DOI:10.19652/j.cnki.femt.2102520

基于多路径递归增强的显著性目标检测方法*

张晓宁　王雨青　陈小林
(中国科学院 长春光学精密机械与物理研究所 长春 130033)

摘　要:近年来,显著性目标检测在计算机视觉领域中得到了广泛的关注。随着深度学习技术的发展,越来越多先进的算法被提出。目前基于深度学习的显著性目标检测方法主要使用VGG、ResNet等经典骨干网络以及它们基于FCN结构进行的变形作为基础网络。这些方法通过在基础网络上增加复杂的结构学习特征,导致网络训练变得困难,对数据的依赖变强。针对上述问题,设计了基于多路径递归增强的显著性目标检测方法。该方法引入多路径递归连接对基础网络进行增强,将网络前一时刻深层学习的高水平信息通过递归的方式传递到网络当前时刻的浅层,使得网络的浅层也能获得语义信息,从而在不增加过多层和参数的情况下提升网络整体的学习能力。在多个公开数据集上的实验结果表明,该方法对各种基础网络有明显的增强作用(其中VGG-FCN结构增强后在DUT-OMRON数据集上F-measure值提升了近9.1%)。最终结果达到了先进的显著性目标检测水平。

关键词:计算机视觉;深度学习;卷积神经网络;多路径递归增强;显著性目标检测
中图分类号:TP391　　**文献标识码**:A　　**国家标准学科分类代码**:510.40

Multi-path recurrent enhanced salient object detection method

Zhang Xiaoning　Wang Yuqing　Chen Xiaolin
(Changchun Institute of Optics, Fine Mechanics and Physics, Chinese Academy of Sciences, Changchun 130033, China)

Abstract: Recently, salient object detection has been widely concerned in computer vision field. Benefiting by the development of deep learning technology, more and more advanced methods are proposed. At the present, most deep learning based salient object detection methods use classical backbone networks such as VGG, ResNet and the FCN-based variations of these backbone networks as the baseline networks. These methods learn features by adding complex structure on the baseline, which leads to difficulties in training stage and more dependencies on data. To address these problems, in this paper, we design a multi-path recurrent enhanced salient object detection method. This method introduces multi-path recurrent connections to enhance the baseline networks and it transfers the high-level information learned by the deep layer of the previous time to the shallow layers of the current time in a recurrent way. By this way, the shallow layers of the network can also attain the semantic information. Without adding too many layers and parameters, the overall learning ability of the baseline networks can be improved effectively. Experiments on benchmark datasets demonstrates that our method have a significant enhancing impact on the baseline networks(F-measure value of VGG-FCN increases 9.1% on DUT-OMRON dataset after enhancement)and can achieve the state-of-the-art salient object detection performance.

Keywords: computer vision; deep learning; convolutional neural networks; multi-path recurrent enhancement; salient object detection

收稿日期:2021-01-27
*基金项目:国家重点研发计划(2018YFC0308100,2018YFC0307902)项目资助

(C)1994-2021 China Academic Journal Electronic Publishing House. All rights reserved.　http://www.cnki.net

0 引 言

人眼在观察一个场景时，能第一时间捕捉到场景中最有用的信息，将注意力集中在特定的区域。受到人眼注意机制的启发，显著性目标检测算法被提出。它通过提取图像特征设计模型来预测图像中显著的目标区域。基于这一特点，显著性目标检测被应用到了很多计算机视觉问题的预处理中，如目标识别、视频压缩、基于内容感知的图像编辑、图像检索等。传统的显著性目标检测方法[1-6]主要使用人工设计的特征，如颜色、对比度等。这些人工设计的特征通常都是在有限的知识和数据统计下得到的，因此在复杂场景下不能很好的表征目标特性。

得益于深度学习技术的发展，显著性目标检测算法在近年来取得了长足的进步。早期的深度学习算法[7]受到全连接层的影响，只能使用图像块或者超像素为单位进行训练，这种方式限制了深度学习模型的学习能力和效率。随着全卷积网络的提出，越来越多的模型[8-15]采用端到端的方式预测像素级别的显著性。目前比较先进的显著性目标检测模型基本都采用经典的 VGG[16]、ResNet[17]等骨干网络或者参考 FCN[18]结构进行变形的网络作为基础网络(baseline networks)。包含非常丰富的目标先验信息。这些先验信息可以帮助后续的显著性目标检测模型更好的提取目标，区分前景和背景。基于基础网络，现有的方法主要通过增加新的复杂结构来学习适合显著性目标检测的特征(如多水平特征[12]等)。这种方式虽然能够有效的提升模型性能，但同时也引入了更多需要学习的参数，使得网络的训练变得困难，对数据的依赖性也会变得更强。

事实上，基础网络本身也有一定的检测效果，但是由于网络相对简单，浅层很难获得高水平的语义信息，因此整体的学习能力有限。由此，本文引入多路径递归连接机制[19]，在不增加新的复杂结构的同时，对网络进行增强。为了探讨多路径递归连接机制的作用，本文采用不同的结构作为基础网络，分别为 VGG、VGG-FCN、ResNet、ResNet-FCN。其中“*-FCN”表示该网络参考 FCN 结构进行的变形。在确定基础网络后，本文采用多路径递归连接，将前一时刻网络深层的高水平信息传递到当前时刻网络的浅层。这样网络的浅层就能获得语义信息，从而增强网络整体的学习能力。为了证明模型的有效性，本文在多个公开的数据集上进行了实验。结果表明，多路径递归连接机制对不同类型的基础网络都能起到很好的增强作用，最终获得了较好的检测效果。

1 基础网络

1.1 VGG 及 VGG-FCN

经过大规模图像分类数据集预训练后的 VGG[16]模型被广泛应用在计算机视觉的各个领域，是目前最好用的骨干网络之一。为了保证基础模型的简单性，本文选取 VGG16 作为基础网络。由于原始的 VGG16 包含全连接层，因此限制了模型在像素级别预测任务上的能力。为了得到端到端的训练模型，本文将 VGG16 第 5 个池化层及以后的层都去掉，然后在 conv5_3 后加入两个卷积层，直接预测显著图。此时得到的显著图尺寸是原输入图片大小的 1/16。因此在最后加入上采样层，使其恢复成原图大小。具体的网络结构如图 1(a)所示。

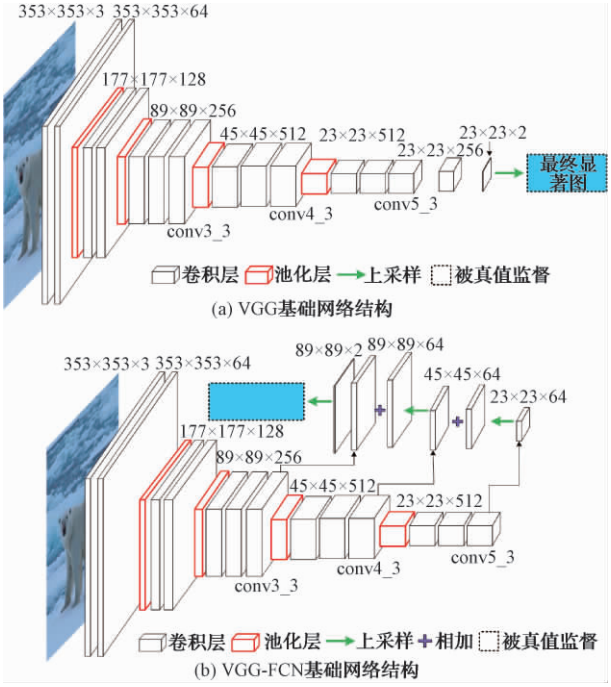

图 1 VGG 及 VGG-FCN 基础网络结构

为了抽象出图像中的语义信息，深度网络需要不断的使用卷积和池化操作对特征进行下采样。而显著性目标检测任务需要为每个像素预测对应的显著值。在低尺度下得到的显著图会缺少很多细节信息，因此不能达到很好的效果。为此，本文参考 FCN[18]中多尺度特征结合的方式，设计了 VGG-FCN。具体的网络结构如图 1(b)所示。分别将 conv5_3、conv4_3、conv3_3 输出的特征外接一个卷积层，再将得到的特征逐级上采样然后相加，得到 1/4 原图大小的特征，再进行显著图的预测。此时得到的特征包含足够的细节信息，同时也能保留深度特征的语义信息。

1.2 ResNet 及 ResNet-FCN

ResNet 是由 He 等[17]在 2015 年提出，指出了之前的骨干网络在训练阶段存在的问题，即随着网络层数的增加训练误差没有减小，反而会增大。为此，ResNet 提出了残差学习模块，将它作为网络的基本单元。若将输入设为 x，将某一有参网络层设为 H，那么以 x 为输入的此层的输出将为 $H(x)$。一般的网络通过训练学习函数 $H(x)$ 的参数，随着层数的增加，参数的训练会变得困难。这是由于层数越多，梯度在反向传播的过程中越容易消失，因此网络很难被优化。残差学习的思想是通过跳跃连接

(C)1994-2021 China Academic Journal Electronic Publishing House. All rights reserved. http://www.cnki.net

(short connection)加入输入 x 的恒等映射，将输出变成式(1)。

$$H(x)=F(x)+x \tag{1}$$

从而学习的目标变成了输入与输出之间的差，也就是所说的残差：

$$F(x)=H(x)-x \tag{2}$$

变成这种结构的好处是，当输入特征 x 已经足够成熟时，它的一点变化都会使 loss 增大。因此，学习过程中会倾向于使得 $F(x)=0$，网络经过恒等映射的支路传递参数，这样就能有效的避免层数增加而导致的梯度消失问题。由于其性能的优越性，越来越多计算机视觉领域的研究者们都采用 ResNet 作为基础网络实现对应领域的任务。选取 ResNet50 作为基础网络，与 VGG 基础网络的设计类似，本文将 ResNet50 中 res5c 之后的池化层及全连接层去掉，此时得到的特征是原图大小的1/32，在它后面加入卷积层直接预测显著图，将其上采样 32 倍即可得到最终的显著图。

由于 ResNet 输出的特征是原图大小的 1/32，直接上采样得到的显著图效果并不理想。为此，采用与 VGG-FCN 类似的方式，将多级特征逐级上采样相加得到更高尺度的特征再进行显著性预测，得到的基础网络为 ResNet-FCN。

2 多路径递归增强

2.1 多路径递归增强机制

得益于在大规模图像分类数据集上的预训练，上述基础网络能够在显著性目标预测上取得一定的效果。但是针对具有复杂语义信息的场景，基础网络的效果却很难令人满意。主要原因是上述基础网络结构相对简单，在学习特征时，网络的底层没有办法获取有价值的语义信息，因此特征往往是杂乱无章的。另外，在一些情况下，即使是网络的深层也只能接收到有限的上下文信息。因此，网络对于语义的挖掘能力有限，学习到的特征也不够有效。为此，本文引入多路径递归增强机制[19]对上述基础网络进行增强，提升它们整体的学习能力。此外，实现多路径递归增强时，每个时间步的网络参数是共享的。也就是说，在原有网络的基础上，只需要多学习几个递归连接的参数。因此这种机制在获得性能显著提升的同时并不会造成计算上的负担。

多路径递归增强机制的本质是一种循环神经网络。不同于传统的循环神经网络只采用单一反馈的方式，多路径递归增强机制通过多个加权的递归连接将顶层学习的上下文特征传播到网络的浅层，从而增强网络整体的学习能力。其网络结构如图 2(a)所示，图中 C1～C5 表示基础网络中的 5 个卷积 block，为了方便说明，在此假定每个卷积 block 只有一个卷积层。可以看出，多路径递归连接机制将网络顶层的特征通过多条递归反馈路径传递到网络的浅层。将网络按照 $T=2$ 时间步展开，其结构图如图 2(b)所示。

假定一个网络包含 L 个层(即 L 个卷积 block，每个 block 只有一层)，每一个层都输出一个特征图，将其表示为 $\boldsymbol{X}^{(\ell)}$。其中，$\boldsymbol{X}^{(0)}$ 和 $\boldsymbol{X}^{(L)}$ 表示网络的输入和最终的输出。$\boldsymbol{W}^{(\ell)}$ 表示第 ℓ 层学习到的权重参数。使用上述表示，一个 L 层的网络每一层的输出可以被表达为：

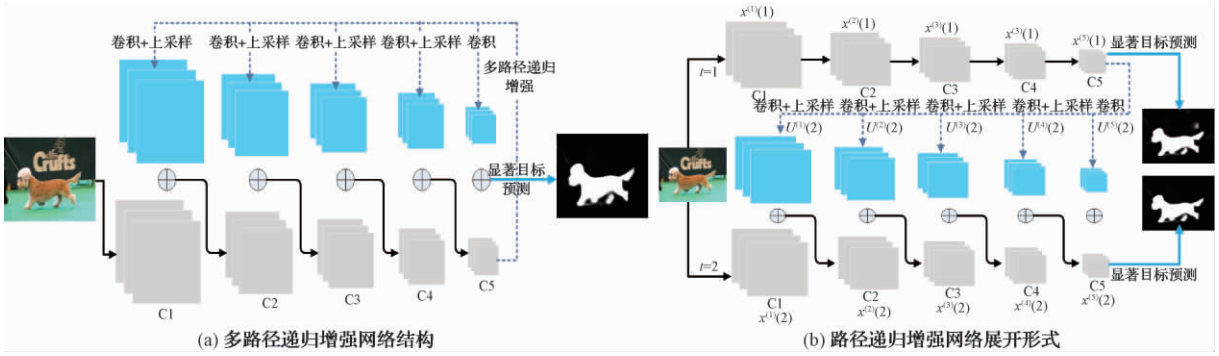

图 2 多路径递归增强网络结构及其展开形式

$$\boldsymbol{X}^{(\ell)}=f^{(\ell)}(\boldsymbol{W}^{(\ell)}\boldsymbol{X}^{(\ell-1)}) \quad \ell=1,\cdots,L \tag{3}$$

式中：$\boldsymbol{W}^{(\ell)}\boldsymbol{X}^{(\ell-1)}$ 在 $\boldsymbol{X}^{(\ell-1)}$ 上执行线性变换，而 $f^{(\ell)}(\cdot)$ 表示多种特定的函数组合，包含激活函数、池化、softmax 等。本文偏置项包含在 $\boldsymbol{W}^{\ell}$ 里。

多路径递归增强机制从 L 个层里选择 M 个进行递归连接。使用 $R=\{r_m, m=1,\cdots,M\}$ 表示被选中的层的集合，其中 r_m 表示层的索引。通过引入多路径递归连接，每一个 R 中的层的输入将变成它前一层的输出与上一时刻顶层的输出的组合。在这里，用 $t\in T$ 表示时间步的索引。引入多路径递归连接后，式(3)可以改写为：

$$\boldsymbol{X}^{(\ell)}(t)=\begin{cases} f^{(\ell)}(g^{(\ell)}(\boldsymbol{W}^{(\ell)}\boldsymbol{X}^{(\ell-1)}(t))+ \\ \quad g^{(\ell)}(\boldsymbol{U}^{(\ell)}(t)\boldsymbol{X}^{(L)}(t-1))), & \ell\in R \\ f^{(\ell)}(\boldsymbol{W}^{(\ell)}\boldsymbol{X}^{(\ell-1)}(t)), & \text{其他} \end{cases} \tag{4}$$

式中：$\boldsymbol{X}^{(\ell)}(t)$ 表示 t 时刻第 ℓ 层输出的特征；$\boldsymbol{U}^{(\ell)}(t)$ 表示从 $t-1$ 时刻顶层 L 的输出到 t 时刻隐层 $\ell\in R$ 的转换矩

(C)1994-2021 China Academic Journal Electronic Publishing House. All rights reserved. http://www.cnki.net

阵；$\boldsymbol{g}^{(\ell)}(\cdot)$ 是针对输入进行归一化操作的函数。进行归一化操作能够保证递归连接传递回去的特征和该隐层原始输入的特征在同一个取值范围内，避免因某一部分响应过大造成另外一部分失效。另外，从公式可以看出，权重 $\boldsymbol{W}^{(\ell)}$ 随着时间不发生变化，也就是说不同时间步网络的参数是共享的。而 $\boldsymbol{U}^{(\ell)}(t)$ 是随时间发生变化的，这样就可以自适应的学习到每个时间步顶层特定的语义信息。

2.2 模型训练与实现

针对不同的基础网络，分别采用2.1节的多路径递归增强机制对网络进行改进。其中VGG系列的基础网络对应引入递归连接的层的集合为 $R=\{\text{conv5_1}, \text{conv4_1}, \text{conv3_1}\}$。而ResNet系列的基础网络对应引入递归连接的层的集合为 $R=\{\text{res5a_branch2a}, \text{res4a_branch2a}, \text{res3a_branch2a}\}$。之所以选用上述层引入递归连接，是因为FCN[18]中的研究表明，VGG、ResNet等骨干网络的conv(res)3－conv(res)5 block包含充分的细节信息及语义信息，从而能够在准确预测目标的同时得到清晰的目标边缘。因此本文选用这些卷积block的第1层引入多路径递归连接。同时，本文也通过实验证明了，在更浅的层引入多路径递归连接不能起到太大的作用，有时甚至会有反效果。最后，本文通过实验确定了每个基础网络增强的最优参数(递归路径选择及迭代时间步数)。

本文采用随机梯度下降(SGD)的方式训练每一个网络。为了实现多路径递归连接，将每个时间步网络上除了递归连接路径上的参数共享。假设在 t 时刻获得的显著图为 S_t，通过前向计算过程，可以得到交叉熵损失函数为：

$$L_t(\Theta) = -\sum_{i,j}\sum_{l_g\in\{0,1\}} \mathbf{1}(S_t^{i,j} = l_g)\log \boldsymbol{Pr}(l_{i,j} = l_g \mid \Theta) \tag{5}$$

式中：i、j 代表空间位置；$l_g \in \{0,1\}$ 代表像素的真值标签值；$\mathbf{1}(\cdot)$ 代表指示函数，当满足条件时，该值为1，否则为0。Θ 代表整个网络的参数。网络 T 个时间步的联合损失函数为：

$$L(\Theta) = \sum_{t=1}^{T}\alpha_t L_t \tag{6}$$

通过优化式(6)可以得到优化后的显著性目标预测网络。测试阶段将图像送入该优化后的网络就可以得到显著目标预测的结果。

3 实验与结果分析

3.1 数据集与评价指标

本文采用了DUTS[20]、DUT-OMRON[2]、ECSSD[21]、HKU-IS[22]4个标准公开的数据集进行实验。为了综合的对算法性能进行评估，本文选取了3个在显著性目标检测领域有较高认可度的评价指标，分别为准确率-召回率曲线(P-R)、F-measure值、MAE 值。P-R曲线越靠近右上角表示结果越好，F-measure值越高表示模型性能越好。MAE 值表征平均绝对误差，该值越低表示效果越好。

3.2 实验细节说明

本文算法基于深度学习开发平台Caffe实现，在训练过程中分别采用预训练好的VGG16及ResNet50对模型进行初始化。训练集采用DUTS训练集，里面包含10 553张训练图像。在送入网络之前，将所有输入图像resize成353×353大小。训练学习率为 1×10^{-10}，动量是0.99，权重衰减为0.005。在经过150K个迭代步后，模型收敛。选取最后一个时间步的输出作为最终的显著图。本文基础网络分别表示为VGG、VGG-FCN、ResNet、ResNet-FCN。增强后的结果根据多路径递归连接路径及参数的选择进行表示(如递归连接路径为{conv5_1, conv4_1}，$T=2$，递归一次时，结果表示为r1-conv5-conv4，简写为r1-54)。

3.3 增强效果分析

在DUT-OMRON数据集上各种基础网络增强前后PR曲线的比较结果如图3所示。从图3可以看出，在引入多路径递归增强后，所有的基础网络性能上都实现了很大的提升。此外，通过增加递归路径及递归次数网络的性能会有进一步的提升。经过实验，在r2-543下取得最好的结果。

本文将针对F-measure和MAE值再进行更进一步的分析。表1和2分别为VGG-FCN及ResNet-FCN在4个数据集上增强前后F-measure及 MAE 值的比较结果。从表1、2可以看出，进行递归增强后算法的性能明显要优于Baseline的结果。在增加了递归连接路径后，基本在所有数据库上指标都有进一步提升。同时增大递归次数，在两个基础网络上都得到了最好的提升效果。在VGG及ResNet这两个基础网络上也有相同的规律。

综合P-R曲线、F-measure及MAE值的结果可以看出，多路径递归增强机制能够对简单的基础网络起到非常有效的增强作用。证明了本文算法的有效性。

3.4 与先进算法比较

为了评估模型的性能，本文选取了8个目前最先进的算法与本文算法进行比较，分别为LEGS[7]、DCL[9]、ELD[10]、RFCN[11]、Amulet[12]、UCF[13]、C2SNet[14]、MLMS[15]，根据开源代码或者显著图进行实验。本文选取的模型是ResNet-FCN增强后的结果。由图4中P-R曲线的比较可以看出，本文的方法达到了目前最先进的水平。说明了多路径递归增强机制的有效性。表3为 F-measure及 MAE 值的比较结果，可以看出，本文的方法在这两个评价指标上也都有非常好的表现。综合来看，本文提出的多路径递归增强机制能够有效的提升基础网络的性能，使其达到目前比较先进的水平。

(C)1994-2021 China Academic Journal Electronic Publishing House. All rights reserved. http://www.cnki.net

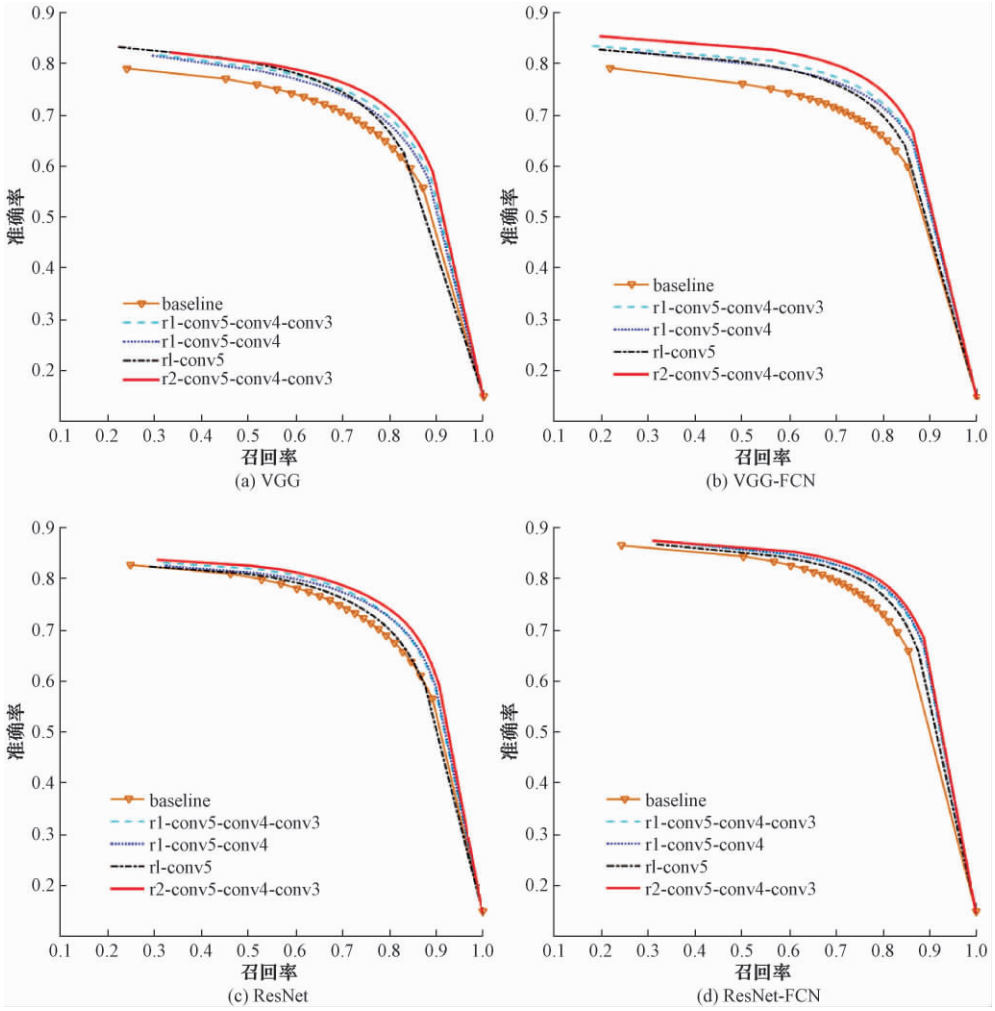

图 3　DUT-OMRON 上不同基础网络增强前后 P-R 曲线比较

表 1　VGG-FCN 增强前后 *F*-measure 与 *MAE* 比较

	DUTS		DUT-O		ECSSD		HKU	
	F-measure	*MAE*	*F*-measure	*MAE*	*F*-measure	*MAE*	*F*-measure	*MAE*
Base	0.711	0.068	0.650	0.086	0.857	0.066	0.847	0.052
r1-5	0.741	0.061	0.679	0.077	0.874	0.061	0.866	0.047
r1-54	0.748	0.059	0.688	0.074	0.879	0.056	0.872	0.045
r1-543	0.749	0.059	0.693	0.073	0.875	0.057	0.873	0.045
r2-543	0.763	0.055	0.709	0.069	0.886	0.053	0.881	0.043

表 2　ResNet-FCN 增强前后 *F*-measure 与 *MAE* 比较

	DUTS		DUT-O		ECSSD		HKU	
	F-measure	*MAE*	*F*-measure	*MAE*	*F*-measure	*MAE*	*F*-measure	*MAE*
Base	0.761	0.054	0.708	0.064	0.887	0.054	0.871	0.044
r1-5	0.767	0.051	0.717	0.061	0.889	0.050	0.874	0.041
r1-54	0.771	0.050	0.724	0.059	0.894	0.047	0.876	0.039
r1-543	0.778	0.048	0.727	0.059	0.896	0.047	0.881	0.038
r2-543	0.781	0.047	0.736	0.058	0.897	0.046	0.883	0.038

(C)1994-2021 China Academic Journal Electronic Publishing House. All rights reserved.　http://www.cnki.net

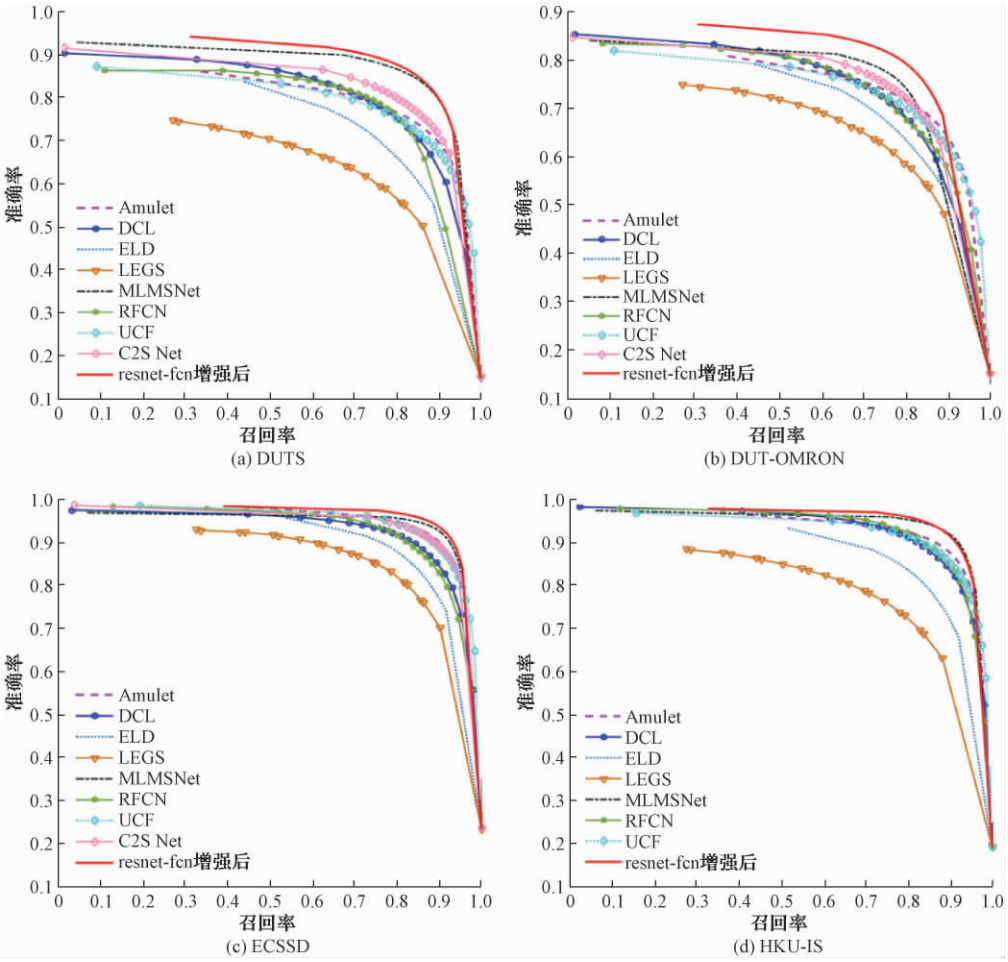

图 4　在 4 个标准数据集上与先进方法 P-R 曲线的比较

表 3　四个数据集上与先进方法 *F*-measure 及 *MAE* 值比较结果

	DUTS		DUT-O		ECSSD		HKU-IS	
	F-measure	*MAE*	*F*-measure	*MAE*	*F*-measure	*MAE*	*F*-measure	*MAE*
LEGS	0.585	0.138	0.592	0.133	0.785	0.119	0.723	0.119
DCL	0.714	0.149	0.684	0.157	0.827	0.151	0.853	0.136
ELD	0.628	0.093	0.611	0.092	0.810	0.082	0.769	0.074
RFCN	0.712	0.090	0.627	0.111	0.834	0.109	0.835	0.089
Amulet	0.678	0.085	0.647	0.098	0.869	0.061	0.839	0.052
UCF	0.629	0.117	0.613	0.132	0.841	0.080	0.808	0.074
C2SNet	0.720	0.072	0.683	0.063	0.863	0.058	—	—
MLMS	0.751	0.049	0.692	0.064	0.866	0.048	0.871	0.039
Ours	0.781	0.047	0.736	0.058	0.897	0.046	0.883	0.038

4　结　论

本文提出了一种基于多路径递归增强的显著性目标检测方法。该方法证明了，基于基础网络结构，不需要设计过多的复杂结构就能获得很好的性能提升。通过引入多路径递归连接路径，本文将网络深层学到的语义信息传递到网络的浅层，从而提升了浅层的特征学习能力。在公开数据集上的实验证明，多路径递归增强机制能够有效地提升基础网络的性能。从而获得了简单有效的显著性检测模型。

参 考 文 献

[1]　胡文才，邢坦，韩辰希. 基于颜色、轮廓特征融合的显著性检测[J]. 国外电子测量技术，2018，37(1)：

(C)1994-2021 China Academic Journal Electronic Publishing House. All rights reserved.　http://www.cnki.net

16-19.

[2] YANG C, ZHANG L, LU H, et al. Saliency detection via graph-based manifold ranking[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2013: 3166-3173.

[3] QIN Y, LU H, XU Y, et al. Saliency detection via cellular automata[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2015: 110-119.

[4] PERAZZI F, KRAHENBUHL P, PRITCH Y, et al. Saliency filters: Contrast based filtering for salient region detection[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2012: 733-740.

[5] 孙丹，王莉莉. 基于空一频域映射与虚警抑制的弱小目标检测算法[J]. 电子测量与仪器学报，2019，33 (1)：36-44.

[6] 范敏，陈曦，王楷，等. 基于对比度与最小凸包的显著性区域检测算法[J]. 仪器仪表学报，2014，35(10)：2328-2334.

[7] WANG L, LU H, RUAN X, et al. Deep networks for saliency detection via local estimation and global search[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2015: 3183-3192.

[8] 王玉，王志腾. 深度网络的显著性目标检测[J]. 电子测量技术，2019，42 (21)：106-109.

[9] LI G, YU Y. Deep contrast learning for salient object detection[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2016: 478-487.

[10] LEE G, TAI Y W, KIM J. Deep saliency with encoded low level distance map and high level features[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2016: 660-668.

[11] WANG L, WANG L, LU H, et al. Saliency detection with recurrent fully convolutional networks [C]. European Conference on Computer Vision, 2016: 825-841.

[12] ZHANG P, WANG D, LU H, et al. Amulet: Aggregating multi-level convolutional features for salient object detection [C]. IEEE International Conference on Computer Vision, 2017: 202-211.

[13] ZHANG P, WANG D, LU H, et al. Learning uncertain convolutional features for accurate saliency detection[C]. IEEE International Conference on Computer Vision, 2017: 212-221.

[14] LI X, YANG F, CHENG H, et al. Contour knowledge transfer for salient object detection [C]. European Conference on Computer Vision, 2018: 355-370.

[15] WU R M, FENG M Y, GUAN W L, et al. A mutual learning method for salient object detection with intertwined multi-supervision[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2019: 8150-8159.

[16] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[C]. International Conference on Learning Representations, 2015: 1-14.

[17] HE K, ZHANG X, REN S Q, et al. Deep residual learning for image recognition[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.

[18] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2015: 3431-3440.

[19] JIN X, CHEN Y, JIE Z, et al. Multi-path feedback recurrent neural networks for scene parsing[C]. In AAAI, 2017.

[20] Wang L, Lu H, Wang Y, et al. Learning to detect salient objects with image-level supervision[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2017: 136-145.

[21] YAN Q, XU L, SHI J, et al. Hierarchical saliency detection[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2013:1155-1162.

[22] LI G, YU Y. Visual saliency based on multiscale deep features[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2015: 5455-5463.

作 者 简 介

张晓宁，硕士，主要从事图像处理、显著性目标检测、深度学习等研究工作。
E-mail:13130427818@163.com

(C)1994-2021 China Academic Journal Electronic Publishing House. All rights reserved. http://www.cnki.net