

基于多尺度先验深度特征的多目标显著性检测方法

李东民¹ 李静¹ 梁大川¹ 王超¹

摘要 显著性检测是近年来国内外计算机视觉领域研究的热点问题,在图像压缩、目标识别与跟踪、场景分类等领域具有广泛的应用.针对大多显著性检测方法只针对单个目标且鲁棒性不强这一问题,本文提出一种基于深度特征的显著性检测方法.首先,在多个尺度上对输入图像进行超像素分割,利用目标先验知识对预显著区域进行提取和优化.然后,采用卷积神经网络提取预选目标区域的深度特征.对高维深度特征进行主成分分析并计算显著性值.最后,提出一种改进的加权多层元胞自动机方法,对多尺度分割显著图进行融合优化,得到最终显著图.在公开标准数据集 SED2 和 HKU-IS 的实验表明,与现有经典显著性检测方法相比,本文方法对多显著目标检测更准确.

关键词 显著性检测,卷积神经网络,过分割,深度特征,元胞自动机

引用格式 李东民,李静,梁大川,王超.基于多尺度先验深度特征的多目标显著性检测方法.自动化学报,2019,45(11):2058-2070

DOI 10.16383/j.aas.c170154

Multiple Salient Objects Detection Using Multi-scale Prior and Deep Features

LI Dong-Min¹ LI Jing¹ LIANG Da-Chuan¹ WANG Chao¹

Abstract Saliency detection has been a hot topic in the field of computer vision in recent years, and has been widely applied in image compression, scene recognition and understanding, target tracking and other applications. Most saliency detection methods are only for a single target and their robustness is not good enough. For this problem, a saliency detection method based on deep feature is proposed. Firstly, the image is over-segmentated with multiple-scales, and the prior knowledge is used to extract and optimize pre-salient regions. Then, the deep features of pre-salient regions are extracted with deep convolution neural networks. The principal component analysis is used to reduce the dimension of deep feature, and the saliency value is calculated. Finally, a weighted multi-layer cellular automata is proposed, and the final saliency map is obtained by fusing the multi-scale segmentation saliency maps with the automata. Experiments on standard datasets SED2 and HKU-IS show that the proposed method is more effective compared with other saliency detection methods.

Key words Saliency detection, convolutional neural networks, over-segmentation, deep feature, cellular automata

Citation Li Dong-Min, Li Jing, Liang Da-Chuan, Wang Chao. Multiple salient objects detection using multi-scale prior and deep features. *Acta Automatica Sinica*, 2019, 45(11): 2058-2070

随着互联网技术的快速发展,数字图像、视频等多媒体数据呈现爆发式增长,基于数字图像及视频的图像处理技术也在迅猛发展.显著性检测通过模拟人类视觉系统选择图像中具有重要信息的区域^[1],可将其作为其他图像处理步骤的一种预处理工作,并已成功应用于目标识别、目标跟踪和图像分割^[2-4]等多种计算机视觉任务之中.

近年来国内外计算机视觉领域在图像显著性检测的研究方面提出许多行之有效的方法. Borji 等^[5]将这些方法分为两类,一类方法基于模拟生物视觉系统构建注意力预测模型 (Visual saliency prediction)^[6-9]. Itti 等^[6]提出的 IT 算法,根据人眼视觉特性,针对多尺度图像通过底层特征的中心-周围对比度得到相应的显著图,并通过显著图融合获取最终显著图.由于人类视觉系统生物结构复杂导致此算法计算复杂度极高.近年来基于频域的显著性检测模型成为此类方法中关注热点, Hou 等^[7]提出一种普残差方法,认为图像包含显著信息和冗余信息,通过在图像幅度谱上做对数运算并利用平均滤波器进行卷积运算得到冗余信息,以幅度谱与卷积结果的差值表示显著信息再反变换到空间域上获得显著区域.在谱残差方法基础上 Guo 等^[8]提出相位谱四元傅里叶变换法,通过相位谱提取图像多特征分量得到显著区域,利用四元傅里叶变换将亮

收稿日期 2017-03-28 录用日期 2017-08-02
Manuscript received March 28, 2017; accepted August 2, 2017
国家电网科技项目——自服务电网大数据治理关键技术与应用研究 (SGLNXT00YJJS1800110) 资助
Supported by the State Grid Corporation Science and Technology Project — Key Technology and Application Research of the Self-Service Grid Big Data Governance (SGLNXT00YJJS1800110)
本文责任编辑 贾云得
Recommended by Associate Editor JIA Yun-De
1. 南京航空航天大学计算机科学与技术学院 南京 211106
1. College of Computer Science and Technology, Nanjing University of Aeronautics and Astronautics, Nanjing 211106

度、颜色和运动信息一起并行处理来计算时空显著性. Li 等^[9] 提出超傅里叶变换方法, 通过对谱滤波进行扩展, 利用超复数表示图像多为特征并使用傅里叶变化得到时空显著性.

另一类方法基于计算机视觉任务驱动构建显著目标检测模型 (Salient object detection). 这类方法通常包括两个步骤. 首先检测图像中突出显著区域, 在此基础上分割出完整目标. 虽然这类方法本质上本质是解决前景与背景分割问题, 但与图像分割相比显著性目标检测根据内容将图像分割为一致区域. 一些经典算法使用底层特征对图像内容进行表示^[10-14], 比如 Cheng 等^[10] 使用图割方法对图像进行分割, 通过稀疏直方图简化图像颜色, 利用空间位置距离加权的颜色对比度之和来衡量图像区域的显著性. Shen 等^[11] 提取图像的颜色特征、方向特征以及纹理特征得到特征矩阵, 利用主成分分析 (Principal component analysis, PCA) 对矩阵进行降维表示再计算对比度得到显著图. Yang 等^[12] 通过将图像划分为多尺度图层, 针对每个图层计算其颜色特征与空间特征的对比度, 融合多个图层生成的显著图获取最终显著图. 该方法能够保证显著性目标的一致性与完整性, 但当显著性目标较小时, 会将显著性目标当作背景融入到背景区域. Cheng 等^[13] 采用高斯混合模型将颜色特征相似的像素聚为图像区域, 综合考虑各区域的颜色对比度和空间分布, 以概率模型生成显著图. Li 等^[14] 以稀疏表示分类 (Sparse representation-based classification, SRC) 原理为基础, 对分割图超像素块进行稠密和稀疏重构, 通过多尺度重构残差建立显著图.

使用不同底层特征的显著性检测方法往往只针对某一类特定图像效果显著, 无法适用于复杂场景下多目标图像, 如图 1 所示. 基于视觉刺激的底层特征缺乏对显著目标本质的理解, 不能更深层次地表示显著性目标的特征. 对于图像中存在的噪声物体, 如与底层特征相似但不属于同一类目标, 往往会被错误的检测为显著目标. 杨赛等^[15] 提出一种基于词袋模型的显著性检测方法, 首先利用目标性计算先验概率显著图, 建立一种表示中层语意特征的词袋模型计算条件概率显著图, 最后通过贝叶斯推断对两幅显著图进行合成. 中层语意特征能够比底层特征更准确的表示图像内容, 因此检测效果更加准确. Jiang 等^[16] 将显著性检测作为一个回归问题, 集成多分割尺度下区域对比度, 区域属性以及区域背景知识特征向量, 通过有监督学习得到主显著图. 由于背景知识特征的引入使算法对背景对象有更好的识别能力, 进而得到更准确的前景检测结果.

近几年来, 基于深度学习的自动学习获取深度特征 (或高层特征) 的方法已经开始在图像显著性检

测中得到应用. 李岳云等^[17] 通过提取超像素块区域和边缘特征, 送入卷积神经网络学习得到显著置信图. 采用条件随机场求能量最小化的区域进行显著性检测. 对单显著目标检测效果较好, 但由于特征选择问题不适用于多目标图像. Li 等^[18] 通过深度卷积神经网络来学习得到获取图像超像素区域的局部和全局深度特征来进行显著性检测 MDF (Multiscale deep features), 检测效果相比于一方法有显著提升, 但运行速度较慢. Hu 等^[19] 通过结合卷积神经网络和区域验证的先验知识获取局部和全局特征. 算法检测效果较好, 但高度复杂的模型影响了算法运行效率. 本文着重研究图像背景信息相对复杂的多目标情况, 提出一种基于先验知识与深度特征的显著性检测方法. 首先对图像进行多尺度分割, 对第一个分割图通过卷积神经网络提取所有超像素块的深度特征并计算显著值, 并生成预显著区域. 将其余分割图的预显著区域超像素块输入卷积神经网络, 通过提取的深度特征计算显著值并更新预显著区域. 不断迭代此过程得到各尺度下的显著图, 最终通过加权元胞自动机方法对多尺度显著图进行融合. 目标先验可过滤大部分背景信息, 减少不必要的深度特征提取, 显著提升算法检测速率.



图 1 复杂背景下的多目标图像

Fig. 1 Multi object image in complex background

本文结构安排如下: 第 1 节详细阐述基于多尺度目标先验与深度特征的多目标显著性检测方法; 第 2 节通过与已有算法在公开数据集上进行定性定量比较, 评价本文所提方法; 第 3 节总结本文所做工作并提出下一步研究方向.

1 显著性检测方法

本节提出了一种基于深度特征显著性检测算法, 总体框架如图 2 所示. 对于输入图像 I , 首先采用超像素分割算法将图像分割为数目较少的超像素块. 对所有超像素块提取深度特征, 通过主成分分析提取包含图像关键信息的多维特征. 基于关键特征计算得到粗分割显著图, 从中提取初始显著区域组成超像素集 *Supselect*. 利用 *Supselect* 集中超像素与背景区域超像素相似性, 对其进行优化. 对输入图像不同尺度超像素分割, 选择包含 *Supselect* 集中超像

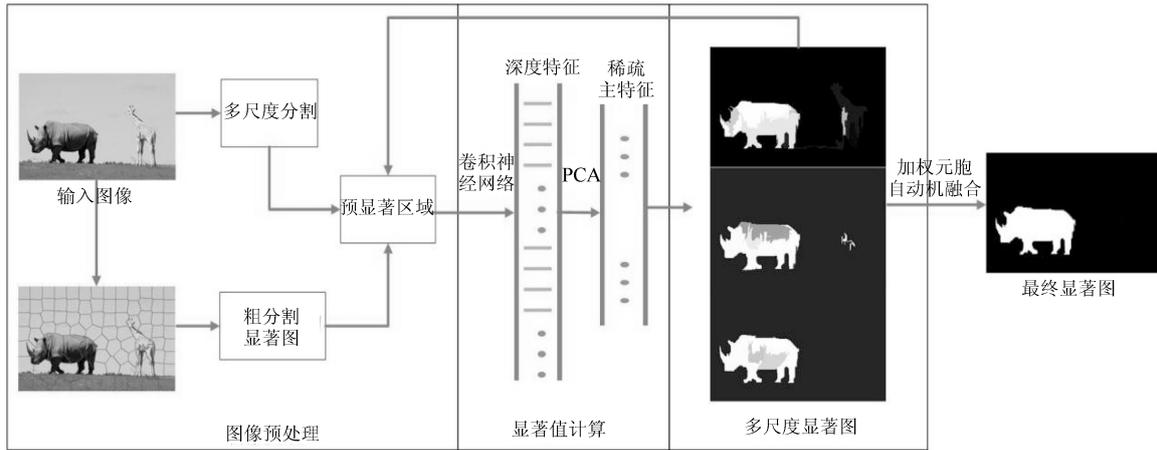


图 2 本文算法总体架构图

Fig. 2 The overall framework of our method

素块的区域进行深度特征提取, 基于相同方法得到这一尺度下显著图 Map^s 和 $Supselect$ 集. 最终采用加权元胞自动机融合得到最终显著图 M_{final} .

1.1 基于多尺度分割的显著区域提取

超像素分割是根据颜色、纹理和亮度等底层特征, 将相邻相似的像素点聚成大小不同图像区域^[20], 降低了显著性计算的复杂度. 常用的超像素生成算法有分水岭^[21] 和简单线性迭代聚类 (Simple linear iterative clustering, SLIC)^[22] 两种分割算法. 本文结合二者各自特点, 在粗分割时采用 SLIC 方法, 获取形状规则, 大小均匀的分割结果. 在细分割时采用分水岭算法获得良好的对象轮廓.

对于 N 个分割尺度 s_1, \dots, s_n , 在某一分割尺度下得到的超像素集用 $Sup_j = \{Sp_i^j\}_{i=1}^{N_j}$. N_j 表示分割尺度 s_j 下的超像素个数, $20 \leq N_j \leq 250$. Sp_i^j 为 s_j 分割尺度下第 i 个超像素. $Sp_i^j(v) = \{R, G, B, L, a, b\}$ 为该超像素中像素点两种颜色特征的特征向量.

1.1.1 预选区域提取

将粗分割尺度 s_j 的分割图作为输入, 通过深度特征提取和显著值计算 (在第 1.2 节和第 1.3 节中详细介绍) 得到的显著图 Map_j . Map_j 作为下一个分割尺度检测时的目标先验知识, 用以指导预选目标区域提取. 对显著图 Map_j 进行二值化处理, 采用自适应的阈值策略, 将 Map_j 的值分为 K 个通道. 用 $p(i)$ 表示属于通道 i 的像素数量, 并确定所有通道中像素数量最多的通道 k , 通过式 (1) 计算阈值 T .

$$T = \frac{k+1}{K} \quad (1)$$

为防止 T 取值过大, 确保在显著目标占据图像

大部分空间时, 较为显著的像素不被二值化为 0. 每个通道像素数目必须满足 $p(i)/area(I) < \varepsilon$, 其中 $area(I)$ 为图像 I 的像素个数. ε 是落在 $[0.65, 0.95]$ 范围内的经验值. 所得二值化目标先验图为 $MapB_j$.

使用 $MapB_j$ 作为目标先验知识, 选取下一个尺度 s_{j+1} 下 $Sup_{j+1} = \{Sp_i^{j+1}\}_{i=1}^{N_{j+1}}$ 相应位置的超像素区域构成预选显著性超像素集 $Supselect_{j+1} = \{Sp_i^{j+1}\}_{i=1}^{M_{j+1}}$. M_{j+1} 是在分割尺度 s_{j+1} 上提取的预选显著目标超像素个数, $M_{j+1} < N_{j+1}$. 假设 Num_i 为超像素 Sp_i^{j+1} 中像素总数, num 是二值图 $MapB_j$ 对应位置上值为 1 的像素个数, 若满足条件 $num/Num_j > 0.5$ 则认为相应位置处的超像素属于 $Supselect_{j+1}$.

1.1.2 区域优化

预选目标超像素集 $Supselect_{j+1}$ 可能包含一些背景区域或缺失部分显著区域. 需对预选目标区域进行优化, 将 $Supselect_{j+1}$ 中可能的背景区域去除掉, 并将背景区域中可能的显著性区域加入进来.

根据两种颜色空间特征的欧氏距离来构造超像素之间的相异矩阵 $Difmat$, 表示超像素之间的相异性. $Difmat$ 是一个 N_{j+1} 阶对称矩阵.

$$Difmat(i, j) = Difmat(Sp_i, Sp_j) = \sqrt{\sum_{k=1}^6 (F_{i,k} - F_{j,k})^2} \quad (2)$$

其中, $F_{i,k}$ 为超区域 Sp_i 的第 k 个特征, k 从 1 到 6 分别对应 R, G, B, L, a 和 b 特征. 对于 $Sp_k \in Supselect_{j+1}$, 通过式 (3) 计算局部的平均相异度

$$MavDif(Sp_k) = \frac{\sqrt{\sum_{l=1, l \neq k}^{M_{j+1}} Difmat(Sp_k, Sp_l)^2}}{M_{j+1}} \quad (3)$$

其中, $Sp_k, Sp_l \in Supselect_{j+1}$, M_{j+1} 是预选显著区域集 $Supselect_{j+1}$ 中超像素个数. 计算 $Supselect_{j+1}$ 中每个超像素 Sp_k 与其相邻的背景区域的平均相异度

$$MavDif(Sp_k)' = \frac{\sqrt{\sum_{l=1, l \neq k}^{M'_{j+1}} Difmat(Sp_k, Sp_l)^2}}{M'_{j+1}} \quad (4)$$

其中, $Sp_k \in Supselect_{j+1}$, $Sp_l \notin Supselect_{j+1}$, 且 Sp_k 与 Sp_l 相邻, M'_{j+1} 表示背景区域中与 Sp_k 相邻的超像素个数. 如果 $MavDif(Sp_k)' > DavDif(Sp_k)$, 表明 Sp_k 与相邻的背景区域的相似度更高, 则将 Sp_k 从 $Supselect_{j+1}$ 删除.

同样, 对于任意 $Sp_h \notin Supselect_{j+1}$, 可计算 Sp_h 与相邻背景区域中的平均相异度 $MavDif(Sp_h)'$, 及 Sp_h 与相邻预选显著区域的平均相异度 $MavDif(Sp_h)$. 如果满足条件 $MavDif(Sp_h)' > MavDif(Sp_h)$, 则说明与其他背景区域相比, Sp_h 与相邻显著区域的相似度更高, 则将 Sp_h 加入到 $Supselect_{j+1}$ 中.

通过比较 $Supselect_{j+1}$ 中超像素与其他显著区域及背景区域的相异度, 从而不断更新 $Supselect_{j+1}$, 直到 $Supselect_{j+1}$ 中超像素不再变化.

1.2 预显著区域深度特征提取

本节基于卷积神经网络的深度特征提取方法如图 3 所示. 在首次超像素分割时提取所有超像素的深度特征, 在之后的深度特征提取过程中, 只对 $Supselect$ 集中超像素进行提取. 在一定的分割策略下, 大大降低计算量, 提高计算速度.

假设不是首次分割, 对于每一个超像素 Sp_i ($Sp_i \in Supselect$) 分别提取局部区域深度特征和全局区域深度特征.

超像素的局部特征包括两部分: 1) 包含自身区域的深度特征 F_{self} ; 2) 包含自身及相邻超像素区域的深度特征 F_{local} .

首先, 根据预选目标超像素集 $Supselect$, 提取每个超像素 Sp_i ($Sp_i \in Supselect$) 所在的最小矩形区域 $Rect_{self}$ (如图 3 区域内的荷花). 由于多数超像素不是规则的矩形, 提取到的矩形一定包含其他像素点, 这些像素点用所在超像素的平均值表示. 通过深度卷积网络就可以得到只包含自身区域的深度特征 F_{self} .

仅有特征 F_{self} 经过显著性计算得到的显著值是没有任何意义的, 在不与其他相邻超像素显著性的对比情况下, 无法确定它是否是显著的. 因此还需提取包含 Sp_i 自身及其相邻超像素的最小矩形区域 $Rect_{local}$, 从而获得局部区域的深度特征 F_{local} .

区域在图像中的位置是一个判断其是否显著的重要因素. 通常认为位于图像中心的区域比位于边缘的区域成为显著区域的可能性更高. 因此, 以整幅图像作为矩形输入区域 $Rect_{global}$, 提取全局区域的深度特征 F_{global} .

深度卷积神经网络模型是由一个数据输入层、

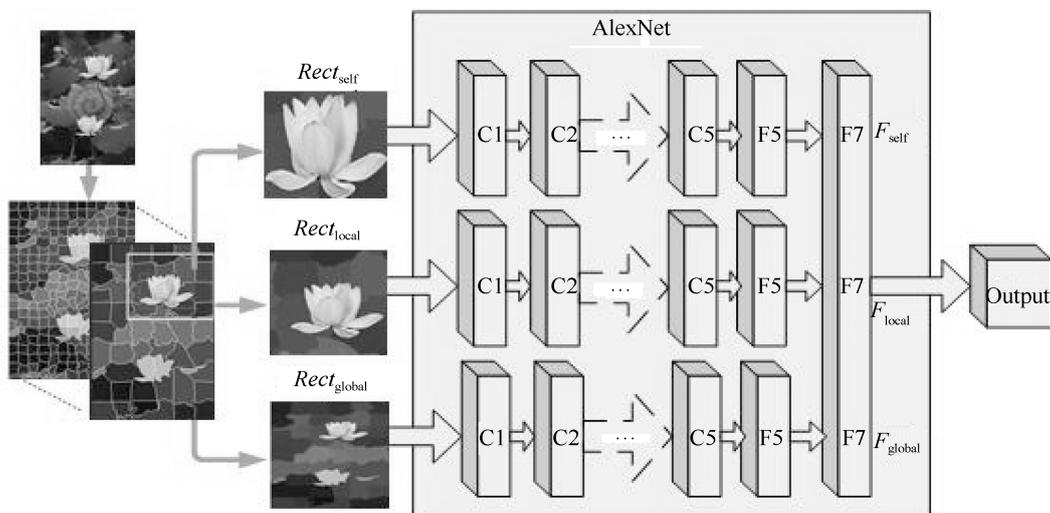


图 3 基于卷积神经网络的深度特征提取架构图

Fig. 3 Deep features extraction based on convolutional neural network

多个卷积层和下采样层、全连接层和输出层共同构成的深度神经网络^[23]. 卷积层和下采样层构成神经网络中间结构, 前者负责特征提取, 后者则负责特征计算. 在一个或者多个下采样层之后会连接一个或多个全连层, 每个全连层都可将特征进行输出. 卷积层输出结果为

$$d_n^l = f \left(\sum_{\forall m} (d_m^{l-1} * k_{m,n}^l) + b_n^l \right) \quad (5)$$

其中, d_n^l 和 d_m^{l-1} 是当前层和上一层特征图, $k_{m,n}^l$ 是模型的卷积核, $f(x) = 1/[1 + \exp(-x)]$ 为神经元激活函数, b_n^l 为神经元偏置. 下采样层特征提取结果为

$$d_n^l = f \left(k_n^l \times \frac{1}{s^2} \sum_{s \times s} d_n^{l-1} + b_n^l \right) \quad (6)$$

其中, $s \times s$ 是下采样模板尺度, k_n^l 为模板权值. 本文利用训练好的 AlexNet 深度卷积神经网络模型来提取预选目标区域的深度特征, 并在此模型基础上去除标签输出层以获取深度特征. 将预处理后图像输入模型, 卷积层 C1 利用 96 个大小为 $11 \times 11 \times 3$ 的图像滤波器来对大小为 $224 \times 224 \times 3$ 的输入图像进行滤波.

卷积层 C2, C3, C4, C5 分别将上一层下采样层的输出作为自己的输入, 利用自身滤波器进行卷积处理, 得到多个输出特征图并传给下一层. 全连接层 F6 和 F7 每层都有 4096 个特征输出, 每个全连接层的输出结果可为

$$d_n^{\text{out}} = f \left(\sum (d_m^{\text{out}-1} \times k_{m,n}^{\text{out}}) + b_n^{\text{out}} \right) \quad (7)$$

1.3 基于深度特征的显著值计算

主成分分析 (Principle component analysis, PCA)^[24] 是最常见的高维数据降维方法, 可以把 p 个高维特征用数目更少的 m 个特征取代. 对于 n 个超像素, 卷积神经网络输出特征可以构成一个 $n \times p$ 维的样本矩阵 W , $p = 12288$. 通过式 (8) 计算样本的相关系数矩阵 $R = (r_{ij})_{p \times p}$

$$r_{ij} = \frac{\sum_{k=1}^n (x_{ki} - \bar{x}_i)(x_{kj} - \bar{x}_j)}{\sqrt{\sum_{k=1}^n (x_{ki} - \bar{x}_i)^2 \sum_{k=1}^n (x_{kj} - \bar{x}_j)^2}}, \quad i, j = 1, 2, \dots, p \quad (8)$$

其中, $\bar{x}_i = \frac{1}{n} \sum_{i=1}^n x_{ij}$, $j = 1, 2, \dots, p$. 通过解方程 $|\lambda I - R| = 0$, 求出特征值并按从大到小的顺序排列. 计算每个特征值 λ_i 的贡献率和累积贡献率

$$\frac{\lambda_i}{\sum_{k=1}^p \lambda_k}, \quad \frac{\sum_{k=1}^i \lambda_k}{\sum_{k=1}^p \lambda_k} \quad (9)$$

计算每个特征值 λ_i 对应的正交单位向量 $\mathbf{z}_i = [z_{i1}, z_{i2}, \dots, z_{ip}]^T$, 选取累计贡献率达到 95% 的前 m 个特征对应的单位向量, 构成转换矩阵 $Z = [\mathbf{z}_1, \mathbf{z}_2, \dots, \mathbf{z}_m]_{p \times m}$. 通过式 (10) 对高维矩阵 M 进行降维, $Sp_i(df) = (f_{i,1}, f_{i,2}, \dots, f_{i,m})$ 表示降维后的 m 维主成分特征. 图像不同尺度的分割图使用同一转换矩阵提取主成分特征.

$$Sp_i(df) = W_{n \times p} Z_{p \times m} \quad (10)$$

1.3.1 对比特征

对比度特征反映了某一区域与相邻区域的差异程度. 超像素 Sp_i 的对比特征值 $w^c(Sp_i)$, 是用它与其他超像素所有特征的距离来定义的, 如式 (11) 所示

$$w^c(Sp_i) = \frac{1}{n-1} \sum_{i=1, i \neq k}^n \|Sp(df)_i - Sp(df)_k\|_2 \quad (11)$$

其中, n 表示超像素的个数, $\|\cdot\|_2$ 是 2-范数.

1.3.2 空间特征

在人类视觉系统中对不同空间位置的关注度不同, 越靠近中心越能引起注意. 图像中不同位置的像素到图像中心的距离满足高斯分布, 对任一超像素 Sp_i , 其空间特征值 $w^s(Sp_i)$ 用式 (12) 计算

$$w^s(Sp_i) = \exp \left(\frac{-d(Sp_{i,x}, c)}{\sigma^2} \right) \quad (12)$$

其中, $Sp_{i,x}$ 为超像素 Sp_i 的中心坐标, c 为图像中心区域. 与图像中心的平均距离越小的超像素块空间特征值越大. 超像素 Sp_i 的显著值用式 (13) 表示

$$Map(Sp_i) = w^c(Sp_i) \times w^s(Sp_i) \quad (13)$$

计算得到第一个分割图的显著图 Map^1 , 作为后序分割尺度的目标先验知识来指导预选目标区域的提取和优化.

1.3.3 目标先验显著性计算

通过目标先验知识提取预选目标区域 *Supselect* 后, 超像素集中显著性区域占绝大部分, 即显著性区域不在是稀疏的. 因此, 再按照式 (11) 计算对比特征值是不准确的.

提取预显著区域的平均超像素特征用 $Sp'(d) = (f'_1, f'_2, \dots, f'_m)$ 来表示, 超像素 Sp_i ($Sp_i \in$

Supselect) 的对比特征值 $w^c(Sp_i)$ 使用式 (14) 计算

$$w^c(Sp_i)' = \|Sp_i - Sp'\|_2 \quad (14)$$

在已知目标的大致空间分布的情况下, 特别是分散的多目标情况, 根据图像中心来计算空间特征不够准确. 可以根据已知的显著目标空间分布来以目标先验图中的显著性区域的中心来代替图像中心进行计算, 如式 (15) 所示.

$$w^s(Sp_i)' = \exp\left(\frac{-d(Sp_{i,x}, c')}{\sigma^2}\right) \quad (15)$$

其中, $Sp_{i,x}$ 为超像素 Sp_i 的中心坐标, c' 为目标先验图中的显著性区域的中心. 如果存在多个独立的显著性区域, 那么 c' 表示与超像素 Sp_i 最近的显著性区域的中心. 由式 (13) 计算最终显著值得到目标先验下的显著性图 Map^i , i 代表不同的尺度.

1.4 基于加权元胞自动机的显著图融合

Qin 等^[25] 提出了多层元胞自动机 (Multi-layer cellular automata, MCA) 融合方法. 显著图中每一个像素点表示一个元胞, 在 M 层元胞自动机中, 显著图中的元胞有 $M-1$ 个邻居, 分别位于其他显著图上相同的位置.

如果元胞 i 被标记为前景, 则它在其他显著图上相同位置的邻居 j 被标记为前景的概率 $\lambda = P(\eta_i = +1 | i \in F)$. 同样, 可以用 $\mu = P(\eta_i = +1 | i \in B)$ 来表示元胞 i 标记背景时, 其邻居 j 成为背景的概率.

对于不同方法得到的显著图, 可以认为是相互独立的. 在同步更新时认为所有显著图的权重是一样的. 不同分割尺度下的显著图之间有指导和细化关系, 在融合的过程中权重不能认为是相等的. 在不同的分割尺度中, 假设首次分割尺度得到的显著图的权重为 λ_1 , 用 $w_i = \lambda_1$ 来表示. 不分割尺度下的显著图权重用式 (16) 表示为

$$w_i = \lambda_{i-1} + \left(1 - \frac{o_i}{O_i}\right), \quad i = 2, \dots, 6 \quad (16)$$

其中, O_i 表示预选目标集中所有超像素包含的像素总数, o_i 表示第 i 幅显著性区所包含的像素数量. 将 λ_1 的初始值设置为 1, 同步更新机制 $f: Map^{M-1} \rightarrow Map$, 定义为

$$l(Map_m^{t+1}) = w_m \sum_{k=1, k \neq m}^M \text{sign}(Map_k^t - \gamma_k \cdot I) \times \ln\left(\frac{\lambda}{1-\lambda}\right) + l(Map_m^t) \quad (17)$$

其中, $Map_m^t = [Map_{m,1}^t, \dots, Map_{m,H}^t]^T$ 表示 t 时刻, 第 m 幅显著图上的所有元胞的显著性值, 矩阵 I 是有 H 个元素的矩阵 $[1, \dots, 1]^T$. 如果一个元胞的邻居被判定为前景, 则相应的增加自身的显著性值, 即应有 $\ln(\lambda/1-\lambda)$, 则有 $\lambda > 0.5$. 并根据经验设置 $\ln(\lambda/1-\lambda) = 0.15$, 在 T_2 个时间步后, 可以通过下式得到最终的显著图 Map_{final}

$$Map_{\text{final}} = \frac{1}{N} \sum_{m=1}^M Map_m^{T_2} \quad (18)$$

将多尺度分割显著图经过加权 MCA 融合后得到最终的显著图, 从而完成单幅图像的显著性检测. 根据前面内容对本文的基于深度特征的多目标显著性检测算法的整个流程进行了总结, 如算法 1 所示.

算法 1. 基于深度特征的多目标显著性检测算法

输入. 原始输入图像 I 和多尺度分割个数 N 和每个尺度下的分割参数.

输出. 显著图 **for** $i = 1 : N$

```

{
  if  $i = 1$  then
    1) 根据确定好的参数, 用 SLIC 对图像  $l$  进行超像素分割;
    2) 确定每个超像素的输入区域  $Rect_{\text{self}}, Rect_{\text{local}}, Rect'$ ;
    3) 将输入区域送入 Alexnet 网络, 提取深度特征  $[F_{\text{self}}, F_{\text{local}}, F_{\text{global}}]$ ;
    4) 将所有超像素的深度特征构成矩阵  $W$ , 利用 PCA 算法计算  $W$  的转换矩阵  $A$ , 获取主成分特征;
    5) 根据主成分特征计算无目标先验的显著值, 得到首次分割显著图  $Map_1$ ;
  else
    6) 根据确定好的参数, 用分水岭算法对图像  $l$  进行超像素分割;
    7) 将显图  $Map^{i-1}$  当作目标先验图, 提取并优化预选目标区域集 Supselect;
    8) 确定 Supselect 中每个超像素的输入区域  $Rect_{\text{self}}, Rect_{\text{local}}, Rect_{\text{global}}$ ;
    9) 将输入区域送入 Alexnet 网络, 提取深度特征  $[F_{\text{self}}, F_{\text{local}}, F_{\text{global}}]$ ;
    10) 将所有超像素的深度特征构成矩阵  $W$ , 用转换矩阵  $A$  得到主成分特征;
    11) 根据主成分特征计算有目标先验的显著值, 得到显著图  $Map_i$ ;
  end if
}
12) 计算每个尺度下的显著图的权重  $w_i$ ;
13) 用加权 MCA 对得到的  $N$  幅显著图进行融

```

合, 得到最终的显著图 Map_{final} .

2 实验结果与分析

2.1 数据集介绍

数据集 SED2^[26] 是目前比较常用的多目标数据集, 它包含了 100 幅图像和相应的人工标注图, 每幅图像中都包含了两个显著目标. HKU-IS^[18] 包含近 4500 幅由作者整理挑选的图像, 每幅图像中至少包含 2 个显著目标, 并且目标与背景的颜色信息相对复杂, 同时提供人工标注的真实图. 本文是针对多目标的检测算法, 因此只选择 HKU-IS 中具有两类或两个以上目标的 2500 幅图像进行实验. 另外为分析本文算法各部分性能, 从 HKU-IS 中随机选择 500 幅图像建立测试数据集, 在进行参数选择和评价 PCA 以及自适应元胞自动机性能时均使用此测试集.

2.2 评价标准与参数设置

在本节的实验中, 通过对比显著图的准确率 (Precision)–查全率 (Recall) 曲线 (PR 曲线)、准确率–查全率–F-measure 柱状图 (F-measure 柱状图) 与平均绝对误差 (Mean absolute error, MAE) 柱状图三个标准来评价显著性检测的效果, 从而选出相对较好的分割尺度.

查准率与查全率是图像显著性检测领域最常用的两个评价标准, PR 曲线越高表示显著性检测的效果越好, 相反 PR 曲线越低, 相应的检测效果就越差. 对于给定人工标注的二值图 G 和显著性检测的显著图 S , 查准率 Precision 与查全率 Recall 的定义如式 (19) 所示

$$P = \frac{\text{sum}A(S, G)}{\text{sum}B(S)}, \quad R = \frac{\text{sum}A(S, G)}{\text{sum}B(G)} \quad (19)$$

其中, $\text{sum}A(S, G)$ 表示显著性检测的视觉特征图 S 和人工标注的真实二值图 G 对应像素点的值相乘后的和, $\text{sum}B(S)$ 、 $\text{sum}B(G)$ 分别表示的是视觉特征图 S 和人工标注的真实二值图 G 上所有像素点的值之和.

不同于准确率–召回率曲线, 在绘制准确率–召回率–F-measure 值柱状图时, 利用每幅图像的自适应阈值 T 对图像进行分割

$$T = \frac{2}{W \times H} \sum_{x=1}^W \sum_{y=1}^H S(x, y) \quad (20)$$

其中, 参数 W 与 H 分别指代图像的宽度与高度. 对每个数据集中的显著图, 计算它们的平均准确率与召回率. 根据式 (21) 计算平均的 F-measure 值, F-measure 的值超高超好. F-measure 值用于综合

评价准确率与查全率, 在显著性检测中查准率要比查全率更加重要, 所以 β^2 的值常设置成 0.3^[19].

$$\text{F-measure} = \frac{(\beta^2 + 1)PR}{\beta^2 P + R} \quad (21)$$

平均绝对误差通过对比显著图与人工标注图的差异来评价显著性模型^[20]. 根据式 (22) 可以计算每个输入图像的 MAE 值, 并利用计算出的 MAE 值绘制柱状图, MAE 值越低表明算法越好^[21].

$$\text{MAE} = \frac{1}{W \times H} \sum_{x=1}^W \sum_{y=1}^H |S(x, y) - G(x, y)| \quad (22)$$

2.2.1 确定分割尺度

本文算法参数主要为分割尺度. 分割尺度太多会增加计算复杂度, 太少则会影响显著性检测效果的准确性. 因此, 根据经验设置 15 个分割尺度并将其限定在^[20, 25] 范围内.

在随机选取的数据上进行实验, 根据经验设置 15 个分割尺度, 提取分割图中所有超像素的深度特征计算显著图. 不同分割尺度显著性检测结果的 Precision-Recall 曲线图如图 4 所示. 从中选择 6 个效果较好的分割尺度. 通过对比分析发现分割尺度 1, 3, 4, 6, 8, 13 这 6 个分割尺度下的显著性检测效果相对较好. 选择这 6 个分割尺度作为本文算法的最终分割尺度.

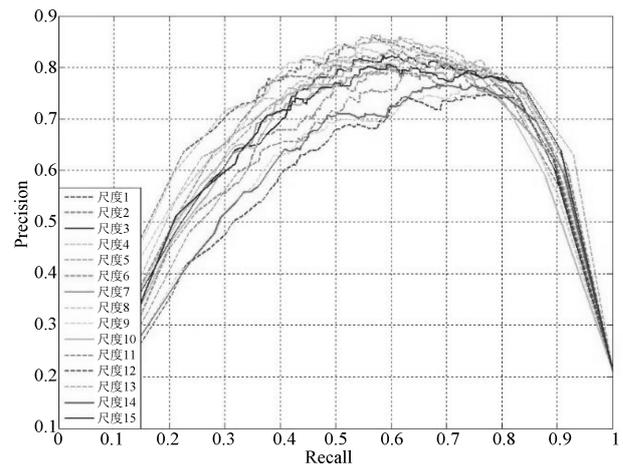


图 4 不同分割尺度下显著性检测的 PR 曲线图

Fig. 4 Precision-Recall curves of saliency detection in different segmentation scales

2.2.2 预显著区域提取策略选择

在结合目标先验知识后, 不同的分割策略组合得到的结果并不一致, 且运行速度也存在较大差异. 按照分割所得超像素个数进行组合, 可分为由少到多、由多到少、多少多交叉和少多少交叉共 4 种组合

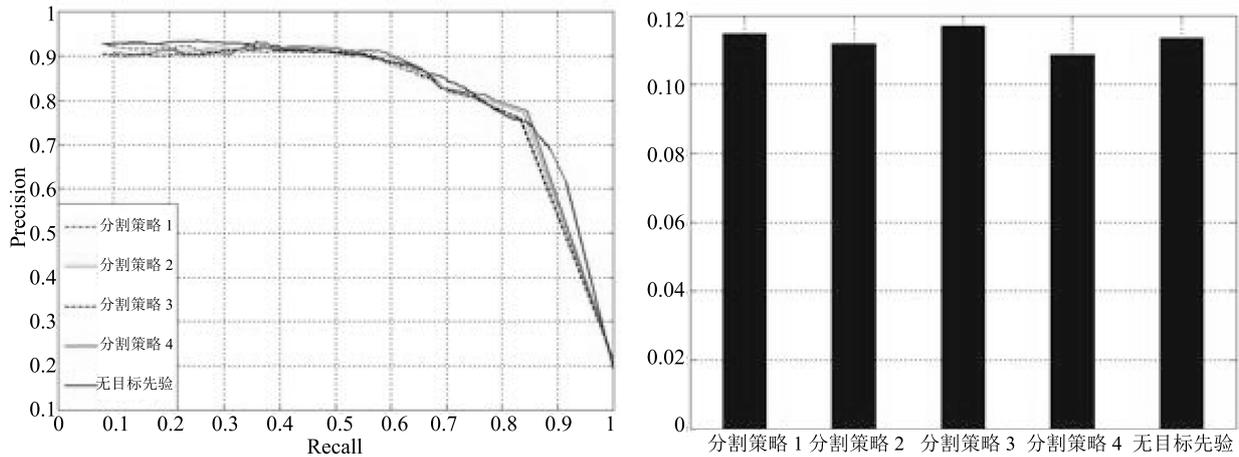


图 5 不同分割策略下显著性检测的 PR 曲线图以及 MAE 柱状图

Fig. 5 Precision-recall curves and MAE histogram in different segmentation strategies

策略. 在这 4 种分割组合策略和不加目标先验情况下显著性检测结果的 PR 曲线图以及 MAE 柱状图如图 5 所示. 运行时间如表 1 所示. 由图可以看出, 4 种策略的 PR 曲线大致相当, 但策略 4 的要稍高于其他 3 种分割策略, 与无标先验的显著性检测相差不大. 从表中可以看出策略 4 运行速度最快, 与无目标先验的检测相比, 在检测效果相差无几的情况下, 平均每幅图像的检测时间提高了 50% 左右.

表 1 不同分割策略下平均每幅图像检测时间

Table 1 The average detection time for each image in different segmentation strategies

方法	时间 (s)
分割策略 1	2.70017
分割策略 2	2.33585
分割策略 3	2.52179
分割策略 4	2.31023
无目标先验	4.52449

2.2.3 PCA 参数确定

为验证 PCA 算法从深度特征中选取主成分的有效性, 本节通过测试集的 500 幅图像中各超像素块中所提取的深度特征作为数据集, 通过可解释方差 (Percentage of explained variance, PEV)^[27] 来衡量主成分在整体数据中的重要性, 该指标是描述数据失真率的一个主要指标, 累计率越大, 数据保持率越高. 计算方式为

$$PEV = \frac{\sum_{i=1}^m R_{ii}^2}{\text{tr}(\Sigma)} \quad (23)$$

其中, R_{ii}^2 为主成分矩阵 M' 奇异值分解后的右矩阵, Σ 为协方差矩阵. 图 6 给出前 50 个主成分与累

计可解释方差. 从图中可以看出随着主成分个数的增加累计可解释方差呈上升趋势, 但这种上升趋势会随着主成分个数的增加而逐渐放缓. 当主成分个数超过 10 后累计可解释方差达到 80% 以上, 认为其能够代表数据整体信息, 在本文设计算法中选取前 10 个主成分进行显著值计算.

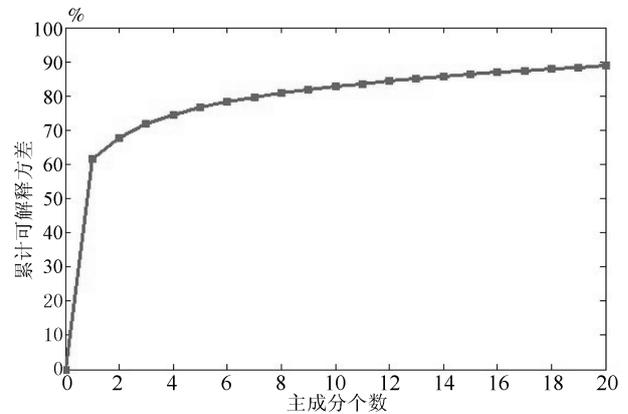


图 6 主成分个数与累计可解释方差关系图

Fig. 6 The relationship between the number of principal component and percentage explained variance

2.2.4 元胞自动机评价

为评估自适应元胞自动机融合有效性, 对测试集使用 9 种不同方式得到显著图, 分别是本文所选 6 种分割尺度、线性融合^[17]、MCA^[24] 以及加权元胞自动机. 通过 PR 值与 MAE 值对这 9 种方法进行评价, 所得结果如图 7 所示.

通过对比可以发现, 不同分割尺度下所得显著图的 PR 曲线十分相似, 但是查准率与查全率均不理想. 通过线性融合方法得到的显著图能改善单一尺度检测结果的鲁棒性使其在检测结果更加稳定.

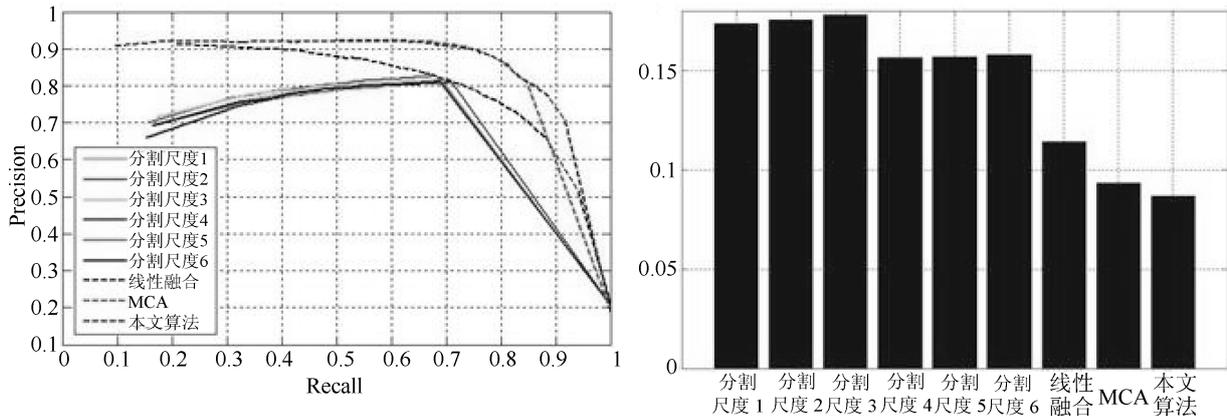


图7 不同融合方法的PR曲线与MAE柱状图

Fig. 7 Precision-Recall curves and MAE histogram of different fusion methods

MCA 融合方法明显好于线性方法得到的显著图, 而改进后的加权 MCA 方法得到的多尺度分割融合图具有更好的查准率, 因此所得融合结果将更加准确. 从 MAE 柱状图中也可看到相同结果.

2.3 实验结果对比

为验证本文提出的多目标显著性检测方法的性能, 在两个数据集上同 10 种显著性检测算法进行对比, 包括 FT09^[28], GC13^[13], DSR13^[29], GMR13^[12], MC13^[14], HS13^[14], PISA13^[30], HC15^[10], SBG16^[31], DRFI^[16] 和 MDF15^[18]. 除 MDF 算法外, 其他都是基于底层特征进行显著性计算的, 也是近几年显著性检测算法中相对较好的一些经典算法. 而 MDF 算法是最早的应用深度卷积神经网络进行显著性检测的算法之一, 且是目前为数不多的提供了源代码的深度学习算法.

2.3.1 主观评价

从主观的视觉上, 图 8~10 分别显示了在两个数据集上的视觉显著图. 从左至右依次是: 原始输入图像, 对比算法 DSR, FTvGCvGMR, HCvHSvM-CvPISA, SBG, DRFI, MDF 的显著图, 以及本文算法显著图和人工标注的真实图.

图 8 显示了本文算法与其他算法在数据集 SED2 上的显著图对比情况. 通过对比可以看出, 本文算法对位于图像边缘的目标 (如图 8 中的第 2~4 行和 9 行) 的检测效果明显优于对比算法. 此外对于图像中的小目标 (如图 8 中第 4~6 行) 检测效果也很优异.

图 9 和图 10 是不同算法在复杂多目标数据集 HKU IS 上的显著图对比情况. 与图 8 相比, 图 9 中图像的背景相对要复杂一些, 而图 10 中的图像都包含了 3 个以上的显著目标. 通过与其他算法显著图的对比可以看出, 本文算法和 MDF 算法相比于其

他算法在多目标的复杂图像的显著性检测的效果更好, 这充分特征了深度特征在图像表达方面的优势. 本文算法经过加权 MCA 融合后的显著图中, 显著目标区域内显著值的一致性要明显显著优于其他方法.

2.3.2 定量比较

为了更加客观地评价本文算法与其他算法, 本文根据不同的评价标准, 在两个数据集上进行了对比实验分析.

图 11 是根据准确率-召回率和准确率-召回率-F-measure 值评价标准, 不同检测算法在数据集 SED2 上检测结果的 PR 曲线图和 F-measure 柱状图. 通过图 11 对比分析可以看出本文算法在数据集 SED2 上的 PR 曲线与 F-measure 柱状图上与 MDF 算法相当, 但明显优于其他对比算法. 这与主观视觉特征的评价相致, 进一步体现了深度特征在图像表达上的优势.

图 12 是不同检测算法在数据集 HKU IS 上的 PR 曲线图和 F-measure 柱状图, 可以看出在复杂数据 HKU IS 上, 本文算法与 MDF 算法相比, 随着查全率的变化, 查准率各有高低, 但都能保持较高的水平. 但在 F-measure 值上, 本文算法要比 MDF 算法高出 7.18%.

相比于数据集 SED2, 数据集 HKU IS 的图像中包含更多的显著目标和相对复杂的背景信息. 与除 MDF 算法外的其他算法相比, 无论是 PR 曲线值, 还是 F-measure 值, 本文算法都明显高于其他对比算法, 并且与在数据集 SED2 的结果相比, 优势更加明显. 这些充分体现了本文算法在图像信息相对复杂的多目标显著性检测中的优越性, 如显著性目标位于图像边缘、多个显著性目标、显著性目标包含多个对比度明显的区域等情况.

图 12 是不同算法根据平均绝对误差这一评价标准在两个数据集上的 MAE 柱状图. 同样, 本文算法

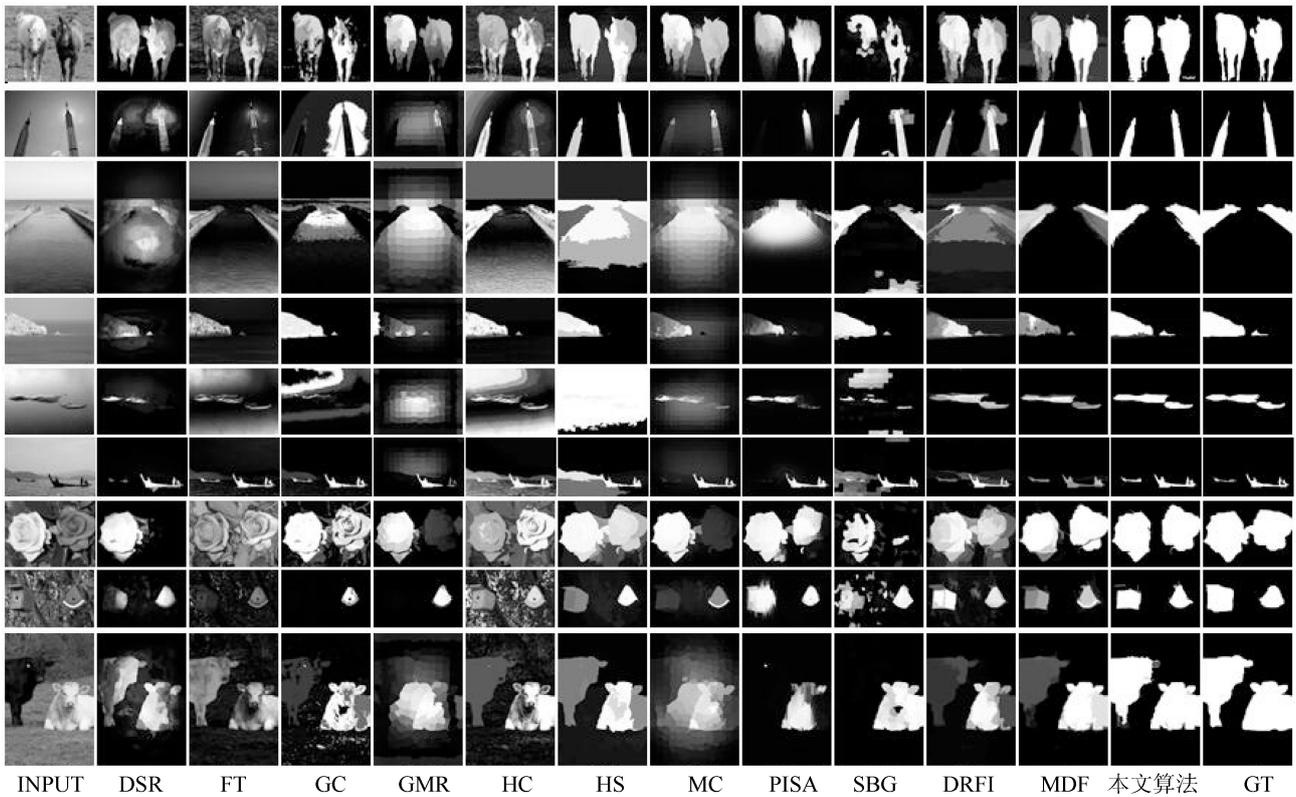


图 8 不同算法在数据集 SED2 上的视觉显著图

Fig. 8 Saliency maps of different algorithms on dataset SED2

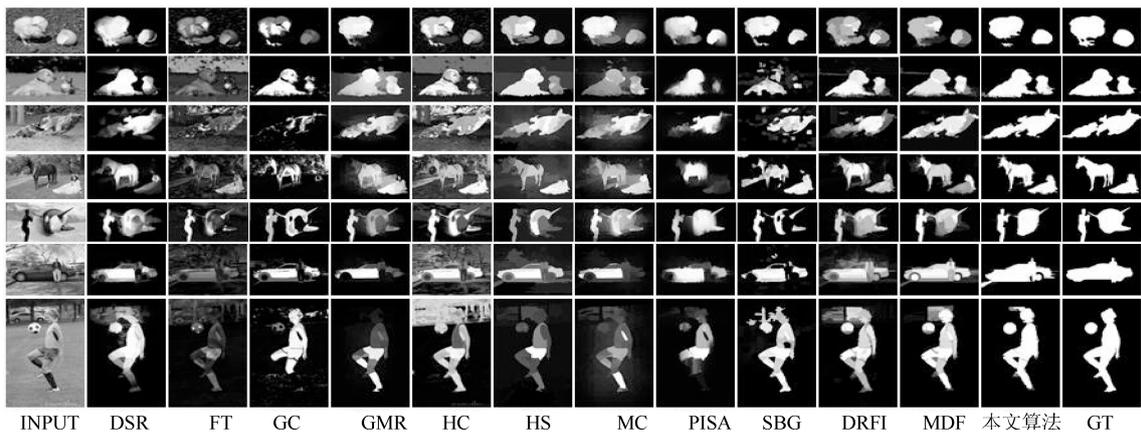


图 9 不同算法在具有不同类别目标的数据集 HKU-IS 上的视觉显著图

Fig. 9 Saliency maps of different algorithms on dataset HKU-IS with different classes of objects

的平均绝对误差远低于其他算法, 在两个数据集上降低到了 10% 以内, 并且在数据集 HKU-IS 更是降低到了 7.2%.

2.3.3 运行时间

不同算法在对图像处理的速度上也存在明显的差异, 如表 2 所示. 在显著性检测的速度上, 本文方法要比 FT、GC 等算法要慢的多, 这也是基于深度学习算法的不足之处. 但与 MDF 算法相比, 处理效

率上提高 7 倍左右, 这说明本文的目标先验知识的应用在提高速度上的有效性.

综上所述可以看出, 无论从视觉特征图上进行主观评价, 还是基于三种评价标准上的客观分析, 本文算法与其他算法相比都具有十分明显的优势. 而 MDF 算法与其他基于低层特征的算法相比优势同样也较为明显. 这些都证明了本文算法的在显著性检测上的有效性, 同时也表明基于深度学习的显著性检测算法在计算机视觉领域的巨大潜力.

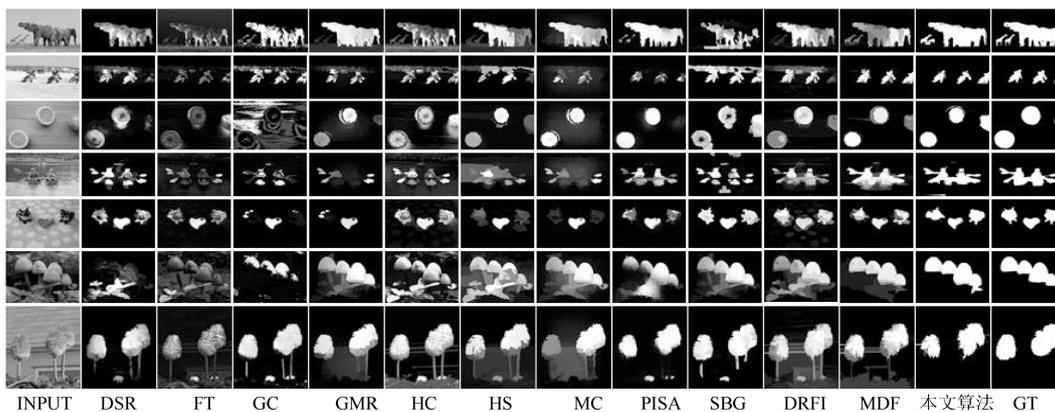


图 10 不同算法在具有多个目标的数据集 HKU-IS 上的视觉显著图

Fig. 10 Saliency maps of different algorithms on dataset HKU-IS with different multiple objects

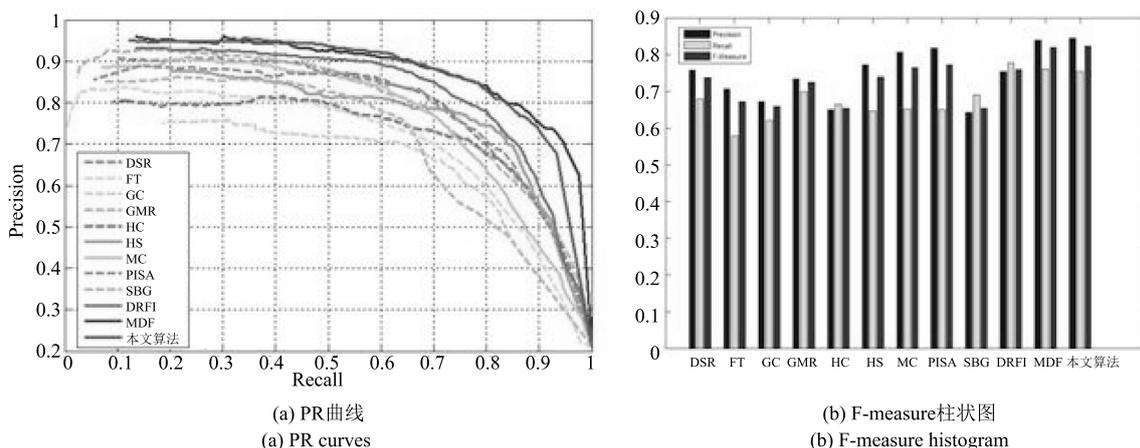


图 11 不同算法在数据集 SED2 上的 PR 曲线图和 F-measure 柱状图

Fig. 11 PR curves and F-measure histogram of different algorithms on dataset SED2

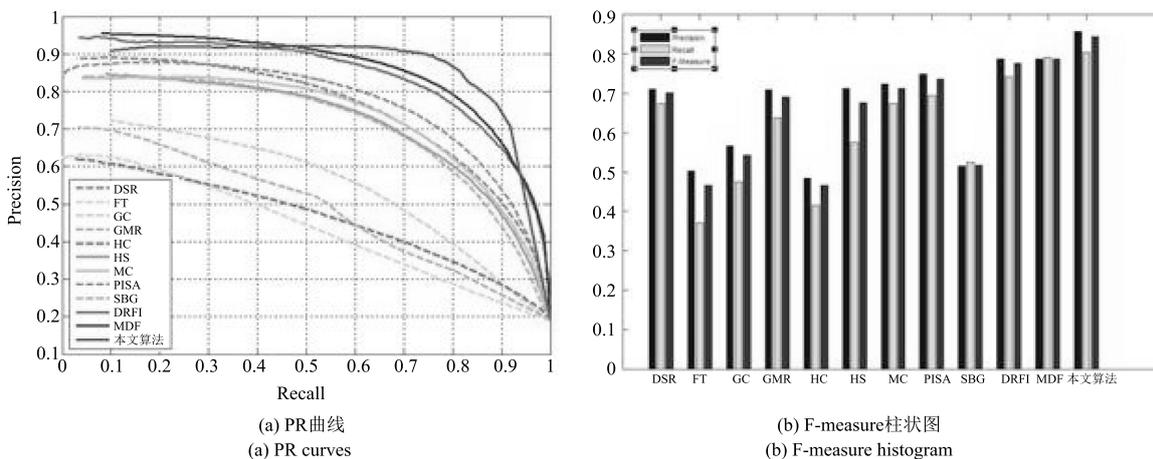


图 12 不同算法在数据集 HKU-IS 上的 PR 曲线图和 F-measure 柱状图

Fig. 12 PR curves and F-measure histogram of different algorithms on dataset HKU-IS

3 结束语

基于深度学习的显著性检测算法能够克服传统的基于底层特征的显著性检测算法在检测效果上的

不足, 但运行速率与之相比又有明显不足. 本文提出一种多尺度分割和目标先验的目标预提取方法, 在此基础上通过深度特征提取进行显著值计算, 使用加权元胞自动机对尺度显著图进行融合与优化. 本

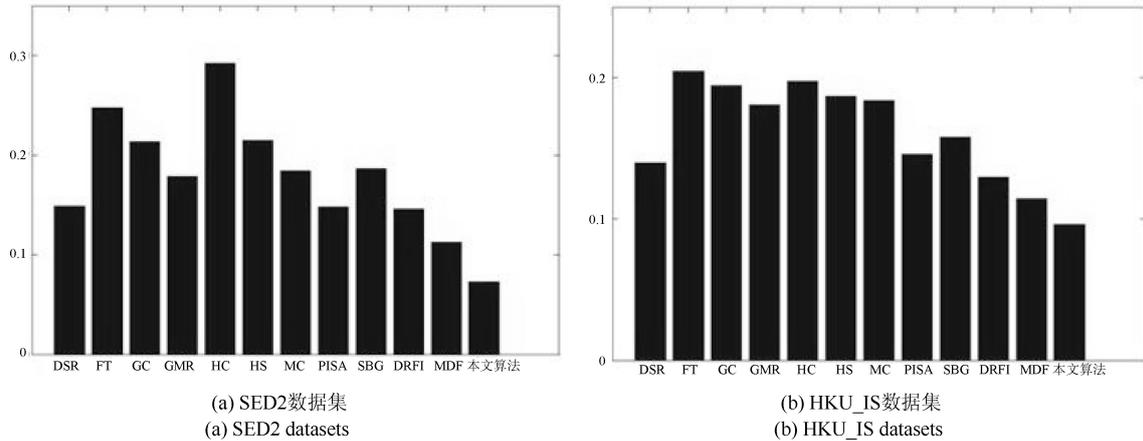


图 13 不同算法在数据集 SED2 和 HKU-IS 上的 MAE 柱状图
 Fig. 13 The MAE histogram of different algorithms on dataset of SED2 and HKU-IS

表 2 平均检测时间对比表

Table 2 Table of contrast result in running times

方法	DSR	FT	GC	GM	HS	MC	SBG	DRFI	MDF	本文算法
代码类型	MATLAB	C++	C++	MATLAB	C++	MATLAB	MATLAB	MATLAB	MATLAB	MATLAB
时间 (s)	3.534	0.023	0.095	0.252	0.492	0.146	3.882	12.135	15.032	2.31

文方法虽然在多目标显著性检测的效果和速度上有所提升,但仍存在许多不足,主要工作将继续完善深度神经网络的构建和效率提升等问题。

References

- 1 Rothenstein A L, Tsotsos J K. Attention links sensing to recognition. *Image and Vision Computing*, 2008, **26**(1): 114–126
- 2 Shao J, Gao J, Yang J. Synergetic object recognition based on visual attention saliency map. In: Proceedings of the 2006 IEEE International Conference on Information Acquisition. Weihai, China: IEEE, 2006. 660–665
- 3 Forssen P E, Meger D, Lai K, Helmer S, Little J J, Lowe D G. Informed visual search: Combining attention and object recognition. In: Proceedings of the 2008 IEEE International Conference on Robotics and Automation. Pasadena, CA, USA: IEEE, 2008. 935–942
- 4 Nakano H, Okuma S, Yano Y. A study on fast object recognition based on selective visual attention system. In: Proceedings of the 2008 IEEE International Conference on Systems, Man and Cybernetics. Singapore: IEEE, 2008. 2116–2121
- 5 Borji A, Cheng M M, Jiang H, Li J. Salient object detection: a benchmark. *IEEE Transactions on Image Processing*, 2015, **24**(12): 5706–5722
- 6 Itti L, Koch C, Niebur E. A model of saliency-based visual attention for rapid scene analysis. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1998, **20**(11): 1254–1259
- 7 Hou X D, Zhang L Q. Saliency detection: a spectral residual approach. In: Proceedings of the 2007 IEEE Conference on Computer Vision and Pattern Recognition. Minneapolis, MN, USA: IEEE, 2007. 1–8
- 8 Guo C L, Zhang L M. A novel multiresolution spatiotemporal saliency detection model and its applications in image and video compression. *IEEE Transactions on Image Processing*, 2010, **19**(1): 185–198
- 9 Li J, Levine M D, An X J, Xu X, He H G. Visual saliency based on scale-space analysis in the frequency domain. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2013, **35**(4): 996–1010
- 10 Cheng M M, Mitra N J, Huang X L, Torr P H S, Hu S M. Global contrast based salient region detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2015, **37**(3): 569–582
- 11 Shen X H, Wu Y. A unified approach to salient object detection via low rank matrix recovery. In: Proceedings of the 2012 IEEE Conference on Computer Vision and Pattern Recognition. Providence, RI, USA: IEEE, 2012. 853–860
- 12 Yang C, Zhang L H, Lu H C, Ruan X, Yang M H. Saliency detection via graph-based manifold ranking. In: Proceedings of the 2013 IEEE Conference on Computer Vision and Pattern Recognition. Portland, OR, USA: IEEE, 2013. 3166–3173
- 13 Cheng M M, Warrell J, Lin W Y, Zheng S, Vineet V, Crook N. Efficient salient region detection with soft image abstraction. In: Proceedings of the 2013 IEEE International Conference on Computer Vision. Sydney, Australia: IEEE, 2013. 1529–1536
- 14 Li X H, Lu H C, Zhang L H, Ruan X, Yang M H. Saliency detection via dense and sparse reconstruction. In: Proceedings of the 2013 IEEE International Conference on Computer Vision. Sydney, NSW, Australia: IEEE, 2013. 2976–2983
- 15 Yang Sai, Zhao Chun-Xia, Xu Wei. A novel salient object detection method using bag-of-features. *Acta Automatica Sinica*, 2016, **42**(8): 1259–1273
(杨赛, 赵春霞, 徐威. 一种基于词袋模型的新的显著性目标检测方法. *自动化学报*, 2016, **42**(8): 1259–1273)

- 16 Jiang H Z, Wang J D, Yuan Z J, Wu Y, Zheng N N, Li S P. Salient object detection: a discriminative regional feature integration approach. In: Proceedings of the 2013 IEEE Conference on Computer Vision and Pattern Recognition. Portland, OR, USA: IEEE, 2013. 2083–2090
- 17 Li Yue-Yun, Xu Yue-Lei, Ma Shi-Ping, Shi He-Huan. Saliency detection based on deep convolutional neural network. *Journal of Image and Graphics*, 2016, **21**(1): 53–59 (李岳云, 许悦雷, 马时平, 史鹤欢. 深度卷积神经网络的显著性检测. 中国图象图形学报, 2016, **21**(1): 53–59)
- 18 Li G B, Yu Y Z. Visual saliency based on multiscale deep features. In: Proceedings of the 2015 IEEE Conference on Computer Vision and Pattern Recognition. Boston, MA, USA: IEEE, 2015. 5455–5463
- 19 Hu Y, Liang Z, Chi Z R, Fu H. A combined convolutional neural network and potential region-of-interest model for saliency detection. In: Proceedings of 2015 the 11th IEEE International Conference on Natural Computation. Zhangjiajie, China: IEEE, 2015. 154–158
- 20 Liu Zhi-Wei, Zhou Dong-Ao, Lin Jia-Yu. Image segmentation based on saliency detection. *Computer Engineering & Science*, 2016, **38**(1): 144–147 (刘志伟, 周东傲, 林嘉宇. 基于图像显著性检测的图像分割. 计算机工程与科学, 2016, **38**(1): 144–147)
- 21 Li D R, Zhang G F, Wu Z C, Yi L N. An edge embedded marker-based watershed algorithm for high spatial resolution remote sensing image segmentation. *IEEE Transactions on Image Processing*, 2010, **19**(10): 2781–2787
- 22 Liu Y J, Yu C C, Yu M J, He Y. Manifold SLIC: a fast method to compute content-sensitive superpixels. In: Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, Nevada, USA: IEEE, 2016. 651–659
- 23 Guo Li-Li, Ding Shi-Fei. Research progress on deep learning. *Computer Science*, 2014, **42**(5): 28–33 (郭丽丽, 丁世飞. 深度学习研究进展. 计算机科学, 2015, **42**(5): 28–33).
- 24 Shahid N, Perraudin N, Kalofolias V, Puy G, Vandergheynst P. Fast robust PCA on graphs. *IEEE Journal of Selected Topics in Signal Processing*, 2016, **10**(4): 740–756
- 25 Qin Y, Lu H C, Xu Y Q, Wang H. Saliency detection via cellular automata. In: Proceedings of the 2015 IEEE Conference on Computer Vision and Pattern Recognition. Boston, MA, USA: IEEE, 2015. 110–119
- 26 Qu Yan-Yun, Zheng Nan-Ning, Li Cui-Hua, Yuan Ze-Jian, Ye Cong-Ying. Salient building detection based on SVM. *Journal of Computer Research and Development*, 2007, **44**(1): 141–147 (曲延云, 郑南宁, 李翠华, 袁泽剑, 叶聪颖. 基于支持向量机的显著性建筑物检测. 计算机研究与发展, 2007, **44**(1): 141–147)
- 27 Shen NM, Li J, Zhou PY, Huo Y, Zhuang Y. BSFCoS: block and sparse principal component analysis based fast co-saliency detection method. *International Journal of Pattern Recognition and Artificial Intelligence*, 2016, **30**(1): Article No.1655003
- 28 Achanta R, Hemami S, Estrada F, Susstrunk S. Frequency-tuned salient region detection. In: Proceedings of the 2009 IEEE Conference on Computer Vision and Pattern Recognition. Miami, USA: IEEE, 2009. 1597–1604
- 29 Yan Q, Xu L, Shi J P, Jia J Y. Hierarchical saliency detection. In: Proceedings of the 2013 IEEE Conference on Computer Vision and Pattern Recognition. Portland, OR, USA: IEEE, 2013. 1155–1162
- 30 Shi K Y, Wang K Z, Lu J B, Lin L. PISA: pixelwise image saliency by aggregating complementary appearance contrast measures with spatial priors. In: Proceedings of the 2013 IEEE Conference on Computer Vision and Pattern Recognition. Portland, OR, USA: IEEE, 2013. 2115–2122
- 31 Chakraborty S, Mitra P. A dense subgraph based algorithm for compact salient image region detection. *Computer Vision and Image Understanding*, 2016, **145**: 1–14



李东民 南京航空航天大学计算机科学与技术学院硕士研究生. 主要研究方向为计算机图像处理.

E-mail: nuaa_lidm@163.com

(**LI Dong-Min** Master student at the College of Computer Science and Technology, Nanjing University of Aeronautics and Astronautics. His main research interest is image processing.)



李静 南京航空航天大学计算机科学与技术学院副教授. 2004年获南京大学计算机科学与工程系博士学位. 主要研究方向为数据挖掘, 计算机图像处理. 本文通信作者.

E-mail: jingli@nuaa.edu.cn

(**LI Jing** Associate professor at the College of Computer Science and Technology, Nanjing University of Aeronautics and Astronautics. She received her Ph.D. degree in computer science and technology from Nanjing University in 2004. Her research interest covers data mining and image processing. Corresponding author of this paper.)



梁大川 南京航空航天大学计算机科学与技术学院硕士研究生. 主要研究方向为计算机图像处理.

E-mail: dacliang@nuaa.edu.cn

(**LIANG Da-Chuan** Master student at the College of Computer Science and Technology, Nanjing University of Aeronautics and Astronautics. His main research interest is image processing.)



王超 南京航空航天大学计算机科学与技术学院硕士研究生. 主要研究方向为计算机图像处理.

E-mail: nuaa_lidm@163.com

(**WANG Chao** Master student at the College of Computer Science and Technology, Nanjing University of Aeronautics and Astronautics. His main research interest is image processing.)