

融合小型深度生成模型的显著性检测

陈星宇¹, 叶锋^{1,2}, 黄添强^{1,2}, 翁彬^{1,2}, 陈家祯^{1,2}, 林文忠³

(1. 福建师范大学数学与信息学院, 福建福州 350117; 2. 数字福建大数据安全技术研究所, 福建福州 350117;
3. 福建省信息处理与智能控制重点实验室(闽江学院), 福建福州 350108)

摘要: 针对基于深度神经网络模型的显著性检测方法中存在的模型训练困难、模型参数量大以及检测速度慢等问题, 本文提出了一种融合小型深度生成模型的显著性检测方法. 方法以生成对抗网络为框架, 设计了包含 11 个卷积模块和 5 个池化层的鉴别器网络以及不包含池化层, 仅包含 15 个卷积模块和 5 个转置卷积模块的小型生成器网络. 其中, 小型生成器网络大小仅 2.4M, 参数量仅 67 万左右. 将训练好的小型生成器用于显著性检测, 并与 LMB(融合背景块再选取过程的显著性检测)算法通过设计的融合算法进行融合, 从而得到最终结果. 通过大量的实验对比分析表明, 提出的方法在 F 值和 MAE(Mean Absolute Error)值上均取得大幅提升.

关键词: 显著性检测; 深度神经网络; 生成对抗网络; 小型生成器网络; 融合算法

中图分类号: TP391.41 **文献标识码:** A **文章编号:** 0372-2112(2021)04-0768-07

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.12263/DZXB.20200488

Saliency Detection Combined with Small-Scale Deep Generation Model

CHEN Xing-yu¹, YE Feng^{1,2}, HUANG Tian-qiang^{1,2}, WENG Bin^{1,2}, CHEN Jia-zhen^{1,2}, LIN Wen-zhong³

(1. College of Mathematics and Informatics, Fujian Normal University, Fuzhou, Fujian 350117, China;

2. Digital Fujian Institute of Big Data Security Technology, Fuzhou, Fujian 350117, China;

3. Fujian Provincial Key Laboratory of Information Processing and Intelligent Control (Minjiang University), Fuzhou, Fujian 350108, China)

Abstract: Aiming at the difficulties of model training, large amount of model parameters, and slow detection speed in the saliency detection method based on deep neural network models, this paper proposes a saliency detection method that integrates small deep generative models. The method uses the generative adversarial network as the framework, designs a discriminator network consisting of 11 convolution modules and 5 pool layers, as well as a small generator network that does not contain the pool layer, including only 15 convolution modules and 5 transposed convolution modules. Among them, the size of the small generator network is only 2.4M, and the amount of parameters is only about 670,000. A trained small generator is used for saliency detection and fused with the LMB (Salient object detection based on background block re-selection method) algorithm through the designed fusion algorithm to get the final result. A large number of experiments and comparative analysis show that the proposed method has achieved significant improvements in both F value and MAE (Mean Absolute Error) value.

Key words: saliency detection; deep neural network; generative adversarial networks; small generation network; fusion algorithm

1 引言

显著性检测作为计算机处理图像视频信息的预处理步骤,它能够让计算机模拟人类处理视觉信息的过

程来提取图像或视频帧中的关键信息,从而加快处理过程.目前,显著性检测被广泛地应用于图像检索,图像压缩以及目标检测等诸多图像处理领域.在分类上,显著性检测从应用角度可分为视觉焦点预测和显著性区

收稿日期:2020-05-21;修回日期:2020-10-08;责任编辑:覃怀银

基金项目:国家自然科学基金(No. 61671077);福建省自然科学基金(No. 2017J01739, No. 2018J01779);闽江学院福建省信息处理与智能控制重点实验室开放基金(No. MJUKF-IPIC201810)

域检测. 后者又可细分为四个分支^[1]: 基于单幅图像的显著性检测、结合深度信息的显著性检测、联合显著性检测以及视频显著性检测. 本文主要关注基于单幅图像的显著性区域检测.

2 提出的方法

2.1 方法流程图

本文提出方法的流程图如图 1 所示. 生成对抗网络

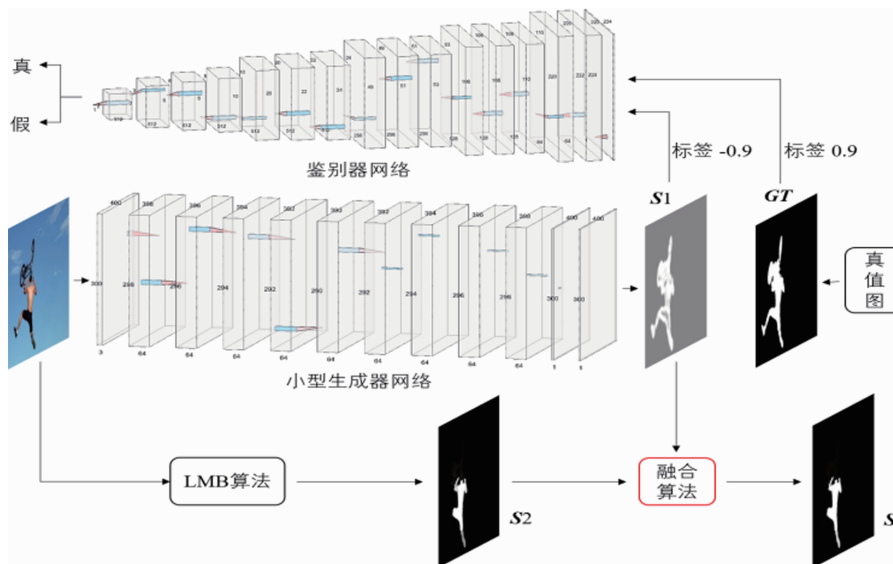


图1 本文方法流程图

2.2 小型生成器的构建

提出的小型生成器网络的详细结构如表 1 所示. 网络由 15 个卷积模块和 5 个转置卷积模块构成, 总参数量仅 67 万左右, 大小仅为 2.4M. 网络中所有卷积层的步长以及转置卷积层的上采样率均设置为 1. 每个卷积模块包含卷积层 Conv (Convolution)、批归一化层 BN (Batch Normalization) 以及非线性激活函数层 ReLU (Rectified Linear Unit) 三个部分. 每个转置卷积模块则包含转置卷积层 ConvT (Transpose Convolution)、批归一化层以及非线性激活函数层三个部分. 参考 VGG (Visual Geometry Group) 网络^[3] 第一层的卷积核个数为 64, 为了控制网络的参数量, 小型生成器网络中所有卷积层与转置卷积层的卷积核个数均设为 64, 核的长宽均为 3. 同时, 文献[3]还指出池化操作使输出特征图的长宽均缩小为原来的一半, 故后续卷积层中卷积核个数需翻倍. 为控制小型生成器网络大小, 网络不包含池化操作, 故所有卷积层的卷积核个数保持 64 不变. 此外, 每三个卷积模块又可分为一组 (共 5 组), 每组中首个卷积层不对输入的特征图进行填充操作, 其余两层则在特征图四周填充单排的 0 像素. 5 个卷积组后是 5

先以手动分阶段的方式进行训练, 训练完毕提取出小型生成器网络用于显著性检测, 得到的显著图记为 S1. 由于 LMB 算法^[2] (融合背景块再选取过程的显著性检测) 在本文实验所采用的所有传统对比方法中综合表现最佳, 故引入 LMB 算法, 将其得到的显著图记为 S2. 最后, 通过本文设计的融合算法将 S1 和 S2 进行融合后生成最终显著图 S.

个转置卷积模块, 经 5 次上采样率为 1 的转置卷积后, 输出的特征图是与原图大小一致的灰度图. 若设输入的 RGB 图像大小为 $m \times n \times 3$, 则每层输出的特征图尺寸如表最后一列所示. 最后, sigmoid 层对灰度图的每个像素点是属于前景或背景进行二分类处理后便得到了显著图.

2.3 鉴别器的构建

提出的鉴别器网络的详细结构如表 2 所示. 网络包含 11 个卷积模块和 5 个池化层. 每个卷积模块同样包含卷积层 Conv、批归一化层 BN 以及非线性激活函数层 ReLU 三个部分. 池化层 pool 的核大小均为 2×2 , 步长均为 2, 采用最大池化函数, 故每经一次池化操作, 特征图长宽大小均缩小一半. 特别的, 若原特征图长宽大小为奇数, 则经池化后新特征图的长宽值大小为向下取整后的值. 与文献[3]的处理方式一致, 池化后的卷积层中卷积核的个数翻倍, 且当个数增至 512 时便不再增加. 此外, 为便于网络设计, 本文将输入的图像经预处理后长宽均统一为 224 像素, 每层输出的特征图尺寸如表最后一列所示. 最后, loss 层用于计算网络判别结果的损失值.

表 1 小型生成器网络详细结构

模块	包含的层	核大小/个数	填充	输出特征图尺寸
Conv_block1	Conv、BN、ReLU	$[3 \times 3 \times 3]/64$	否	$(m-2) \times (n-2) \times 64$
Conv_block2	Conv、BN、ReLU	$[3 \times 3 \times 64]/64$	是	$(m-2) \times (n-2) \times 64$
Conv_block3	Conv、BN、ReLU	$[3 \times 3 \times 64]/64$	是	$(m-2) \times (n-2) \times 64$
Conv_block4	Conv、BN、ReLU	$[3 \times 3 \times 64]/64$	否	$(m-4) \times (n-4) \times 64$
Conv_block5	Conv、BN、ReLU	$[3 \times 3 \times 64]/64$	是	$(m-4) \times (n-4) \times 64$
Conv_block6	Conv、BN、ReLU	$[3 \times 3 \times 64]/64$	是	$(m-4) \times (n-4) \times 64$
Conv_block7	Conv、BN、ReLU	$[3 \times 3 \times 64]/64$	否	$(m-6) \times (n-6) \times 64$
Conv_block8	Conv、BN、ReLU	$[3 \times 3 \times 64]/64$	是	$(m-6) \times (n-6) \times 64$
Conv_block9	Conv、BN、ReLU	$[3 \times 3 \times 64]/64$	是	$(m-6) \times (n-6) \times 64$
Conv_block10	Conv、BN、ReLU	$[3 \times 3 \times 64]/64$	否	$(m-8) \times (n-8) \times 64$
Conv_block11	Conv、BN、ReLU	$[3 \times 3 \times 64]/64$	是	$(m-8) \times (n-8) \times 64$
Conv_block12	Conv、BN、ReLU	$[3 \times 3 \times 64]/64$	是	$(m-8) \times (n-8) \times 64$
Conv_block13	Conv、BN、ReLU	$[3 \times 3 \times 64]/64$	否	$(m-10) \times (n-10) \times 64$
Conv_block14	Conv、BN、ReLU	$[3 \times 3 \times 64]/64$	是	$(m-10) \times (n-10) \times 64$
Conv_block15	Conv、BN、ReLU	$[3 \times 3 \times 64]/64$	是	$(m-10) \times (n-10) \times 64$
Convt_block1	Convt、BN、ReLU	$[3 \times 3 \times 64]/64$	-	$(m-8) \times (n-8) \times 64$
Convt_block2	Convt、BN、ReLU	$[3 \times 3 \times 64]/64$	-	$(m-6) \times (n-6) \times 64$
Convt_block3	Convt、BN、ReLU	$[3 \times 3 \times 64]/64$	-	$(m-4) \times (n-4) \times 64$
Convt_block4	Convt、BN、ReLU	$[3 \times 3 \times 64]/64$	-	$(m-2) \times (n-2) \times 64$
Convt_block5	Convt、BN、ReLU	$[3 \times 3 \times 64]/1$	-	$m \times n \times 1$
sigmoid	sigmoid	-	-	$m \times n \times 1$

表 2 鉴别器网络详细结构

模块	包含的层	核大小/个数	填充	输出特征图尺寸
Conv_block1	Conv、BN、ReLU	$[3 \times 3 \times 1]/64$	否	$222 \times 222 \times 64$
Conv_block2	Conv、BN、ReLU	$[3 \times 3 \times 64]/64$	否	$220 \times 220 \times 64$
pool1	pool(max)	$[2 \times 2]/1$	否	$110 \times 110 \times 64$
Conv_block3	Conv、BN、ReLU	$[3 \times 3 \times 64]/128$	否	$108 \times 108 \times 128$
Conv_block4	Conv、BN、ReLU	$[3 \times 3 \times 128]/128$	否	$106 \times 106 \times 128$
pool2	pool(max)	$[2 \times 2]/1$	否	$53 \times 53 \times 128$
Conv_block5	Conv、BN、ReLU	$[3 \times 3 \times 128]/256$	否	$51 \times 51 \times 256$
Conv_block6	Conv、BN、ReLU	$[3 \times 3 \times 256]/256$	否	$49 \times 49 \times 256$
pool3	pool(max)	$[2 \times 2]/1$	否	$24 \times 24 \times 256$
Conv_block7	Conv、BN、ReLU	$[3 \times 3 \times 256]/512$	否	$22 \times 22 \times 512$
Conv_block8	Conv、BN、ReLU	$[3 \times 3 \times 512]/512$	否	$20 \times 20 \times 512$
pool4	pool(max)	$[2 \times 2]/1$	否	$10 \times 10 \times 512$
Conv_block9	Conv、BN、ReLU	$[3 \times 3 \times 512]/512$	否	$8 \times 8 \times 512$
Conv_block10	Conv、BN、ReLU	$[3 \times 3 \times 512]/512$	否	$6 \times 6 \times 512$
pool5	pool(max)	$[2 \times 2]/1$	否	$3 \times 3 \times 512$
Conv_block11	Conv、BN、ReLU	$[3 \times 3 \times 512]/1$	否	$1 \times 1 \times 1$
loss	loss	-	-	-

2.4 网络的目标函数

$$\min_G \max_D V(D, G) = E_{x \sim p_{\text{data}}(x)} [\log D(x)] + E_{z \sim p_G(z)} [\log(1 - D(G(z)))] \quad (1)$$

本文训练生成对抗网络使用的目标函数与文献[4]中的一致,如式(1)所示.其中, $p_{\text{data}}(x)$ 表示真实数据样本集, $p_G(z)$ 表示由生成器生成的数据样本集, $D(\cdot)$ 表示鉴别器对输入数据做出的预测值, $G(z)$ 表示生成器生成的数据样本.

2.5 网络的训练过程

为提高训练稳定性,本文将真值图所对应的标签值设为0.9,而将生成器生成的显著图所对应的标签值设为-0.9.此外,由于Matlab中存在单一数组元素个数不能超过14000个的限制,故本文将5个公用数据集分为2组分批输入网络进行训练.这2组数据集分别是由MSRA10K数据集(10000张)独自构成的A组和其余4个数据集(DUT-OMRON、ECSSD、SOD以及SED2,总计6568张)构成的B组.训练过程如下:

(1)随机初始化网络参数;

(2)将A组数据集作为训练集,以学习率 10^{-6} 训练5轮,调整学习率为 3×10^{-6} 后再训练1轮;

(3)将B组数据集作为训练集,以学习率 10^{-6} 训练10轮;

(4)将A组数据集作为训练集,以学习率 10^{-6} 训练8轮后停止训练.

2.6 提出的融合算法以及最终显著图的生成

本文提出的融合算法以MCA(Multi-layer Cellular Automata)算法^[5]为基础,对其修改后使得每次只对输入的2张显著图进行融合,本文称之为MCA2算法.提出的融合算法步骤如下:

(1)输入小型生成器网络检测得到的显著图S1与LMB算法检测得到的显著图S2;

(2)初始化变量*i*为0,初始化矩阵变量S与T为空;

(3)调用MCA2算法对S1与S1进行自身融合,将输出的显著图存于矩阵变量T中;

(4)*i*的值自增1,若*i*大于4,则转步骤(7),否则执行下一步;

(5)调用MCA2算法对S2与T进行融合,将输出的显著图存于矩阵变量S中;

(6)将T值更新为S并返回步骤(4);

(7)输出矩阵变量S.

经融合算法处理,输出的矩阵变量S即为本文算法的最终显著图.

3 实验分析

3.1 数据集与评估指标

实验采用的5个公用数据集分别为MSRA10K(10000张)、ECSSD(1000张)、DUT-OMRON(5168张)、SOD(300张)以及SED2(100张).

实验采用的2个客观评估指标分别是*F*值与MAE(Mean Absolute Error)值.*F*值的定义如式(2)所示.

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

其中,*P*表示查准率,*R*表示查全率, β^2 为固定变量.与多数文献一致,本文 β^2 取值为0.3.MAE的定义如式(3)所示.

$$\text{MAE} = \frac{1}{W \times H} \sum_{x=1}^W \sum_{y=1}^H |S(x, y) - G(x, y)| \quad (3)$$

其中,*W*和*H*分别代表图像的宽和高,(*x*,*y*)代表像素的坐标,*S*代表算法生成的显著图,*G*代表人工标定的真值图.

3.2 实验环境与主要超参数设置

本文实验的硬件环境为配置了Intel(R)Core(TM)i7-9750H@2.60GHz6核处理器、16GB内存、RTX2060显卡以及6GB显存的笔记本电脑.软件环境为Windows10、Matlab2019、VS2015、编译Matconvnet库的GPU版本以及安装cudnn库.

本文实验的主要超参数设置如下:受限于显存大小仅有6GB,批大小设为8;ReLU非线性激活函数的泄露因子leak均设为0.1;更新网络参数的优化算法为Adam算法.

3.3 主观对比分析

本文提出的算法与7个新近算法(GP^[6]、LPS^[7]、BSCA^[5]、SMD^[8]、TSG^[9]、LMH^[10]、LMB^[2])在5个公用数据集上进行实验对比分析.

本文算法各部分检测结果如图2所示.其中,Gen表示小型生成器网络的检测结果.首先,从第1、5、6、7张图像的检测结果可以发现小型生成器网络在面对含有多个显著目标的图像时表现优异.其次,由第2、8、9、14张图像的检测结果可以看出小型生成器网络检测出的显著区域更加完整.最后,第3、4张图像的检测结果表明小型生成器网络在面对前景与背景相似的这类图像时表现不佳.通过与LMB算法的融合,最终检测结果显著性区域的置信度得到提高(第2、4、5、8、10、11、13张图的结果),背景区域得到更有效的抑制(第3、6张图的结果).但小型生成器网络在面对第1、2、6、7、8、11、14张图像时检测出的显著性区域没有很好地融入算法的最终结果,故提出的融合算法还有改进空间.

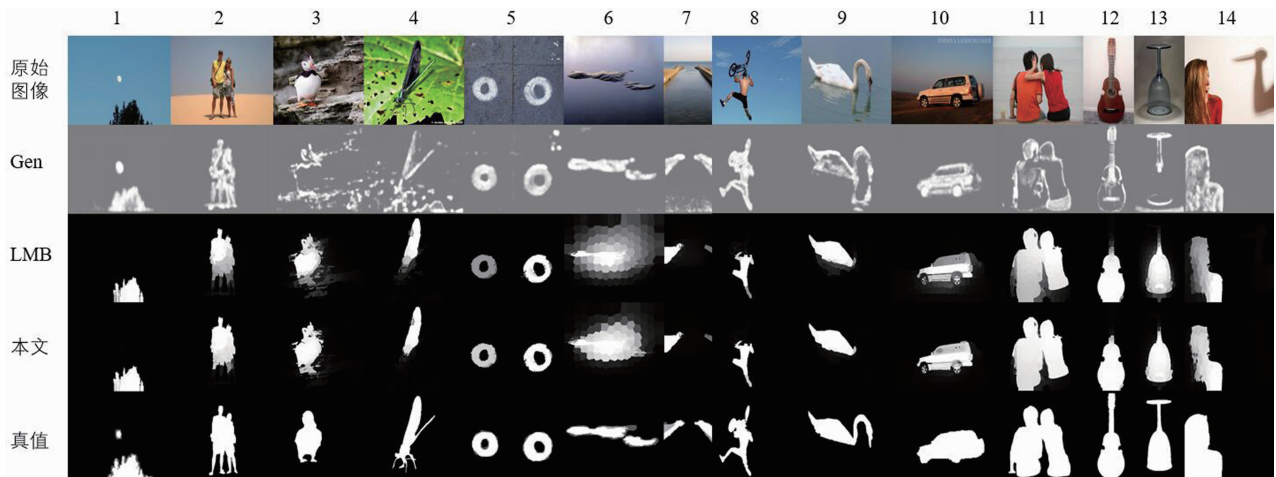


图2 本文算法的各部分检测结果

本文算法与7种对比算法检测得到的显著图如图3所示. 可以看到,本文算法相较于LMB算法有细微的提升,表现为显著性区域置信度更高、更加明亮(第1、2、4、8、10、13、14张图的结果),对背景也有更好地抑制

(第3、6、11张图的结果). 与其他算法的对比中,本文算法在显著性区域完整性、显著区域置信度以及对背景抑制三个方面均有不同程度的提升.

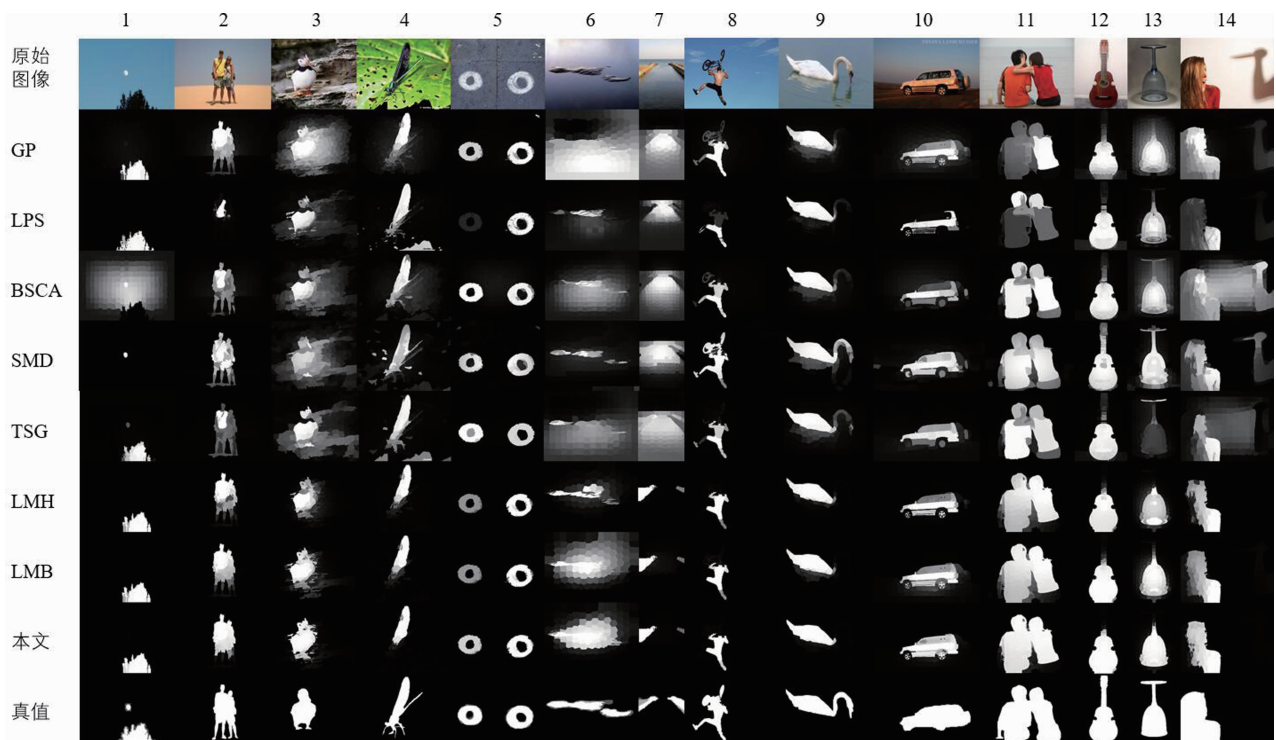


图3 本文算法与各对比算法的检测结果

3.4 客观对比分析

实验在5个公用数据集上取得的各指标结果如表3所示. 由表可以看出,本文算法在5个数据集上各指标值均优于LMB算法. 在MSRA10K数据集上,本文算法的MAE值为0.0841,在所有对比算法中取得第一,相较于LMB算法的0.0928降低了约9.4%. 算法的 F 值为0.7397,在所有算法中取得第二,相较于LMB算

法的0.7219提升了约2.5%. 在ECSSD数据集上,本文算法的MAE值为0.1540, F 值为0.6593,两个指标在所有对比算法中均取得第一. 相较于LMB算法,MAE降低了约5.8%, F 值提升了约3.3%. 在DUT-OMRON数据集上,本文算法的MAE值为0.1443, F 值为0.5378,两个指标在所有对比算法中均取得第二. 相较于LMB算法,MAE降低了约6.1%, F 值提升了约

2.6%. 在 SOD 数据集上,本文算法的 MAE 值为 0.2280, F 值为 0.5529,两个指标在所有对比算法中均取得第一. 相较于 LMB 算法,MAE 降低了约 3.5%, F 值提升了约 3.9%. 在 SED2 数据集上,本文算法的

MAE 值为 0.1451, F 值为 0.6883,两个指标在所有对比算法中均取得第二. 相较于 LMB 算法,MAE 降低了约 3.1%, F 值提升了约 1.6%.

表 3 本文算法与 7 个对比算法在 5 个公用数据集上各评估指标的对比结果

数据集	指标	GP	LPS	BSCA	SMD	TSG	LMH	LMB	本文
MSRA10K	F	0.6869	0.6188	0.6626	0.7615	0.7229	0.7159	0.7219	0.7397
	P	0.7810	0.8163	0.7806	0.8760	0.8861	0.8260	0.8135	0.8205
	R	0.6599	0.5220	0.6453	0.7159	0.6549	0.6265	0.6586	0.6759
	MAE	0.1231	0.1238	0.1252	0.1046	0.1142	0.0946	0.0928	0.0841
ECSSD	F	0.6198	0.5207	0.6028	0.6213	0.5808	0.6300	0.6384	0.6593
	P	0.7118	0.7683	0.7379	0.7517	0.7652	0.7725	0.7513	0.7609
	R	0.6606	0.4305	0.6183	0.6358	0.5573	0.5398	0.5903	0.6035
	MAE	0.1910	0.1860	0.1824	0.1734	0.1804	0.1622	0.1635	0.1540
DUT-OMRON	F	0.4715	0.4772	0.4794	0.5115	0.5051	0.5414	0.5244	0.5378
	P	0.5093	0.6220	0.5498	0.5887	0.6043	0.6050	0.5714	0.5769
	R	0.6670	0.4703	0.6284	0.6355	0.5953	0.5929	0.6333	0.6495
	MAE	0.2085	0.1449	0.1907	0.1661	0.1769	0.1362	0.1537	0.1443
SOD	F	0.5268	0.4043	0.5096	0.5328	0.4831	0.5252	0.5323	0.5529
	P	0.6419	0.6952	0.6791	0.7102	0.6922	0.7174	0.6858	0.6945
	R	0.5540	0.3104	0.5064	0.5032	0.4521	0.4142	0.4566	0.4656
	MAE	0.2605	0.2560	0.2525	0.2328	0.2547	0.2324	0.2363	0.2280
SED2	F	0.6506	0.6264	0.6351	0.6942	0.6564	0.6730	0.6777	0.6883
	P	0.7760	0.8557	0.7940	0.8660	0.8360	0.8866	0.8601	0.8648
	R	0.5894	0.4542	0.5527	0.5668	0.5401	0.4687	0.5061	0.5160
	MAE	0.1759	0.1549	0.1707	0.1417	0.1666	0.1512	0.1498	0.1451

注:加粗字体表示每行最优值.

3.5 模型有效性分析

一方面,为验证本文算法最终结果的提升是由于融合了小型生成器网络 Gen,而不是 MCA 算法自身的优化作用导致的,本文在 DUT-OMRON 数据集上进行了实验验证,实验结果如表 4 所示. 从表中可以看到,“LMB + Gen”的结果(即本文方法最终结果)在 MAE 值、 F 值、准确率 P 这三个关键指标上均优于“LMB + LMB”的结果.

表 4 LMB 算法自身融合结果与本文算法最终结果在 DUT-OMRON 数据集上的各指标对比

	MAE	F	P	R
LMB	0.1537	0.5244	0.5714	0.6333
Gen	0.1932	0.2891	0.3569	0.3673
LMB + LMB	0.1482	0.5364	0.5709	0.6592
LMB + Gen	0.1443	0.5378	0.5769	0.6495

注:加粗字体表示每列最优值.

另一方面,为验证提出的小型生成器网络 Gen 与传统检测方法融合后能改善传统方法的性能表现,本文将 Gen 与其余传统对比算法分别进行融合,融合前后的结果对比如表 5 所示. 从表中可以看到,每个算法在融合后 MAE 值与 F 值两个指标均得到大幅度提升.

表 5 其余 6 种传统对比算法与小型生成器网络 Gen 融合前后在 DUT-OMRON 数据集上 MAE 值与 F 值对比

	MAE	F
GP + Gen	0.1783(0.2085)	0.5018(0.4715)
LPS + Gen	0.1279(0.1449)	0.5198(0.4772)
BSCA + Gen	0.1605(0.1907)	0.5190(0.4794)
SMD + Gen	0.1426(0.1661)	0.5511(0.5115)
TSG + Gen	0.1554(0.1769)	0.5425(0.5051)
LMH + Gen	0.1302(0.1362)	0.5528(0.5414)

注:每行括号中的值表示各算法不与 Gen 融合时的原始值.

此外,本文在 DUT-OMRON 数据集上对小型生成器网络 Gen 的检测速度也进行了评估. 在本文实验环境下,通过 GPU 检测得到一张显著图平均耗时 0.09s, CPU 下则为 0.76s.

4 结论

本文基于生成对抗网络框架,设计并训练了全新的小型生成器网络,网络的参数量仅为 67 万左右,体积仅 2.4M. 通过设计的融合算法将小型生成器网络与 LMB 算法进行融合,从而提出了融合小型深度生成模型的显著性检测方法. 大量的实验对比分析表明,本文

提出的算法是有效的且具有优越性. 此外, 提出的小型生成器网络由于参数量的限制, 对前景与背景相似的图像检测效果不佳, 而提出的融合算法也还需改进, 以便进一步提升算法的性能.

参考文献

- [1] Cong R, Lei J, Fu H, et al. Review of visual saliency detection with comprehensive information [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2018, 29(10): 2941 – 2959.
- [2] 陈星宇, 叶锋, 等. 融合背景块再选取过程的显著性检测 [J]. 中国图象图形学报, 2020, 25(6): 1104 – 1115.
Chen X Y, Ye F, et al. Salient object detection based on background block re-selection method [J]. Journal of Image and Graphics, 2020, 25(6): 1104 – 1115. (in Chinese)
- [3] Simonyan K, Zisserman A. Very Deep Convolutional Networks for Large-Scale Image Recognition [EB/OL]. <https://arxiv.org/abs/1409.1556.html>, 2014-09-04.
- [4] Goodfellow I, Pouget-Abadie J, Mirza M, et al. Generative adversarial nets [A]. Advances in Neural Information Processing Systems [C]. Montréal, Canada: NIPS, 2014. 2672 – 2680.
- [5] Qin Y, Lu H, Xu Y, et al. Saliency detection via cellular automata [A]. IEEE Conference on Computer Vision and Pattern Recognition [C]. Boston, MA, USA: IEEE, 2015. 110 – 119.
- [6] Jiang P, Vasconcelos N, Peng J. Generic promotion of diffusion-based salient object detection [A]. IEEE International Conference on Computer Vision [C]. Santiago, Chile: IEEE, 2015. 217 – 225.
- [7] Li H, Lu H, 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.
- [8] Peng H, Li B, Ling H, et al. Salient object detection via structured matrix decomposition [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(4): 818 – 832.
- [9] 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.
- [10] 叶锋, 洪斯婷, 等. 基于多特征扩散方法的显著性物体检测 [J]. 电子与信息学报, 2018, 40(5): 1210 – 1218.

Ye F, Hong S T, et al. Salient object detection via multi-feature diffusion-based method [J]. Journal of Electronics & Information Technology, 2018, 40(5): 1210 – 1218. (in Chinese)

作者简介



陈星宇 男, 1993 年生于福建福州. 现为福建师范大学计算机应用技术专业硕士研究生, 主要研究方向为显著性检测、深度学习.
E-mail: 1052281512@qq.com



叶 锋 (通信作者) 男, 1978 年生于福建福州. 现为福建师范大学副教授、硕士生导师. 主要研究方向为计算机视觉、深度学习、视频图像编码.
E-mail: yefeng@fjnu.edu.cn



黄添强 男, 1971 年生于福建莆田. 现为福建师范大学教授、博士生导师. 主要研究方向为人工智能、机器学习、数据挖掘及其应用.
E-mail: huangtianqiang@fjnu.edu.cn



翁 彬 男, 1981 年生于福建福州. 现为福建师范大学讲师、硕士生导师. 主要研究方向为深度学习及其应用.
E-mail: wengbin@fjnu.edu.cn

陈家祯 女, 1972 年生于福建福州. 现为福建师范大学副教授、硕士生导师. 主要研究方向为视频图像处理.
E-mail: jiazhen_chen@fjnu.edu.cn

林文忠 男, 1964 年生于福建福州. 现为闽江学院教授. 主要研究方向为智能控制技术、电力电子变换技术.
E-mail: 5806526@qq.com