arXiv:2601.00562v1 [cs.CV] 2 Jan 2026

一种用于精确图像分割的级联信息交互网络

Hewen Xiao[1], Jie Mei[2*], GuangfuMa[2], WeirenWu[1]

[1]空间科学与应用技术研究院，哈尔滨工业大学，深圳，518055，广东，中国。[2]哈尔滨工业大学机械工程与自动化学院，深圳，518055，广东，中国。

*通讯作者。电子邮箱：jmei@hit.edu.cn；贡献作者：hoan.xiao@gmail.com；magf@hit.edu.cn；wwrhitsz@163.com；

摘要

视觉感知在实现自主行为方面发挥着关键作用，相较于复杂的多传感器系统，它提供了一种经济高效的替代方案。然而，在复杂场景中实现稳健分割仍是一项挑战。为此，本文提出了一种集成新型全局信息引导模块的级联卷积神经网络。该模块旨在有效融合多个层级的低层纹理细节与高层语义特征，从而克服单尺度特征提取固有的局限性。这一架构创新显著提升了分割准确率，尤其是在视觉杂乱或模糊的环境中，而传统方法在这些环境下往往效果不佳。在基准图像分割数据集上的实验评估表明，所提出的框架具有更高的精度，优于现有最先进方法。结果彰显了该方法的有效性及其在实际机器人应用中的良好部署前景。

关键词：图像分割，级联信息交互网络

1 引言

在计算机视觉技术中，图像分割发挥着至关重要的作用，是一项不可或缺的辅助技术。其主要功能是将视觉场景分解为有意义的区域，从而为检测、跟踪和识别等下游任务提供便利。提升分割质量可直接增强机器人感知系统的鲁棒性和准确率，并广泛应用于避障 [1],导航 [2], 和目标跟踪 [3]。

传统图像分割方法严重依赖手工设计特征或内在先验 [4], ，这往往限制了它们在复杂或杂乱场景中的适应能力。深度学习的最新进展，尤其是卷积神经网络（CNNs），通过从数据中学习多层级特征，显著提升了分割性能 [5–7]。然而，由于多层级特征之间信息交互存在局限，许多基于卷积神经网络的模型 [8–10] 仍难以兼顾细粒度细节保留与全局上下文理解。要解决这一问题，需要更有效的多层级和多尺度表征机制，以同时提升空间分辨率和语义抽象能力。

为应对图像分割中视觉感知所面临的挑战，本文提出了一种配备全局信息引导模块的级联神经网络。该模块能够有效融合不同层级的低层纹理细节和高层语义特征，克服单尺度特征提取的局限。这种设计提升了分割准确率，尤其是在视觉上杂乱或模糊的环境中。我们在标准图像分割数据集上进行了广泛评估，以验证所提方法。结果表明，我们的方法在分割准确率方面优于现有方法，展现出其在复杂环境中的实时机器人应用潜力。

2 相关工作

图像分割旨在找出图像中人们最感兴趣的区域。传统的图像分割方法通常利用手工设计的线索或内在先验来预测显著性分数 [11, 12]。然而，这些方法效率低下且泛化能力较差，因此受到限制。随着深度学习的兴起，近期方法大多采用卷积神经网络（CNN）进行逐像素预测。

与传统方法相比，基于 CNN 的方法在常用的图像分割基准上表现更优。其中，早期工作 [8–10]大多采用迭代或分阶段的方式逐步优化预测结果。后来的一些方法 [5, 6, 13] 侧重于基于 U 形架构设计新的多尺度特征提取模块和策略。另一些方法 [7, 14, 15] 则引入了各种注意力机制，以增强网络的特征表征能力。

近年来，生成模型迅速发展，并对视觉学习任务产生了重大影响，涵盖从图像合成 [16] 到强化学习 [17]等领域。这一趋势也推动了图像分割的发展，研究人员开始将生成范式融入其中，例如基于变分自编码器

的方法 [18],生成对抗网络驱动的框架 [19]，以及基于扩散模型的技术 [20]。这些方法利用生成先验来优化特征表示，并促使分割结果更加稳定、连贯。

与上述现有图像分割方法相比，我们采用一种全新的多尺度信息级联交互模式，并结合全局信息引导模型，以减少细节信息的丢失并提高准确率。

3 方法

为了精确分割目标并便于视觉伺服模块计算其位置，我们采用 Swin Transformer [21] 作为编码器，这得益于其独特优势：Swin Transformer 引入了局部注意力机制，继承了卷积神经网络处理大图像的优势，并采用基于窗口的方法，发挥 Transformer 在长距离依赖建模方面的能力。为了基于不同的骨干网络提取特定尺度的特征，我们引入一个额外的卷积层，其卷积核大小为 1，以统一通道维度。因此，得到的统一通道特征可表示为$\mathcal{E} = \{E_i, 1 \leq i \leq I\}$，其中 I 通常设为 5。

如图 1所示，在应用卷积池化进行下采样，再通过上采样恢复原始分辨率后，图像往往会出现模糊和精细细节丢失。传统方法会沿自底向上和自顶向下路径级联相同分辨率的特征图，从而在一定程度上减轻局部特征的损失。然而，直接提取特征可能会限制多尺度信息融合，因为层级特征交互往往未得到充分利用。为克服这一限制，我们提出了一种级联信息交互网络，使多尺度信息能够在滤波器层级进行交换。该技术建立了一种结构化机制，用于逐步细化特征，确保不同分辨率层级之间有效通信。此外，我们认识到，深层架构通常能够更好地建模复杂模式，因此往往能取得更优性能。基于这一思路，我们扩展了模型中的交互层，以增强层级特征表示。给定来自编码器的通道统一特征图 $\mathcal{E}$，通过级联交互器获得传递给解码器的特征 $\mathcal{D} = \{D_i, 1 \leq j \leq J\}$ 如下

$$D_j = \mathbb{F}^q\left(E_k, \ldots, E_m\right), \quad 1 \leq j \leq 5, \quad 1 \leq k \leq m \leq 5 \tag{1}$$

其中， $\mathbb{F}$ 表示每个交互层级中的特征融合， q 表示函数操作的数量，即级联层级数。

在分割任务中，高效的多尺度模块能够显著提升模块性能。高层信息可用于引导和增强不同尺度间低层信息的交互。为保留局部信息和相对全局信息的压缩表示，我们引入了全局信息引导模块（GIGM）。高层信息可用于引导低层信息，从而增强不同尺度信息之间的交互。模块输入包含低层信息 F_i，该信息经过

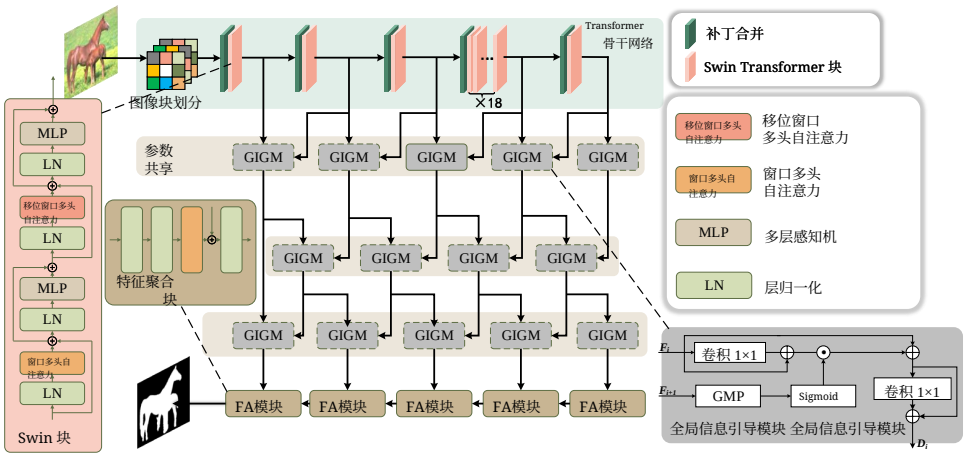


图1 所提出网络框架的概览

一 1×1 卷积层处理。此外，高层信息 F_{i+1}经过全局最大池化（GMP）和Sigmoid函数处理，如图 1中的灰色方框所示。高层信息被压缩后用于校准低层信息，从而保留局部特征。最后，输出 D_i 经过一个 1×1 卷积层处理后得到。 D_i 作为从相对高层路径到低层路径的信息引导。该模块可表示如下：

$$G_{i+1} = Sigmoid\left(GMP\left(F_{i+1}\right)\right), 1 \leq i \leq M-1 \tag{2}$$

$$D_i = (Conv^1 + 1)(G_{i+1} \odot (Conv^1 + 1)(F_i) + F_i),\ 1 \leq i \leq M. \tag{3}$$

4 实验结果

4.1 实验设置

本研究所采用的评估数据集包括五个广泛使用的数据集：ECSSD [22], PASCAL-S [23],DUT-OMRON [24],HKU-IS [25], 和 DUTS-TE[26]。在模型训练中，我们遵循图像分割研究中的既有实践，在所有实验中统一使用 DUTS-TR 数据集 [26] 。

我们的模型训练了 60 轮，每批次包含 30 个样本；我们选择的优化器学习率为 0.005、动量为 0.9、权重衰减为 5e-5。训练和测试时，图像输入尺寸均调整为 384×384 。为了评估各种方法的有效性，我们采用了三种常用指标：F度量分数（F_β）、平均绝对误差（MAE）和 S度量分数（S_α）。（F_β）的计算方式如下：

$$F_\beta = \frac{(1+\beta^2) \times \text{Precision} \times \text{Recall}}{\beta^2 \times \text{Precision} + \text{Recall}}. \tag{4}$$

为了赋予准确率更高的权重，我们将 β^2 设为 0.3。在像素级， MAE评估预测图像 P 与标注图像 L之间的平均绝对差异。

$$\mathrm{MAE} = \frac{1}{W \times H} \sum_{x=1}^{W} \sum_{y=1}^{H} |P(x,y) - L(x,y)|, \tag{5}$$

其中，图像的宽度和高度分别表示为 W 和 H。S度量（S_α）综合了目标感知（S_o）和区域感知（S_r）结构相似性分量，其计算如下：

$$S_\alpha = \gamma S_o + (1-\gamma) S_r, \tag{6}$$

其中，按照通常做法， γ 取 0.5。

本文采用的损失函数将交并比（IoU）损失与二元交叉熵损失（BCE）相结合：$l = l_{iou} + l_{bce}$。由于具有出色的鲁棒性，二元交叉熵（BCE）损失函数被广泛用于二元分类，并通过计算图像的逐像素损失获得：

$$l_{bce}(p,l) = -\frac{1}{n} \sum_{k=1}^{n} \left[l_k \log\left(p_k\right) + \left(1 - l_k\right) \log\left(1 - p_k\right) \right] \tag{7}$$

p 和 l 分别表示预测图像和标签。 k 是像素的索引， n 是 x 中的像素数量。与强调像素级差异的BCE损失函数不同，IoU损失考虑整体图相似性，其定义如下：

$$l_{\text{iou}}\left(p,l\right) = 1 - \frac{\sum_{k=1}^{n} \left(l_k * p_k\right)}{\sum_{k=1}^{n} \left(l_k + p_k - l_k * p_k\right)}. \tag{8}$$

4.2 与最先进方法的比较

我们将所提出的图像分割方法与 22 种最先进的方法进行了比较，包括 PAGR [15], DGRL [8], PiCANet [14], MLMS [27],PAGE [7],ICTB [9],CPD [10], BASNet [28], PoolNet [5], CSNet [29],GateNet [6], MINet [30],ITSD [31],VST [32],MSFNet [33], CII [34], PoolNet+ [35]、DCN [36], DNA [37],RCSB [38], PriorNet [39] 和 NASAL [40]。为确保比较公平，我们采用作者分享的显著图，或使用他们发布的模型进行计算。随后，我们通过计算本方法及其他方法的 F度量分数 F_β、S度量分数 S_α 和平均绝对误差（MAE），对所得结果进行定量比较。表 1 展示了上述其他先进方法的测量结果。在ECSSD数据集上，我们的方法取得了最高的 F_β （0.952）和最低的 MAE（0.028），同时保持较高的 S_α 值 0.933。这些结果表明，该方法在捕捉精细细节和复杂目标结构方面的能力有所增强，

尤其是在杂乱场景中。同样，在 PASCAL-S 上，我们的模型仍保持领先性能，MAE 最低，同时 F_β 和 S_α 值具有竞争力，表明其在应对遮挡和具有挑战性的背景时鲁棒性更强。在 HKU-IS 上的表现进一步凸显了模型的泛化能力，其 F_β为 0.898，MAE 为 0.031，且 S_α 为 0.929，在所有指标上均优于对比方法。在 DUT-OMRON 和 DUTS-TE 等更具挑战性的数据集上，该方法依然保持优势；与知名的 PoolNet相比，我们的模型提升了 1.1% 和 0.+8%，进一步证实了其在复杂场景中描绘目标边界的有效性。我们的模型凭借其独特架构，在显著目标检测方面取得领先表现；该架构将多尺度特征交互与全局信息引导相结合。这种设计在保持全局上下文准确性的同时，增强了细节保留能力。

在图2中，我们展示了由我们的方法生成的显著图示例。这些显著图展示了我们的方法能够生成边界清晰、突出区域均匀的准确结果。

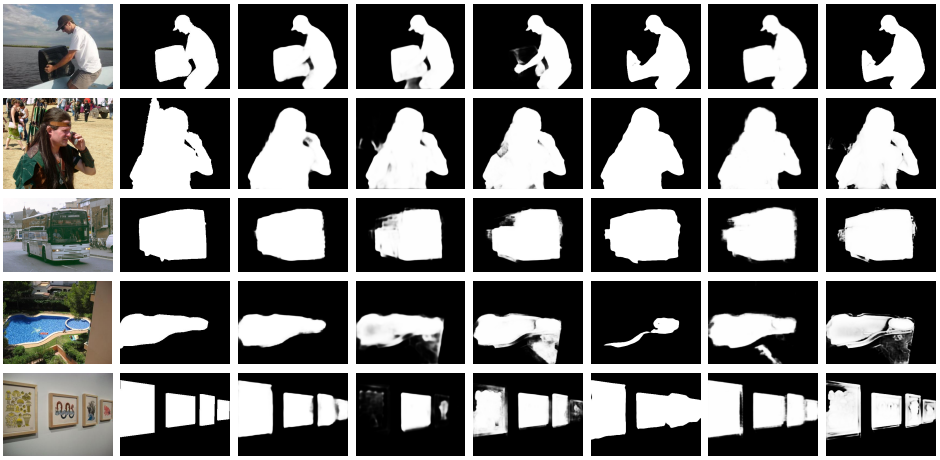


图2 显著图与最先进方法的视觉对比。从左至右：输入图像、真实标注、我们的方法、DNA、CII、MSFNet、VST 和 ITSD。我们的方法始终能够生成最佳结果。

5 结论

在这项工作中，我们提出了一种级联交互网络，旨在增强信息交互能力并提高图像分割模型的鲁棒性。我们方法的核心是集成了全局信息引导模块，该模块促进低层纹理细节与高层语义特征的有效融合。这一机制成功克服了单尺度特征提取的局限，确保模型即使在视觉上杂乱或模糊的环境中也能达到较高的分割准确率。在标准数据集上进行的大量实验和对比验证了我们提出的框架不仅优于现有

Table 1 Comparisons of our method with other state-of-the-art methods on five popular SOD benchmarks.

Method	ECSSD			PASCAL-S			DUT-OMRON			HKU-IS			DUTS-TE		
	$F_\beta \uparrow$	MAE $\downarrow$	$S_\alpha \uparrow$	$F_\beta \uparrow$	MAE $\downarrow$	$S_\alpha \uparrow$	$F_\beta \uparrow$	MAE $\downarrow$	$S_\alpha \uparrow$	$F_\beta \uparrow$	MAE $\downarrow$	$S_\alpha \uparrow$	$F_\beta \uparrow$	MAE $\downarrow$	$S_\alpha \uparrow$
PAGR [15]	0.927	0.061	0.889	0.847	0.089	0.822	0.771	0.071	0.775	0.919	0.047	0.889	0.854	0.055	0.839
DGRL [8]	0.922	0.041	0.903	0.844	0.072	0.836	0.774	0.062	0.806	0.910	0.036	0.895	0.828	0.049	0.842
PiCANet [14]	0.935	0.047	0.917	0.864	0.075	0.854	0.820	0.064	0.830	0.920	0.044	0.904	0.863	0.050	0.868
MLMS [27]	0.930	0.045	0.911	0.853	0.074	0.844	0.793	0.063	0.809	0.922	0.039	0.907	0.854	0.048	0.862
PAGE [7]	0.931	0.042	0.912	0.848	0.076	0.842	0.791	0.062	0.825	0.920	0.036	0.904	0.838	0.051	0.855
ICTB [9]	0.938	0.041	0.918	0.855	0.071	0.850	0.811	0.060	0.837	0.925	0.037	0.909	0.855	0.043	0.865
CPD [10]	0.939	0.037	0.918	0.859	0.071	0.848	0.796	0.056	0.825	0.925	0.034	0.907	0.865	0.043	0.869
BASNet [28]	0.942	0.037	0.916	0.857	0.076	0.838	0.811	0.057	0.836	0.930	0.033	0.908	0.860	0.047	0.866
PoolNet [5]	0.944	0.039	0.921	0.865	0.075	0.850	0.830	0.055	0.836	0.934	0.032	0.917	0.886	0.040	0.883
CSNet [29]	0.944	0.038	0.921	0.866	0.073	0.851	0.821	0.055	0.831	0.930	0.033	0.911	0.881	0.040	0.879
GateNet [6]	0.946	0.040	0.920	0.877	0.068	0.858	0.831	0.055	0.838	0.935	0.033	0.915	0.889	0.040	0.885
MINet [30]	0.947	0.034	0.925	0.874	0.064	0.856	0.826	0.056	0.833	0.936	0.028	0.920	0.888	0.037	0.884
ITSD [31]	0.947	0.035	0.925	0.871	0.066	0.859	0.823	0.061	0.840	0.933	0.031	0.916	0.883	0.041	0.885
VST [32]	0.951	0.034	0.932	0.875	0.062	0.872	0.829	0.058	0.850	0.942	0.030	**0.929**	0.891	0.037	0.896
MSFNet [33]	0.943	0.033	0.915	0.865	0.061	0.852	0.824	0.050	0.832	0.930	0.027	0.909	0.881	0.034	0.877
CII [34]	0.950	0.034	0.926	0.882	0.062	0.865	0.831	0.054	0.839	0.939	0.029	0.920	0.890	0.036	0.888
PoolNet+ [35]	0.949	0.040	0.925	0.879	0.068	0.864	0.831	0.056	0.842	0.941	0.034	0.921	0.894	0.039	0.890
DCN [36]	0.952	0.031	0.928	0.872	0.062	0.861	0.823	0.051	0.845	0.940	0.027	0.922	0.894	0.035	0.891
DNA [41]	0.940	0.043	0.915	0.855	0.079	0.837	0.803	0.063	0.818	0.927	0.036	0.905	0.873	0.046	0.860
RCSB [38]	0.945	0.033	0.922	0.879	0.059	0.860	**0.849**	**0.049**	0.835	0.939	0.027	0.918	0.897	0.035	0.881
PriorNet [39]	**0.953**	0.031	0.931	0.881	0.059	0.869	0.839	0.051	0.849	0.940	0.029	0.920	**0.901**	0.033	0.897
NASAL [40]	0.925	0.052	0.904	0.836	0.092	0.825	0.800	0.069	0.818	0.913	0.044	0.898	0.833	0.060	0.841
Ours	0.952	**0.028**	**0.933**	**0.888**	**0.054**	**0.879**	0.842	**0.049**	**0.858**	**0.943**	**0.025**	**0.929**	0.898	**0.031**	**0.900**

在精度方面优于现有方法，同时也保持了实际部署所需的效率。这些结果表明，我们的模型有望成为自主机器人系统中视觉感知的有效解决方案。

参考文献

[1] Zhang, Y., Wen, L., Hong, L., Zhang, L., Guo, Q., Li, S., Bing, Z., Knoll, A.：面向动态多障碍物环境中移动机器人的显著性检测安全关键控制。载于：2025 IEEE机器人与自动化国际会议（ICRA），第7756–7762页（2025年）。IEEE[2] Liu, Z., Liu, Y., Fang, Y., Guo, X.：采用头部稳定控制的蝾螈式机器人的自主视觉导航。IEEE/ASME机电一体化汇刊，1–12（2025年）[3] Roberts, R., Ta, D.-N., Straub, J., Ok, K., Dellaert, F.：显著性检测与基于模型的跟踪：用于森林环境中小型机器人导航的双部分视觉系统。载于：无人系统技术 XIV，第8387卷，第306–317页（2012年）。SPIE[4] Zhang, D., Han, J., Zhang, Y., Xu, D.：合成监督信号，以在无需人工标注的情况下学习深度显著性网络。IEEE模式分析与机器智能汇刊 **42(7)**，1755–1769（2019年）[5] Liu, J.-J., Hou, Q., Cheng, M.-M., Feng, J., Jiang, J.：一种用于实时显著目标检测的简单基于池化的设计。载于：IEEE计算机视觉与模式识别会议（2019年）[6] Zhao, X., Pang, Y., Zhang, L., Lu, H., Zhang, L.：抑制与平衡：一种用于显著目标检测的简单门控网络。载于：欧洲计算机视觉会议（2020年）[7] Wang, W., Zhao, S., Shen, J., Hoi, S.C., Borji, A.：利用金字塔注意力和显著边缘进行显著目标检测。载于：IEEE计算机视觉与模式识别会议（2019年）[8] Wang, T., Zhang,L., Wang, S., Lu, H., Yang, G., Ruan, X., Borji, A.：全局检测，局部细化：一种新颖的显著性检测方法。载于：IEEE计算机视觉与模式识别会议，第3127–3135页（2018年）[9] Wang, W., Shen, J., Cheng, M.-M., Shao, L.：一种用于显著目标检测的迭代式协同自顶向下与自底向上推理网络。载于：IEEE计算机视觉与模式识别会议（2019年）[10]Wu, Z., Su, L., Huang, Q.：用于快速、准确显著目标检测的级联部分解码器。载于：IEEE计算机视觉与模式识别会议（2019年）

[11] Lee, G., Tai, Y.-W., Kim, J.：结合编码低层距离图和高层特征的深度显著性。载于：IEEE计算机视觉与模式识别会议（2016年）[12]Xu, J., Liu, Z.-A., Hou, Y.-K., Zhen, X.-T., Shao, L., Cheng, M.-M.：通过客观评价实现逐像素非局部图像平滑。IEEE多媒体汇刊 **23**，4065–4078（2021年）[13] Chang, Y., Liu, Z., Wu, Y., Fang, Y.：基于深度学习的原子力显微镜自动形态分析。IEEE自动化科学与工程汇刊 **21(4)**，7662–7673（2024年）[14] Liu, N., Han, J., Yang, M.-H.：PiCANet：学习用于显著性检测的逐像素上下文注意力。载于：IEEE计算机视觉与模式识别会议，第3089–3098页（2018年）[15] Zhang, X., Wang, T., Qi, J., Lu, H., Wang, G.：用于显著目标检测的渐进式注意力引导循环网络。载于：IEEE计算机视觉与模式识别会议，第714–722页（2018年）[16] Rombach, R., Blattmann, A., Lorenz, D., Esser, P., Ommer, B.：利用潜在扩散模型进行高分辨率图像合成。载于：IEEE/CVF计算机视觉与模式识别会议论文集，第10684–10695页（2022年）[17] Liu, Z., Liu, Y., Fang, Y.：面向蝾螈式机器人的基于扩散模型的路径跟随器。IEEE神经网络与学习系统汇刊 **36(8)**，14399–14413（2025年）[18] Zhang, J., Fan, D.-P., Dai, Y., Anwar, S., Saleh, F., Aliakbarian, S., Barnes, N.：不确定性启发的RGB-D显著性检测。IEEE模式分析与机器智能汇刊 **44(9)**，5761–5779（2021年）[19] Wang, C., Dong, S., Zhao, X., Papanastasiou, G., Zhang, H., Yang, G.：Saliency-GAN：物联网雾环境中的深度学习半监督显著目标检测。IEEE工业信息学汇刊 **16(4)**，2667–2676（2019年）[20] Sun, K., Chen, Z., Lin, X., Sun, X., Liu, H., Ji, R.：用于伪装目标和显著目标检测的条件扩散模型。IEEE模式分析与机器智能汇刊，2833–2848（2025年）[21] Liu, Z., Lin, Y., Cao, Y., Hu, H., Wei, Y., Zhang, Z., Lin, S., Guo, B.：Swin Transformer：使用移位窗口的分层视觉Transformer。载于：IEEE国际计算机视觉会议，第10012–10022页（2021年）[22]Yan, Q., Xu, L., Shi, J., Jia, J.：层次化显著性检测。载于：IEEE计算机视觉与模式识别会议，第1155–1162页（2013年）

[23] Li, Y., Hou, X., Koch, C., Rehg, J.M., Yuille, A.L.：显著目标分割的奥秘。载于：IEEE计算机视觉与模式识别会议，第280–287页（2014年）[24] Yang, C., Zhang, L., Lu, H., Ruan, X., Yang, M.-H.：基于图的流形排序的显著性检测。载于：IEEE计算机视觉与模式识别会议，第3166–3173页（2013年）[25]Li, G., Yu, Y.：基于多尺度深度特征的视觉显著性。载于：IEEE计算机视觉与模式识别会议，第5455–5463页（2015年）[26] Wang, L., Lu, H., Wang, Y., Feng, M., Wang, D., Yin, B., Ruan, X.：学习在图像级监督下检测显著目标。载于：IEEE计算机视觉与模式识别会议，第136–145页（2017年）[27] Wu, R., Feng, M., Guan, W., Wang, D., Lu, H., Ding, E.：一种采用交织式多重监督的显著目标检测互学习方法。载于：IEEE计算机视觉与模式识别会议（2019年）[28]Qin, X., Zhang, Z., Huang, C., Gao, C., Dehghan, M., Jagersand, M.：Bas-net：边界感知显著目标检测。载于：IEEE计算机视觉与模式识别会议（2019年）[29] Gao, S.-H., Tan, Y.-Q., Cheng, M.-M., Lu, C., Chen, Y., Yan, S.：采用10万个参数的高效显著目标检测。载于：欧洲计算机视觉会议（2020年）[30]Pang, Y., Zhao, X., Zhang, L., Lu, H.：用于显著目标检测的多尺度交互网络。载于：IEEE计算机视觉与模式识别会议，第9413–9422页（2020年）[31] Zhou, H., Xie, X., Lai, J.-H., Chen, Z., Yang, L.：用于准确快速显著性检测的交互式双流解码器。载于：IEEE计算机视觉与模式识别会议，第9141–9150页（2020年）[32] Liu, N., Zhang, N., Wan, K., Shao, L., Han, J.：视觉显著性变换器。载于：IEEE国际计算机视觉会议，第4722–4732页（2021年）[33] Zhang, M., Liu, T., Piao, Y., Yao, S., Lu, H.：Auto-msfnet：用于显著目标检测的多尺度融合网络搜索。载于：ACM多媒体会议（2021年）[34] Liu, J.-J., Liu, Z.-A., Peng, P., Cheng, M.-M.：重新思考显著目标检测中的U形结构。IEEE图像处理汇刊 **第30卷**，9030–9042（2021年）[35] Liu, J.-J., Hou, Q., Liu, Z.-A., Cheng, M.-M.：Poolnet+：探索池化在显著目标检测中的潜力

池化在显著目标检测中的应用。IEEE模式分析与机器智能汇刊 **45(1)**，887–904（2022年）[36] Wu, Z., Su, L., Huang, Q.：用于显著目标检测的分解与补全网络。IEEE图像处理汇刊 **第30卷**，6226–6239（2021年）[37] Yao, Z., Wang, L.：用于显著目标检测的边界信息渐进引导网络。IEEE多媒体汇刊 **24**，4236–4249（2022年）[38] Ke, Y.Y., Tsubono, T.：用于准确显著目标检测的递归轮廓显著性融合网络。载于：IEEE/CVF冬季计算机视觉应用会议，第2940–2950页（2022年）[39] Zhu, G.,Li, J., Guo,Y.：PriorNet：用于显著目标检测的两种深度先验线索。IEEE多媒体汇刊 **26**，5523–5535（2024年）[40]Liu, Z.-A., Liu, J.-J.：通过U形架构搜索实现高效显著目标检测。Knowledge-Based Systems **318**，113515（2025年）[41] Liu, Y., Cheng, M.-M., Zhang, X.-Y., Nie, G.-Y., Wang, M.：DNA：用于显著目标检测的深度监督非线性聚合。IEEE控制论汇刊 **52(7)**，6131–6142（2022年）