

基于优化的极限学习机和深度层次的RGB-D显著检测

刘政怡* 徐天泽

(安徽大学计算机科学与技术学院 合肥 230601)

摘要: 目前,相当多的显著目标检测方法均聚焦于2D的图像上,而RGB-D图像所需要的显著检测方法与单纯的2D图像相去甚远,这就需要新的适用于RGB-D的显著检测方法。该文在经典的RGB显著检测方法,即极限学习机的应用的基础上,提出融合了特征提取、前景增强、深度层次检测等多种思路的新的RGB-D显著性检测方法。该文的方法是:第一,运用特征提取的方法,提取RGB图4个超像素尺度的4096维特征;第二,依据特征提取中产生的4个尺度的超像素数量,分别提取RGB图的RGB, LAB, LBP特征以及深度图的LBE特征;第三,根据LBE和暗通道特征两种特征求出粗显著图,并在4个尺度的遍历中不断强化前景、削弱背景;第四,根据粗显著图选取前景与背景种子,放入极限学习机中进行分类,得到第1阶段显著图;第五,运用深度层次检测、图割等方法对第1阶段显著图进行再次优化,得到第2阶段显著图,即最终显著图。

关键词: RGB-D显著目标检测; 极限学习机; 流程优化; 多特征; 深度层次优化

中图分类号: TP391

文献标识码: A

文章编号: 1009-5896(2019)09-2224-07

DOI: 10.11999/JEIT180826

RGB-D Saliency Detection Based on Optimized ELM and Depth Level

LIU Zhengyi XU Tianze

(College of Computer Science and Technology, Anhui University, Hefei 230601, China)

Abstract: Currently, many saliency-detection methods focus on 2D-image. But, these methods cannot be applied in RGB-D image. Based on this situation, new methods which are suitable for RGB-D image are needed. This paper presents a novel algorithm based on Extreme Learning Machine(ELM), feature-extraction and depth-detection. Firstly, feature-extraction is used for getting a feature, which contains 4-scale superpixels and 4096 dimensions. Secondly, according to the 4-scale superpixels, the RGB, LAB and LBP feature of RGB image are computed, and LBE feature of depth image. Thirdly, weak salient map with LBE and dark-channel features are computed, and the foreground objects is strengthened in every circle. Fourthly, according to weak salient map, both foreground seeds and background seeds are chosen, and then, put these seeds into ELM to compute the first stage salient map. Finally, depth-detection and graph-cut are used for optimizing the first stage salient map and getting the second stage salient map.

Key words: RGB-D saliency detection; Extreme Learning Machine(ELM); Process optimization; Multiple features; Depth level optimization

1 引言

近年来,图像处理日益重要,对图像中重要信息的提取是许多图像、视觉工作的基础,对进一步图像处理工作有着重要的意义。显著目标提取常常被应用在诸如语义判别^[1]、图像分割^[2]、目标识别^[3]、视频跟踪^[4]、图像分类^[5]等领域,并发挥着不可替代的作用。

针对RGB图像的显著检测已有许多行之有效的显著检测方法。诸如Manifold Ranking算法^[6], BootStrap Learning算法^[7]等,应用了图像的颜色、纹理、空间分布等信息,取得了一定效果。其中颜色信息一般有CIELAB颜色信息和RGB颜色信息。这些颜色信息常常被用来作为描述像素或者超像素,用以计算不同像素或者超像素的对比度^[8,9]。此外另一种常使用的信息是位置信息,常以“中心先验”的形式出现^[10],有两种方式,其一是假定中心区域部分为前景,其二是假定图像四周为背景。在RGB-D显著检测逐渐发展起来后,深度信息作为显著检测的一个维度,也受到广泛应用^[11]。

收稿日期: 2018-08-22; 改回日期: 2019-05-15; 网络出版: 2019-06-03

*通信作者: 刘政怡 22927463@qq.com

基金项目: 安徽省自然科学基金(1908085MF182)

Foundation Item: The Natural Science Foundation of Anhui Province (1908085MF182)

在manifold ranking算法和bootstrap learning算法中,前者是在中心先验思想的基础上进行显著检测,后者则融合了多种RGB信息特征。它们的效果是显而易见的。然而,第一,它们未将深度信息纳入框架之中;第二,虽然建立了结合多种特征的检测框架,但流程并不完善,对信息的应用程度不够;第三,所使用的特征维度较低,难以精确地表达像素、超像素的特征。

在近年的一些文献^[12,13]中可以看到一些不同的思路。针对简单低维特征难以精确描述超像素块信息的问题,如果引入由卷积神经网络计算得到的、具有更高信息量的高维特征,那么对于显著检测的精确性,将有很大的提升。

本文致力于解决这些问题,其中主要的贡献有:首先,采用已被验证卓有成效的极限学习机(Extreme Learning Machine, ELM)^[14]作为融合RGB和深度等多种特征的检测框架。其次,采用深度学习,高维特征提取的方法^[15],对RGB图像的区域信息进行高精度地提取,并且为了与ELM检测相匹配,本文进行了4个尺度的超像素提取,而非单尺度地提取特征。另一方面,对于深度采用了局部背景封闭(Local Background Enclosure, LBE)特征^[16],这种算法对于深度信息有高效的利用方式。

从以往的实际应用看,CIELAB,RGB和局部二值模式(Local Binary Patterns, LBP)特征对于描述超像素块的颜色信息有着明显的效果。然而这些

特征虽然效果优异,但是在精确描述超像素块的信息上,仍旧稍显不足,这是本文认为类似研究可以提高的地方。为此,本文引入了基于卷积神经网络的高维度特征。由于其维度极高,包含的信息更多,可以更好地描述一个超像素块的颜色属性。在图像分类^[17]、显著检测^[18]等多个领域,神经网络都有不俗的效果。Donahue等人^[19]提出,经过专门训练的卷积神经网络可以用来完成对特定图像数据集进行特征提取的工作。Razavian等人^[20]扩展了这一结论,提出基于CNN的深度学习可以成为几乎所有计算机视觉问题的备选方法。

另外,本文对已有的ELM检测流程进行了优化。原有的ELM检测流程只是简单地利用暗通道特征在每个超像素尺度上求出粗显著图进行前景、背景种子的选择,而本文则采取了新的流程,下文将有详细介绍。之后,本文提出了改进的优化方法,利用深度图的层次性对极限学习机产生的显著图进行优化,从而得到更精确的显著图。

2 本文的方法

2.1 多尺度特征

对于极限学习机而言,显著检测的基本单位是像素级还是超像素级,是单个特征还是多个特征,是低维度特征还是高维度特征,是RGB特征还是RGB-D特征,对最终分类效果有重大影响^[21]。图1展示了本文的基本流程。由于高维度特征提取是超像素级别,因此本文的显著检测也建立在超像素级别。

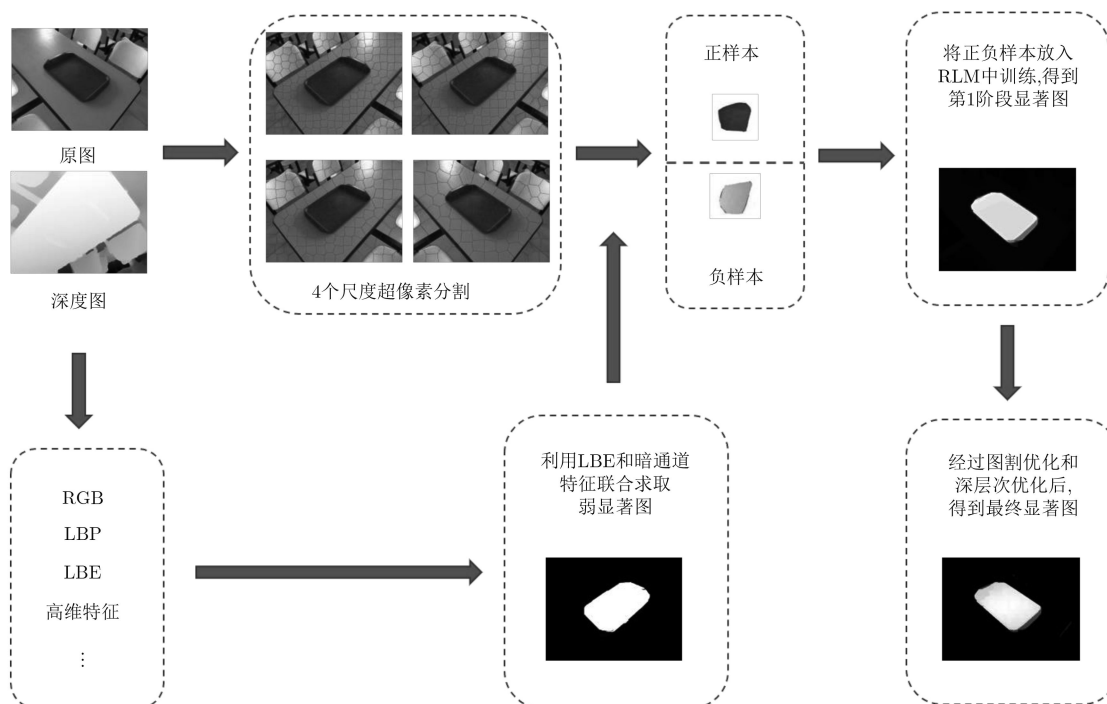


图1 本文算法程序流程图

多尺度的超像素分割是避免这种情况的非常优秀的方法,这在以往的显著检测论文中已有验证^[22]。

在特征选择上,首先,对于RGB图像,本文选用了经典的CIELAB、RGB特征、LBP特征、局部暗通道特征以及4096维高维特征。其次,以往的大多数应用分类器进行的显著检测,均把焦点放在RGB图片上,没有充分发挥支持向量机(Support Vector Machine, SVM)、ELM等优秀的分类器在显著检测上的潜力。因此,本文引入LBE特征这一性质较为优良的深度特征,把原有的RGB检测扩展至RGB-D的范畴。

2.2 对引导学习流程的优化

以往使用分类器进行的多尺度显著检测中虽然考虑到了多尺度对于超像素显著值精度的影响,但是在上文提到的已有的极限学习机算法中,只是孤立地在每个尺度上求出弱显著图后将其线性叠加。这种方式的弊端有:(1)极大地浪费了多尺度超像素带来的丰富信息;(2)仅由某一个特征(例如LBE特征)求取弱显著图,即使该特征表现优异,也难免会在某些特征本身难以精确描述的部位发生误判。

本文利用LBE与局部暗通道特征求出弱显著图。相比以前部分研究中仅依赖于局部暗通道特征或者仅依赖于LBE特征求取弱显著图的方式,采取双特征联合计算弱显著图的方式更好地弥补了单个特征的不足。

这里可以通过图2来对单特征的显著方法与本文的显著方法进行对比。其中第1行为本文结果,第2行为LBE结果。




图2 LBE部分显著图与本文对应显著图对比

由图2可以看出,多特征对于避免重大的误判有着极为重要的作用。图2中第1组、第3组图片显然精确度较之本文算法为低,而第2组图片则更为严重,LBE完全丢失了所寻找的显著目标。

这里,本文应用如下的方法对两幅弱显著图进行融合。

$$\mathbf{wSal}_n = \mathbf{wSal}_{n-1} + \mathbf{LBE}_n * \mathbf{Dark}_n \quad (1)$$

其中, \mathbf{wSal}_n 为第 n 种超像素尺度下的弱显著值, \mathbf{LBE}_n 和 \mathbf{Dark}_n 为第 n 种超像素尺度的对应弱显著

图,“*”表示内积。本文根据LBE特征和局部暗通道特征求出的弱显著图相乘,再与前一种超像素尺度求出的弱显著图相加。这种融合的方式,可以在最大程度上加强前景目标,削弱背景噪音。

经过这样的处理以后,弱显著图中的前景目标会显得更加清晰突出。从显著值的角度看,这种方式反复地将前景目标的显著值进行了加强,极大地提高了前景目标的显著值,而抑制了背景的显著值。这样一来,就为正负样本的选取做好了准备。

如图3所示,经过流程优化后的 P - R 曲线在前半段与未优化的曲线重合,但后半段开始,则显然地高于未经优化的结果所生成的 P - R 曲线。




图3 有无流程优化的 P - R 曲线对比

3 极限学习机

极限学习机是由Huang^[23]提出求解单隐层神经网络的算法。该算法性能优良,应用广泛,如在文献^[24,25]中可以看到ELM取得了良好的效果。简要介绍如下:对于一个单隐层神经网络,假设有 N 个任意的样本 $(\mathbf{X}_i, \mathbf{t}_i)$ 其中 $\mathbf{X}_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in \mathbf{R}_n$, $\mathbf{t}_i = [t_{i1}, t_{i2}, \dots, t_{im}]^T \in \mathbf{R}_m$ 。对于一个有 L 个隐层结点的单隐层神经网络可以表示为

$$\sum_{i=1}^L \beta_i g(\mathbf{W}_i * \mathbf{X}_i + \mathbf{b}_i) = \mathbf{o}_j, j = 1, 2, \dots, N \quad (2)$$

其中, $g(x)$ 为激活函数, $\mathbf{W} = [w_{i1}, w_{i2}, \dots, w_{im}]^T$ 为输入权重, β_i 为输出权重, \mathbf{b}_i 是第 i 个隐层单元的偏置, $\mathbf{W}_i * \mathbf{X}_j$ 表示 \mathbf{W}_i 和 \mathbf{X}_j 的内积。单隐层神经网络学习的目标是使得输出的误差最小,可以表示为

$$\sum_{j=1}^N \|\mathbf{o}_j - \mathbf{t}_j\| = 0 \quad (3)$$

即存在 β_i , \mathbf{W}_i 和 \mathbf{b}_i 使得

$$\sum_{i=1}^L \beta_i g(\mathbf{W}_i * \mathbf{X}_i + \mathbf{b}_i) = \mathbf{t}_j, j = 1, 2, \dots, N \quad (4)$$

矩阵表示为 $\mathbf{H}\beta = \mathbf{T}$,其中 \mathbf{H} 是隐层结点的输

出, β 为输出权重, T 为期望输出。为了能够训练单隐层神经网络, 以期得到 \widehat{W}_i , \widehat{b}_i 和 $\widehat{\beta}_i$, 使得

$$\|H(\widehat{W}_i, \widehat{b}_i)\widehat{\beta}_i - T\| = \min_{W, b, \beta} \|H(W_i, b_i)\beta_i - T\| \quad (5)$$

其中, $i=1, 2, \dots, L$, 这等于最小化损失函数

$$E = \sum_{j=1}^N \left(\sum_{i=1}^L \beta_i g(W_i * X_i + b_i) - t_j \right)^2 \quad (6)$$

在计算出弱显著图后, 本文依据显著值和阈值的关系选取正负样本。经过实验, 本文将正样本阈值设置为粗显著图显著均值的1.5倍, 即超像素块的显著值大于或等于全图显著均值1.5倍, 即为正样本。假如不存在符合条件的正样本, 则把显著值最高的超像素块设置为正样本。而对于负样本, 本文设定的阈值为粗显著图均值的0.05倍, 即小于或等于全图显著均值0.05倍或位于图像边界的超像素块, 即为负样本。

4 对ELM结果的进一步优化

4.1 深度层次检测

在真值图中, 往往可以看到前景图像是均匀且连续的, 前景图像从图像深度的角度来说, 应当是起伏和缓, 没有较大断裂的。那么可以有如下推论: 如果把深度逐段分割, 前景目标应该密集地出现在某一段或者几段深度区间内。

如果一个超像素块本身显著值低, 而其位于的深度段显著总值很高, 那么可以认为该超像素块的显著值有很大概率相对于正确显著值偏小, 就需要将其提高。如果相反, 则需要降低。

根据深度值由深到浅, 将深度分为 t 组。并设 M_w 是待优化的显著图, D 是对应的深度图, Sup 是超像素集合, Sal 是显著值, S 是小组显著总值的集合。

依据 D 计算每个超像素块的深度均值, 并依据均值将超像素块放入对应小组中。然后, 计算出每个小组的显著值总值, 如式(7)

$$S_t = \sum_{k=1}^n Sal_k \quad (7)$$

其中, S_t 是第 t 个小组的显著值总值, Sal_k 是当前小组中第 k 个超像素块的显著值, n 是当前小组超像素块的总数。最后, 将 S 进行归一化, 并将其作为先验概率, 对每个超像素块的显著值进行调整。这里使用贝叶斯条件概率来对每个超像素块的概率值进行调整。

$$Sup^* = \frac{P(SupSu)}{P(Su)} \quad (8)$$

其中, Sup^* 指的是当前超像素块的最终显著值, 是在 Su 的概率下对 Sup 的概率的调整。 Sup 指的是当前超像素块未经优化的显著值, $P(Su)$ 指 Sup 所在小组的先验概率。 $P(Sup Su)$ 指的是 Sup 和 Su 的联合概率。运用这种方法, 可以将位于高显著值组的低显著值超像素的显著值调高, 将与之相反的超像素块的显著值调低。

4.2 图割优化

图割(graph-cut)方法^[26]指的是根据灰度、颜色、纹理和形状等特征把图像划分成若干互不交迭的区域, 并使这些特征在同一区域内呈现出相似性, 而在不同区域间呈现出明显的差异性。到目前为止, 图割法已经在众多领域取得良好的效果, 如气象学^[27], 医学^[28]等。运用这种方法, 可以使显著图呈现平滑且连续的效果。

5 实验

如图4所示, 显然, 图例中本文的算法结果直观上更加清晰、准确。

本文选择在RGBD1000数据集上进行实验。该数据集包含1000张RGB图像, 1000张对应的由Microsoft Kinect采集的深度图, 以及1000张标注好的对应的真值图。下面是 $P-R$ 曲线的展示:

需要说明的是, 图5中是实验的结果。实验中, 与其它5种显著检测算法的最终显著图进行了对比。这5种方法均为RGB-D显著检测算法, 它们分别是: ACSD算法^[29], DES算法^[30], LBE算法, GP算法^[31], MGMR算法^[13]。

本次实验均在配置参数为Intel(R) Core(TM) i5-7500CPU @ 3.40 GHz, 内存16.0 GB的计算机上运行完成。所使用的开发程序为MATLAB(R2014a)。

本次实验的评价标准为精确度(Precision, P), 召回率(Recall, R)。并绘制了对应的 $P-R$ 曲线来对算法的性能进行评估。精确度, 指的是被正确检索的目标占有检索到的目标的比重; 召回率, 指的是被正确检索的目标占有正确目标的比重。

基本目标是, 以 P 为纵轴, R 为横轴。计算出 P 随 R 变化的曲线, 这就是 $P-R$ 曲线。曲线越高, 说明算法检测的效果越好。以图所见, 本文的方法确实优于当下较为流行的部分算法。

除了 $P-R$ 曲线以外, 本文还使用 F -measure对显著图进行了评估。 F -measure是 P 和 R 值的加权平均, F 值越高, 说明算法的效果越好。如表1所示, 本文算法在 F -measure值上也优于其他算法。

6 结束语

从实用性看, 本文提出的算法较为健壮, 可移

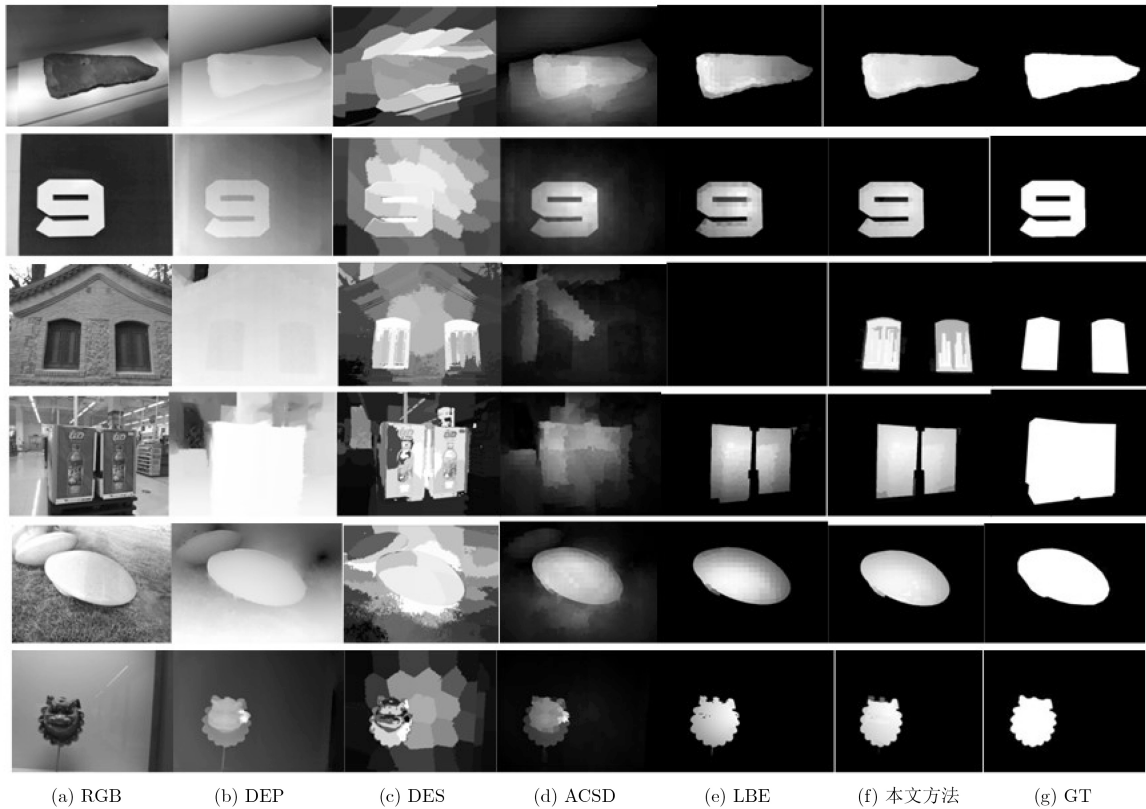


图4 部分图片不同方法显著图像对比




图5 各种方法的P-R曲线对比

表1 各算法F-measure值

算法	本文ELM	ACSD	MGMR	GP	LBE	DES
F值	0.7526	0.5857	0.6464	0.7220	0.7408	0.2728

植、复用性较强。与以前ELM的相关算法相比, 本文立足于ELM学习算法, 在分类机的工作流程、分类所使用的特征以及对分类结果进行调优3个环节, 均作出了一定的改进, 主要包括将原本只有单幅显著图的半监督用图扩展为两幅, 将4096维高维特征引入分类机, 以及提出基于深度层次性的显著图调优方法。总的来看, 本文做出了一定的成果, 推进了应用ELM进行RGBD显著目标检测的精确性。

参考文献

- [1] GOFERMAN S, ZELNIK-MANOR L, and TAL A. Context-aware saliency detection[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2012, 34(10): 1915–1926. doi: 10.1109/TPAMI.2011.272.
- [2] ROTHER C, KOLMOGOROV V, and BLAKE A. "GrabCut": Interactive foreground extraction using iterated graph cuts[J]. *ACM Transactions on Graphics*, 2004, 23(3): 309–314. doi: 10.1145/1015706.1015720.
- [3] DING Yuanyuan, XIAO Jing, and YU Jingyi. Importance filtering for image retargeting[C]. *The IEEE Conference on Computer Vision and Pattern Recognition*, Colorado Springs, USA, 2011: 89–96.
- [4] MAHADEVAN V and VASCONCELOS N. Saliency-based discriminant tracking[C]. *2009 IEEE Conference on Computer Vision and Pattern Recognition*, Miami, USA, 2009: 1007–1013.
- [5] SIAGIAN C and ITTI L. Rapid biologically-inspired scene classification using features shared with visual attention[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2007, 29(2): 300–312. doi: 10.1109/TPAMI.2007.40.
- [6] 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.
- [7] TONG Na, LU Huchuan, RUAN Xiang, *et al.* Salient object detection via bootstrap learning[C]. 2015 IEEE Conference on Computer Vision and Pattern Recognition, Boston, USA, 2015: 1884–1892. doi: [10.1109/CVPR.2015.7298798](https://doi.org/10.1109/CVPR.2015.7298798).
- [8] PERAZZI F, KRÄHENBÜHL P, PRITICH Y, *et al.* Saliency filters: Contrast based filtering for salient region detection[C]. 2012 IEEE Conference on Computer Vision and Pattern Recognition, Providence, USA, 2012: 733–740.
- [9] CHENG Mingming, MITRA N J, HUANG Xiaolei, *et al.* Global contrast based salient region detection[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2015, 37(3): 569–582. doi: [10.1109/TPAMI.2014.2345401](https://doi.org/10.1109/TPAMI.2014.2345401).
- [10] KLEIN D A and FRINTROP S. Center-surround divergence of feature statistics for salient object detection[C]. 2011 IEEE International Conference on Computer Vision, Barcelona, Spain, 2011: 2214–2219.
- [11] PENG Houwei, LI Bing, XIONG Weihua, *et al.* RGBD Salient Object Detection: A Benchmark and Algorithms[M]. FLEET D, PAJDLA T, SCHIELE B, *et al.* Computer Vision - ECCV 2014. Cham: Springer, 2014: 92–109. doi: [10.1007/978-3-319-10578-9_7](https://doi.org/10.1007/978-3-319-10578-9_7).
- [12] ZHANG Pingping, WANG Dong, LU Huchuan, *et al.* Learning uncertain convolutional features for accurate saliency detection[C]. 2017 IEEE International Conference on Computer Vision, Venice, Italy, 2017: 212–221.
- [13] XUE Haoyang, GU Yun, LI Yijun, *et al.* RGB-D saliency detection via mutual guided manifold ranking[C]. 2015 IEEE International Conference on Image Processing, Quebec City, Canada, 2015: 666–670.
- [14] ZHANG Lu, LIU Jianhua, and LU Huchuan. Saliency detection via extreme learning machine[J]. *Neurocomputing*, 2016, 218: 103–112. doi: [10.1016/j.neucom.2016.08.066](https://doi.org/10.1016/j.neucom.2016.08.066).
- [15] LI Guanbin and YU Yizhou. Visual saliency based on multiscale deep features[C]. 2015 IEEE Computer Vision and Pattern Recognition, Boston, USA, 2015: 5455–5463.
- [16] FENG D, BARNES N, YOU Shaodi, *et al.* Local background enclosure for RGB-D salient object detection[C]. 2016 IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, USA, 2016: 2343–2350.
- [17] KRIZHEVSKY A, SUTSKEVER I, and HINTON G E. ImageNet classification with deep convolutional neural networks[C]. The 25th International Conference on Neural Information Processing Systems, Lake Tahoe, USA, 2012: 1097–1105.
- [18] GIRSHICK R, DONAHUE J, DARRELL T, *et al.* Rich feature hierarchies for accurate object detection and semantic segmentation[C]. 2014 IEEE Conference on Computer Vision and Pattern Recognition, Columbus, USA, 2014: 580–587.
- [19] DONAHUE J, JIA Yangqing, VINYALS O, *et al.* DeCAF: A deep convolutional activation feature for generic visual recognition[C]. The 31st International Conference on International Conference on Machine Learning, Beijing, China, 2014: 647–655.
- [20] RAZAVIAN A S, AZIZPOUR H, SULLIVAN J, *et al.* CNN features off-the-shelf: An astounding baseline for recognition[C]. 2014 IEEE Conference on Computer Vision and Pattern Recognition Workshops, Columbus, USA, 2014: 806–813.
- [21] GUO Jingfang, REN Tongwei, HUANG Lei, *et al.* Saliency detection on sampled images for tag ranking[J]. *Multimedia Systems*, 2019, 25(1): 35–47. doi: [10.1007/s00530-017-0546-9](https://doi.org/10.1007/s00530-017-0546-9).
- [22] TONG Na, LU Huchuan, ZHANG Lihe, *et al.* Saliency detection with multi-scale superpixels[J]. *IEEE Signal Processing Letters*, 2014, 21(9): 1035–1039. doi: [10.1109/LSP.2014.2323407](https://doi.org/10.1109/LSP.2014.2323407).
- [23] HUANG Guangbin. What are extreme learning machines? Filling the gap between frank Rosenblatt’s dream and john von Neumann’s puzzle[J]. *Cognitive Computation*, 2015, 7(3): 263–278. doi: [10.1007/s12559-015-9333-0](https://doi.org/10.1007/s12559-015-9333-0).
- [24] CAO Weipeng, MING Zhong, WANG Xizhao, *et al.* Improved bidirectional extreme learning machine based on enhanced random search[J]. *Memetic Computing*, 2019, 11(1): 19–26. doi: [10.1007/s12293-017-0238-1](https://doi.org/10.1007/s12293-017-0238-1).
- [25] ESHTAY M, FARIS H, and OBEID N. Improving extreme learning machine by competitive swarm optimization and its application for medical diagnosis problems[J]. *Expert Systems with Applications*, 2018, 104: 134–152. doi: [10.1016/j.eswa.2018.03.024](https://doi.org/10.1016/j.eswa.2018.03.024).
- [26] BOYKOV Y, VEKSLER O, and ZABIH R. Fast approximate energy minimization via graph cuts[C]. The 7th IEEE International Conference on Computer Vision, Kerkyra, Greece, 1999: 377–384.
- [27] LIU Shuang, ZHANG Zhong, XIAO Baihua, *et al.* Ground-based cloud detection using automatic graph cut[J]. *IEEE Geoscience and Remote Sensing Letters*, 2015, 12(6): 1342–1346. doi: [10.1109/LGRS.2015.2399857](https://doi.org/10.1109/LGRS.2015.2399857).
- [28] YU Kai, CHEN Xinjian, SHI Fei, *et al.* A novel 3D graph cut based co-segmentation of lung tumor on PET-CT images with Gaussian mixture models[J]. *SPIE*, 2016, 9784: 97842V.
- [29] JU Ran, GE Ling, GENG Wenjing, *et al.* Depth saliency

- based on anisotropic center-surround difference[C]. 2014 IEEE International Conference on Image Processing, Paris, France, 2014: 1115–1119.
- [30] CHENG Yupeng, FU Huazhu, WEI Xingxing, *et al.* Depth enhanced saliency detection method[C]. International Conference on Internet Multimedia Computing and Service, Xiamen, China, 2014.
- [31] REN Jianqiang, GONG Xiaojin, YU Lu, *et al.* Exploiting global priors for RGB-D saliency detection[C]. 2015 IEEE Conference on Computer Vision and Pattern Recognition Workshops, Boston, MA, USA, 2015: 25–32.
- 刘政怡: 女, 1978年生, 副教授, 研究方向为计算机视觉.
徐天泽: 男, 1994年生, 硕士生, 研究方向为计算机视觉.