法。区域边缘显著计算,首先通过超像素表示图像,对区域的边界和内部边缘像素进行聚焦操作,计算区域显著特征。全局颜色显著计算是在全局范围内衡量显著性物体,利用颜色唯一性构建多尺度特征学习,并连接到一个完全连接的神经网络分类器,评估区域显著性。区域显著特征和全局显著特征通过CNN网络融合在一起,形成最终的显著图。在同一深度学习框架下,通过在每一层多次共享权重,吸收周围环境中隐藏的卷积单位特征,同时,采用循环结构网络,参考周围环境信息,剔除噪声特点。

2 算法分析

根据引言中的分析,将所提算法按照逻辑顺序进行实现。

2.1 超像素特征提取

采用超像素作为图像元素,采用简单线性迭代聚类(SLIC)算法^[10]将输入图像 I 初始分割为 N 个超像素。对于每个超像素构造一个特征向量,用于覆盖RGB(Red, Green, Blue)颜色空间、HSV(Hue, Saturation, Value)颜色空间和CIELab(The CIE Lab Color Space)颜色空间的特征。将计算的各像素特征向量平均值,转换为每个超像素对应的特征向量。超像素特征向量计算公式为

$$x_i = \frac{1}{C} \sum_{j=1}^{m_i} \omega_{ji} f_j, \quad (1)$$

式中: $f_j \in \mathbf{R}^{m \times 1}$ 为超像素 i 中像素 j 的特征向量, \mathbf{R} 为实数集; n_i 为超像素 i 中的像素个数; C 为归一化常数。 ω_{ji} 为距离权重,计算公式为

$$\omega_{ji} = \exp\left(-\frac{\|p_j - p_i\|_2^2}{2 \times \xi^2}\right), \quad (2)$$

式中: p_i 和 p_j 分别为超像素 i 和像素 j 的中心位置坐标; ξ 为标量,实验中设置为 $\sqrt{2}$ 。将输入图像 I 中所有超像素的特征向量水平堆叠产生特征矩阵 $\mathbf{X} \in \mathbf{R}^{m \times N}$ (m 代表位数, N 代表个数),即 $\mathbf{X} = (x_1, x_2, \dots, x_N) \in \mathbf{R}^{m \times N}$ 。根据不同的要求划分超像素个数,图1为不同超像素 k 的结果图。



图1 不同 k 值的分割图。(a)原图;(b) $k=50$;
(c) $k=100$;(d) $k=200$

Fig. 1 Partition results for different k values. (a) Original image; (b) $k=50$; (c) $k=100$; (d) $k=200$

2.2 区域像素特征计算

设置一个半过滤器,窗口宽度 $W = 4\delta_1$,因为 $2\delta_1$ 对应于高斯拉普拉斯(LOG)过滤器的波峰和波谷之间的距离,故过滤器的主要范围为 $[-W, W]$ 。

区域层次一致性是将每个物体的显著性作为整体计算^[11],本文在子对象级别上进行显著计算,即为每个单独区域 I_i 执行显著计算($i=1, \dots, N$)。采用 B_i 表示边界像素 m_i 的集合, E_i 表示内部边缘像素 n_i 的集合。在 $B_i \cup E_i$ 集合中, I_i 的焦点与所有像素的焦点值的总和呈正相关。采用高斯函数的差分(DOG)得到一个具有清晰边界的区域 $L_g(p)$, p 为区域超像素个数。使用边界锐度作为权重,区域级的焦点 $H_r(I_i)$ 计算公式为

$$H_r(I_i) = \frac{1}{m_i} \sum_{p \in B_i} |L_g(p)| \cdot \exp\left[\frac{1}{m_i + n_i} \sum_{p \in (B_i \cup E_i)} H_r(I)\right], \quad (3)$$

(3)式中使用指数函数强调像素点的重要性,获得整个图像 I 的区域锐化,将其表示为 $H(I)$ 。

所采用的区域级焦点计算,本质上是对区域的边界和内部边缘像素进行聚焦操作。然后将显著物体识别为小区域,计算小区域显著概率,以便在突出区域检测中优先考虑显著概率高的区域。

通过测量每个区域的目标距离,在图像上形成一个完整的目标映射。对于每个区域,计算其区域级对象 $S_r(I_i)$,即

$$H_r(I_i) = \frac{1}{|I_i|} \sum_{x \in I_i} I_p(x), \quad (4)$$

式中: x 为区域的超像素,在对象被划分为一个区域后,同时得到了整个图像 I 上对应的映射,将其表示为 $S(I)$ 。

2.3 区域内连续边缘计算

图像的连续边缘适合显著物体检测,显著对象的边界内部或边界上存在强边缘,可以将检测显著对象的问题转换为寻找闭合曲线的问题。但多数情况下,在突出物体的边界上检测到的边缘不能形成闭合曲线,即在显著物体的边界上检测到的边缘是不连续的^[12-13],所提算法提供了一种表示相邻超像素之间关系的方式,采用纹理和对象边界的内在信息,计算物体的显著信息。

边缘强度能更全面地衡量相邻超像素之间的关

系。计算得到的显著边界和内部区域的关系为

$$S_{pi} = \left[1 - \frac{\sum_{j=1}^{N_R} \gamma(\mathbf{H}_i, \mathbf{H}_j) \cdot D(R_j)}{\sum_{j=1}^{N_R} \gamma(\mathbf{H}_i, \mathbf{H}_j)} \right] \times B_{pi}, \quad (5)$$

式中: N_R 为显著区域内部的超像素集合; $D(R_j) = \left\| \boldsymbol{\mu}_j - \left(\frac{M}{2}, \frac{N}{2} \right) \right\|$,为边缘图像区域 C_j 中心和中心图像之间的欧几里德距离; $\gamma(\cdot, \cdot)$ 为两个矢量之间的卡方距离; $\mathbf{H}_i, \mathbf{H}_j$ 分别为 C_i, C_j 颜色直方图的归一化矢量。 B_{ci} 为超像素 R_i 的边界先验值,定义为

$$B_{ci} = \exp\left(-2 \frac{|R_i \cap B|}{\partial R_i} \cdot \Gamma\right), \quad (6)$$

式中: B 为图像边界上的像素; ∂R_i 为周边上的像素; R_i 为图像边界上的超像素集; $|R_i \cap B|$ 为边界像素 R_i 的数量; Γ 用于调节边界先验条件下的边缘特征集合。

图 2(b)、(c)和(d)分别为 Canny 算子、Sobel 算子和文献[14]的方法提取的边缘特征图,图 2(e)为所提方法提取的边缘特征图,对比发现:本文算法可以更好地剔除部分噪声信息。



图 2 边缘特征提取。(a)原图;(b) Canny 算子;(c) Sobel 算子;(d)文献[14];(e)所提算法

Fig. 2 Extraction of edge features. (a) Original images; (b) Canny operator; (c) Sobel operator; (d) Ref. [14]; (e) proposed algorithm

2.4 全局颜色显著性计算

显著特征计算受全局环境的影响,本文采用一种全局颜色稀有度衡量显著性的方法。文献[15]提出了一种检测图像色彩稀有度的方法,本文基于该方法,将颜色和极值区域的方向信息相结合,方向信息基于比例空间 L^* ,每个尺度 σ 包含至少一个极值,首先计算水平和垂直梯度图^[16],然后计算梯度幅度 $m_\sigma(x, y)$ 和方向 $\theta_\sigma(x, y)$ 。

$$m_\sigma(x, y) = \sqrt{f_\sigma^h(x, y)^2 + f_\sigma^v(x, y)^2}, \quad (7)$$

$$\theta_\sigma(x, y) = \arctan[f_\sigma^h(x, y)/f_\sigma^v(x, y)], \quad (8)$$

式中:

$$f_\sigma^h(x, y) = L_\sigma(x+1, y) - L_\sigma(x-1, y), \quad (9)$$

$$f_\sigma^v(x, y) = L_\sigma(x, y+1) - L_\sigma(x, y-1), \quad (10)$$

为计算方向分布, $f_\sigma^h(x, y)$ 和 $f_\sigma^v(x, y)$ 分别为水平和垂直方向的增量,构建标准化直方图 $P(\theta)$, $\theta \in [0^\circ, 1^\circ, \dots, 359^\circ]$,通过 $m(x, y)$ 值计算概率,其位置 (x, y) 产生 θ 。对于每个尺度 σ ,构建一个图像的直方图,对于每个极值 $P_\sigma^{\text{all}}(\theta)$,建立周围圆形区域的单独直方图极值,半径为 $P_\sigma^{\text{in}}(\theta)$ 。

本文仅关注每个图像的近似分布,聚类之后,整合属于同一聚类的元素,从而整合了概率属于 K 簇的每个像素,将所有属于高斯混合模型(GMM)的某个分量的像素定义为 $p(c | I_{x,y})$ 的概率之和,即

$$p(K | I_{x,y}) = \sum_{c \in K} p(c | I_{x,y}), \quad (5)$$

式中: K 为簇个数, $K=1,2,3,\dots$; c 为簇特征; $p(c | I_{x,y})$ 为像素 $I_{x,y}$ 的概率属于 K^{th} 集群中 GMM 的第 c^{th} 个组成部分。

由于显著物体颜色比噪声颜色分布更集中,本文将二维图像转换为三维图像,增加的维数表示颜色集中度,即

$$\text{Comp}(K) = \left[\frac{\sum_{I_{x,y}} \| \mathbf{r} - \boldsymbol{\mu} \|^2 \cdot p(K | I_{x,y})}{\sum_{I_{x,y}} p(K | I_{x,y})} \right]^{-1}, \quad (11)$$

式中: \mathbf{r} 为像素 $I_{x,y}$ 的坐标; $\boldsymbol{\mu}$ 为显著区域中心的位置。与中心像素 $\boldsymbol{\mu}$ 越近,集中度越高。

构建一个归一化三维直方图 $P(L^*, a^*, b^*)$, 使用 L^*, a^*, b^* 建立整个图像的直方图 $P^{\text{all}}(L^*,$

$a^*, b^*)$, 每个极值构建单独的直方图,计算公式为

$$P_i^{\text{out}}(L^*, a^*, b^*) = P_i^{\text{all}}(L^*, a^*, b^*) - P_i^{\text{in}}(L^*, a^*, b^*), \quad (12)$$

$$P_i^{\text{out}}(\theta) = P_i^{\text{all}}(\theta) - P_i^{\text{in}}(\theta), \quad (13)$$

式中: $P_i^{\text{in}}(L^*, a^*, b^*)$ 为极值周围的圆形区域,半径为 r_i 。

每个极值获得了颜色稀有特征和方向特征,采用基于位置的权重计算实际偏差。通过显著图 $S(x, y)$ 可检测到大致显著区域,计算公式为

$$S(x, y) = \sum_{i=1}^N \frac{\Delta C_i(x_i, y_i, \sigma_i) w_i P_i^{\text{out}} m_\sigma(x, y)}{2\pi\hat{\sigma}_i^2} \times \exp\left[-\frac{(x_i - x)^2 + (y_i - y)^2}{2\hat{\sigma}_i^2}\right], \quad (14)$$

式中: $\hat{\sigma}^2$ 为方差。

图 3 为全局颜色特征实验对比结构图,图 3(a) 为原图,图 3(b) 为将原始图像进行直方图模糊的结果,图 3(c) 为将图 3(b) 基于全局颜色稀有性提取的特征,图 3(d) 为结合颜色和方向信息得到的显著区域,图 3(e) 为图 3(d) 灰度化后的结果图。




图 3 显著颜色特征提取。(a)原图;(b)直方图模糊处理;(c)全局颜色特征;(d)显著区域;(e)所提算法结果
Fig. 3 Extraction of salient color features. (a) Original images; (b) blurred histogram; (c) global color feature; (d) salient region; (e) results by proposed algorithm

3 显著区域融合

所提算法充分挖掘图像的区域特征值显著图和全局特征显著图,二者分别采用不同的特征信息计算图像显著特征,独立互补,可基于 CNN 融合进一步改善显著检测效果。

图 4 中 concat 为特征提取层,conv 为卷积层,num 为参数个数,size 为卷积核大小。融合部分是将采用区域边缘提取的显著特征和采用全局颜色提取的显著特征以非线性方式基于 CNN 网络进行合成。使用 ImageNet 数据集^[17] 预训练本文模型,再基于 Caffe Model 进行开发。首先,调整输入图像




图 4 合成网络结构图

Fig. 4 Structural diagram of network synthesis

大小为 $224 \text{ pixel} \times 224 \text{ pixel}$, 其网络结构如图 4 所示,然后采用循环网络结构吸收语境和结构信息隐藏的卷积特征。通过在每一层多次共享权重,该网络架构可以在不显著增加总参数的情况下增加 CNN 的深度数。

循环网络结构由具有不同输出尺寸的重复模块组成。对于输入图像 I , 循环结构网络生成低空间分辨率的 5 个特征图 ($f_i^{(1)}, f_i^{(2)}, \dots, f_i^{(5)}$), 步幅为 2。每幅图由一个残余卷积块产生, 从 conv5 获得的特征映射 $f_i^{(5)}$ 具有最小的空间维度, 而 $f_i^{(1)}$ 具有最大的空间维度, 第 l 个特征的输出特征图为 $f_i^{(l)}$ ($l \in \{3, 4, 5\}$)。采用 3×3 卷积映射第 l 个残差块的输出, 将特征映射 $f_i^{(l)}$ ($l \in \{4, 5\}$) 上采样到与 $f_i^{(3)}$ 相同的大小。将元素乘法模型应用于所有特征映射 $f_i^{(l)}$, 包括 1 个 128 通道的 3×3 卷积层和 1 个 2 通道的 1×1 卷积层, 在空间上采用 Softmax 操作 $M_g(\cdot)$, 最后进行归一化操作, 即

$$S_g(x, y) = \frac{\exp[M_g(x, y)]}{\sum_{(x', y')} \exp[M_g(x', y')]}, \quad (15)$$

式中: $S_g(x, y)$ 为在 (x, y) 处的归一化的响应值, g 为块的数量。如果像素 i 在位置 (x, y) 显著, 那么映射中应对该像素的相关区域分配更高的显著值。

对加权图进行上采样获得 E_{u_g} , 特征 f_{t_g} 满足

$$F_g(Q) = E_{u_g}^\circ f_{t_g}(Q), \quad (16)$$

式中: Q 为特征通道数; $^\circ$ 表示使用元素的操作。注意, E_{u_g} 在 $f_{t_g}(Q)$ 的所有频道中共享。




图 5 循环网络结构特征检测。(a) 原图; (b) 没经过循环模块的显著区域; (c) 经过循环模块的显著区域; (d) 真值图

Fig. 5 Feature detection based on loop network structure. (a) Original images; (b) salient regions without loop module; (c) salient regions with loop module; (d) ground truth figures

图 5 验证了循环网络结构对噪声信息的剔除能力, 图 5(a) 为待处理的原始图像, 图 5(d) 为原图对应的真值图 (手工标注显著区域分割图)。由图 5(c) 和图 5(b) 对比得出: 加入循环模块能更好地剔除噪声信息, 增强图像的显著区域。

4 性能对比实验

所有实验均在 MATLAB R2014b 平台、Python3.5 和 Caffe 工具箱开展。计算机配备为 i7-7700 CPU @ 3.6 GHz (16G 内存) 和 NVIDIA GPU (4G 内存)。将本文算法与 12 种较先进的显著性检测方法在两个基准数集中进行测试。MSRA-B 数据集^[18] 包含 1000 张图片, 该数据集中的图像通常只有一个显式的突出对象和简单的背景。ECSSD 数据集^[19] 中包含图像的语义性较好, 但结构较复杂。所选择的 12 种显著性对比方法包括 DSR (dense and sparse reconstruction)^[10]、FT (frequency tuned)^[11]、CA (context aware)^[12]、HC (histogram color)^[15]、SUN (saliency using natural)^[1]、SEG (straddling expansion)^[14]、RC (region context)^[1]、MZ (multiple calculation)^[16]、LC (local context)^[15]、CSD (center-surround difference)^[20]、GU (global unit)^[16] 和 AC (attention cues)^[4]。

图 6 显示了一些流行的结果, 包括显著图和真值图。与 CA 算法、SUN 算法、SEG 算法、RC 算法和 FT 算法相比, 本文算法提取显著对象的内部信息更加完整、清晰, 显著对象边界轮廓更清晰, 能均匀地突出整个物体; 与 DSR 算法、MZ 算法、LC 算法、CSD 算法、GU 算法和 AC 算法相比, 检测的显著目标细节更丰富, 可更好地保持显著对象的边缘连续性、提取显著物体的亮度信息, 同时抑制周围的环境噪声。

利用 3 个主要指标评估显著对象检测算法的性能, 包括精度-召回率 ($P-R$) 曲线、 F -measure (F) 和平均绝对误差 (MAE)。通过对预测的显著图进行阈值处理, 并将二进制图与地面实况进行比较来计算精度和召回率。数据集的 $P-R$ 曲线显示了不同阈值下的显著图的平均精度和召回率^[21-22]。 F 为平均精度和平均召回率的调和平均值, 即

$$F = \frac{(1 + \alpha) \times P_c \times R_c}{\alpha \times P_c + R_c}, \quad (17)$$

式中: α 为学习率; P_c 和 R_c 为 $P-R$ 曲线所对应的值。

表 1 列出了本文算法及其他 12 种算法在 ECSSD 图像库、MSRA 图像库中的 F 值 (越大越好) 和 MAE (越小越好), 以及受试者工作特征 (ROC) 曲线下面积 (AUC, 越大越好)。所提算法在




图 6 所提算法与其他算法效果对比图。(a)原图;(b) SUN 算法;(c) SEG 算法;(d) RC 算法;(e) CA 算法;(f) MZ 算法;(g) AC 算法;(h) LC 算法;(i) FT 算法;(j) DSR 算法;(k) HC 算法;(l) CSD 算法;(m) GU 算法;(n)所提算法;(o)真值图

Fig. 6 Results of proposed algorithm and other algorithms. (a) Original images; (b) SUN algorithm; (c) SEG algorithm; (d) RC algorithm; (e) CA algorithm; (f) MZ algorithm; (g) AC algorithm; (h) LC algorithm; (i) FT algorithm; (j) DSR algorithm; (k) HC algorithm; (l) CSD algorithm; (m) GU algorithm; (n) proposed algorithm; (o) ground truth figures

表 1 参数结果的比较

Table 1 Comparison of quantitative results

Data Set	Metric	DSR	SEG	CA	HC	LC	FT	AC	MZ	CSD	SUN	GU	RC	Proposed
MSRA	<i>F</i> -measure	0.803	0.746	0.691	0.808	0.776	0.801	0.795	0.786	0.805	0.723	0.816	0.751	0.827
	MAE	0.345	0.325	0.324	0.254	0.320	0.186	0.286	0.294	0.140	0.329	0.134	0.352	0.126
	AUC	0.863	0.817	0.761	0.875	0.831	0.862	0.867	0.846	0.865	0.781	0.883	0.816	0.894
ECSSD	<i>F</i> -measure	0.774	0.716	0.675	0.765	0.736	0.771	0.758	0.749	0.768	0.705	0.776	0.728	0.789
	MAE	0.386	0.354	0.364	0.251	0.342	0.195	0.298	0.325	0.142	0.367	0.142	0.356	0.132
	AUC	0.838	0.785	0.732	0.832	0.806	0.836	0.826	0.812	0.821	0.762	0.842	0.807	0.856

MSRA 和 ECSSD 图像库中具有的最佳性能分别为 82.7%、12.6%、89.4% 和 78.9%、13.2%、78.9%。其次性能较好的为 GU 算法,在 MSRA 图像库中测试值依次为 81.6%、13.4%、88.3%,在 ECSSD 图像库中为 77.6%、14.2%、84.2%。

所提算法在 MSRA 和 ECSSD 图像库中也有较高的检测准确率和回归率,其中 *F* 值较大,*M* 值较小。

表 2 列出了各种算法的平均时间成本。所提算法计算成本适中;CA 算法和 RC 算法在 MATLAB 中 fastest,但与所提算法相比,*P-R* 曲线相对较低。

表 2 不同方法对 10 张图像的平均计算时间

Table 2 Average computation time of different methods on 10 images

Method	MSRA dataset		ECSSD dataset	
	Programming languages	Runtime /s	Programming languages	Runtime /s
SUN	MATLAB	2.08	MATLAB	2.11
SEG	MATLAB	0.86	MATLAB	0.89
RC	C++	0.69	C++	0.81
CA	MATLAB	0.76	MATLAB	0.86
MZ	C++	2.97	C++	3.12
LC	C++	1.83	C++	1.93
AC	MATLAB	23.54	MATLAB	25.12
FT	C++	0.87	MATLAB	0.95
GU	MATLAB	1.43	MATLAB	1.49
CSD	MATLAB	2.23	MATLAB	2.31
HC	C++	1.98	C++	2.21
DSR	Python	1.32	Python	1.83
Proposed	Python	0.76	Python	0.85

5 结 论

利用区域的边界特征和全局颜色特征实现了图像显著特征的计算,将上述特征基于 CNN 融合,再采用循环结构网络,吸收周围环境的结构信息中隐藏的卷积特征,组成最终的显著图。不同的全局显著性线索之间的复杂关系可以被深层网络捕获。

将所提算法与近年来 12 种经典显著性提取模型进行有效性实验对比,实验效果通过 P - R 曲线、 F -measure、MAE 值和算法运行时间综合对比各模型性能。结果表明,本文算法能更准确、更快地检测出图像中的显著物体,能更好地提取显著物体的整体信息,并确定其边界,可应用于目标检测或图像分割领域。

参 考 文 献

- [1] Tong N, Lu H C, Ruan X, *et al.* Salient object detection via bootstrap learning [C] // 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 7-12, 2015, Boston, MA, USA. New York: IEEE, 2015: 4204 - 4216.
- [2] Lee G, Tai Y W, Kim J. Deep saliency with encoded low level distance map and high level features [C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE, 2016: 660-668.
- [3] Wang L J, Lu H C, Ruan X, *et al.* Deep networks for saliency detection via local estimation and global search [C] // 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 7-12, June 2015, Boston, MA, USA. New York: IEEE, 2015: 3183-3192.
- [4] Borji A, Cheng M M, Jiang H Z, *et al.* Salient object detection: a benchmark [J]. IEEE Transactions on Image Processing, 2015, 24(12): 5706-5722.
- [5] Jiang H, Wang J, Yuan Z, *et al.* Automatic salient object segmentation based on context and shape prior [J]. Proceedings of the 2011 British Machine Vision Conference, 2011: 1115-1124.
- [6] Achanta R, Hemami S, Estrada F, *et al.* Frequency-tuned salient region detection [C] // 2009 IEEE Conference on Computer Vision and Pattern Recognition, June 20-25, 2009, Miami, FL, USA. New York: IEEE, 2009: 1597-1604.
- [7] Li G B, Yu Y Z. Deep contrast learning for salient

object detection [C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE, 2016: 478-487.

- [8] Li X, Zhao L M, Wei L N, *et al.* Deep saliency: multi-task deep neural network model for salient object detection [J]. IEEE Transactions on Image Processing, 2016, 25(8): 3919-3930.
- [9] Liu X S, Shen J X, Zhang Y P. Adaptive support weight stereo matching algorithm based on human visual characteristics [J]. Laser & Optoelectronics Progress, 2018, 55(3): 031013.
刘雪松, 沈建新, 张燕平. 基于人眼视觉特性的自适应支持权重立体匹配算法 [J]. 激光与光电子学进展, 2018, 55(3): 031013.
- [10] Chen X Z, Ma H M, Wang X. Improving object proposals with multi-thresholding straddling expansion [C] // 2015 IEEE Conference on Computer Vision and Pattern Recognition, June 7-12, 2015, Boston, MA, USA. New York: IEEE, 2015: 2587-2595.
- [11] Zhang P P, Wang D, Lu H C, *et al.* Learning uncertain convolutional features for accurate saliency detection [C] // 2017 IEEE International Conference on Computer Vision (ICCV), October 22-29, 2017, Venice, Italy. New York: IEEE, 2017: 212-221.
- [12] Cheng M M, Zhang G X, Mitra N J, *et al.* Global contrast based salient region detection [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37(3): 569-582.
- [13] Ma Y F, Zhang H J. Contrast-based image attention analysis by using fuzzy growing [C] // Proceedings of the Eleventh ACM International Conference on Multimedia. New York: ACM, 2003: 374-381.
- [14] Yang B, Zhang X Y, Chen L, *et al.* Edge guided salient object detection [J]. Neurocomputing, 2017, 221: 60-71.
- [15] Liu X S, Shen J X, Zhang Y P. Adaptive support weight stereo matching algorithm based on human visual characteristics [J]. Laser & Optoelectronics Progress, 2018, 55(3): 031013.
刘雪松, 沈建新, 张燕平. 基于人眼视觉特性的自适应支持权重立体匹配算法 [J]. 激光与光电子学进展, 2018, 55(3): 031013.
- [16] Huang F, Qi J Q, Lu H C, *et al.* Salient object detection via multiple instance learning [J]. IEEE Transactions on Image Processing, 2017, 26(4): 1911-1922.

- [17] Yang B, Zhang X Y, Chen L, *et al.* Edge guided salient object detection[J]. *Neurocomputing*, 2017, 221: 60-71.
- [18] Li S M, Lei G Q, Fan R. Depth map super-resolution reconstruction based on convolutional neural networks[J]. *Acta Optica Sinica*, 2017, 37(12): 1210002.
李素梅, 雷国庆, 范如. 基于卷积神经网络的深度图超分辨率重建[J]. *光学学报*, 2017, 37(12): 1210002.
- [19] Yang B, Zhang X Y, Chen L, *et al.* Edge guided salient object detection[J]. *Neurocomputing*, 2017, 221: 60-71.
- [20] Ju R, Liu Y, Ren T W, *et al.* Depth-aware salient object detection using anisotropic center-surround difference [J]. *Signal Processing: Image Communication*, 2015, 38: 115-126.
- [21] Fang X, Wang G H, Yang H C, *et al.* High resolution remote sensing image classification combining with mean-shift segmentation and fully convolution neural network [J]. *Laser & Optoelectronics Progress*, 2018, 55(2): 022802.
方旭, 王光辉, 杨化超, 等. 结合均值漂移分割与全卷积神经网络的高分辨遥感影像分类[J]. *激光与光电子学进展*, 2018, 55(2): 022802.
- [22] Ju R, Liu Y, Ren T W, *et al.* Depth-aware salient object detection using anisotropic center-surround difference [J]. *Signal Processing: Image Communication*, 2015, 38: 115-126.