

# 基于非下采样轮廓小波变换增强的从粗到精的 显著性检测

刘冬梅, 常发亮\*

山东大学控制科学与工程学院, 山东 济南 250061

**摘要** 随着机器视觉和人工智能的快速发展, 视觉注意机制作为机器视觉的重要组成部分, 受到越来越多的关注。提出一种建立在非下采样轮廓小波变换(NSCT)基础上的从粗到精的显著性检测方法, 该方法作为一种基于频域分析的显著性检测算法, 能够充分利用图像的低频和低频信息, 并能抑制光照对检测造成的影响。模型首先对输入图像进行非下采样轮廓小波分解, 对低频分量进行 Retinex 增强以改善图像亮度的均匀性, 从而抑制光照对显著性检测带来的影响, 随后对其进行粗糙显著性检测; 对高频分量进行非线性增强以抑制噪声并增强细节, 重构得到高频特征图, 在低频粗糙显著图的范围内对高频特征图进行全局和局部的显著性分析; 最后经过融合得到精细显著图。在三个数据集上进行对比实验, 验证了所提算法的可行性和有效性。

**关键词** 机器视觉; 显著性检测; Retinex; 非下采样轮廓小波变换; 非线性增益

**中图分类号** TP391.4

**文献标识码** A

**doi:** 10.3788/AOS201939.0115003

## Coarse-to-Fine Saliency Detection Based on Non-Subsampled Contourlet Transform Enhancement

Liu Dongmei, Chang Faliang\*

School of Control Science and Engineering, Shandong University, Jinan, Shandong 250061, China

**Abstract** With the rapid developments of machine vision and artificial intelligence, the visual attention mechanism, as an important part of machine vision, has attracted more and more attention. A coarse-to-fine saliency detection method is proposed based on non-subsampled contourlet transform (NSCT), which, as a frequency-domain based saliency detection method, can make full use of the low-frequency and high-frequency information of images and suppress the influence of illumination on detection as well. First, the non-subsampled contourlet transform is used to decompose the input images. The low-frequency components are enhanced by Retinex to ameliorate the brightness uniformity of images, and thus the influence of illumination on the saliency detection is suppressed. Then, the coarse saliency detection is performed. The high-frequency components are enhanced nonlinearly to suppress noises and enhance details, and thus the high-frequency feature maps are obtained via reconstruction. The global and local saliency analyses of the high-frequency feature maps are performed within the scope of low-frequency coarse saliency maps. Finally, the fine saliency maps are obtained via fusion. The contrast experiments are carried out on three datasets and the results confirm the feasibility and effectiveness of the proposed method.

**Key words** machine vision; saliency detection; Retinex; non-subsampled contourlet transform; nonlinear gain

**OCIS codes** 150.0155; 110.2970; 100.2980

## 1 引 言

人类视觉可以从大量复杂的场景中高效地捕捉有价值的信息, 因此近年来关于模拟人类视觉的视觉注意机制的研究受到越来越多科研人员的关注。显著性检测作为视觉注意机制研究的主要组成部

分, 成为研究热点之一。显著性检测侧重于检测场景中完整的显著目标, 其模型可分为由数据驱动的自底向上的模型和由任务驱动的自顶向下的模型。

自底向上的显著性检测模型计算主要利用显著目标与背景的对比度较大这一先验知识。经典的 Itti<sup>[1]</sup>模型通过图像的颜色、亮度、方向等底层特征

**收稿日期:** 2018-06-19; **修回日期:** 2018-07-21; **录用日期:** 2018-08-23

**基金项目:** 国家自然科学基金(61673244)、山东省重点研发计划(2017GGX10137)

\* **E-mail:** flchang@sdu.edu.cn

的特征图计算显著性,计算快速,但是生成的是低分辨率的显著图。Achanta 等<sup>[2]</sup>提出频率调谐方法,采用多尺度双窗口的形式,以内外窗口的像素点的平均色差度量显著性。Cheng 等<sup>[3]</sup>提出了基于区域对比度的显著性检测方法,同时考虑了全局对比度和空间相干性。Li 等<sup>[4]</sup>通过多尺度的深度卷积神经网络提取物体特征,再通过这些特征训练找出图像中的显著目标。Liu 等<sup>[5]</sup>利用深度卷积神经网络和手工提取特征相结合的方法进行显著性检测。还有一些学者在频域空间构建显著图,比如 Guo 等<sup>[6]</sup>提出四元数傅里叶变换的相位谱模型。Imamoglu 等<sup>[7]</sup>使用小波变换的高频系数构造特征图,并在其基础上获取全局和局部显著图,最后通过融合实现图像的显著性检测。频域分析对于图像的细节描述更细致,非下采样轮廓小波变换(NSCT)<sup>[8]</sup>相比于小波变换具有更丰富的方向性和各向异性,对任意一维光滑边缘的表示都接近最优。之前的一些基于频域空间的显著性检测方法一般是利用图像的高频信息进行分析,未考虑低频信息,本文利用 NSCT 的低频和高频信息对图像进行显著性检测。

此外,基于各个策略的显著性检测方法很少考虑图像光照对检测效果的影响,比如光照带来的阴影和低光照下图像细节的模糊等可能会对显著性检测带来一定的影响。Retinex 最早由 Land 等<sup>[9]</sup>提出,该理论认为人眼对物体颜色的感知不会受光照环境的影响,而是由与物体材料性质相关的反射函

数决定,因此本文采用 Retinex 对图像进行增强以减轻光照带来的影响。

综上,本文提出一种基于 NSCT 增强的从粗到精的显著性检测模型。该模型首先对图像进行 NSCT 分解,并对得到的低频分量进行 Retinex 增强,以抑制光照带来的影响,之后进行粗糙显著性检测;对得到的高频分量进行细节增强和噪声抑制并生成高频特征图,然后在粗糙显著性检测的基础上对高频分量从全局和局部的角度进行精细显著性检测。

## 2 基本原理

### 2.1 Retinex

Retinex 认为人类视觉对物体的感知取决于物体表面的反射特性,实质上是把一幅图像看作是由入射分量和反射分量两部分的逐像素乘积,因此 Retinex 算法广泛应用于图像增强和去雾<sup>[10]</sup>。基于 Retinex 的图像增强过程即除去或削弱图像中的光照分量,保留并增强其反射分量。常用的 Retinex 算法有单尺度 Retinex (SSR) 算法<sup>[11]</sup>、多尺度 Retinex (MSR) 算法和带色彩恢复的多尺度 Retinex (MSRCR) 算法<sup>[12]</sup>。MSR 算法是多个尺度 SSR 算法处理结果的加权叠加,当处理细节丰富的图像时能获得比 SSR 算法更好的结果,在增强的过程中,图像往往会局部失真,不能显现出真正的颜色效果,因此 MSRCR 算法中引入彩色恢复因子,从而消除图像色彩失真的缺陷,其计算公式为

$$R_{\text{MSRCR}_i}(x, y) = GC_i(x, y) \sum_{u=1}^U \omega_u \{ \lg I_i(x, y) - \lg [F_u(x, y) * I_i(x, y)] \} + Gt, \quad (1)$$

$$C_i(x, y) = \beta \{ \lg [\alpha I_i(x, y)] - \lg \left[ \sum_i I_i(x, y) \right] \}, \quad (2)$$

式中: $R_{\text{MSRCR}_i}(x, y)$ 代表增强后的输出图像; $I_i(x, y)$ 代表原始输入图像; $G$ 和 $t$ 分别为增益和偏移量参数,用来把最后输出结果的像素值域拉伸到显示屏幕所允许的最大灰度范围中; $F_u(x, y)$ 为高斯函数; $u$ 为尺度的总个数( $u=1 \sim U$ ),一般取大、中和小三个尺度; $\omega_u$ 为权重,且 $\sum \omega_u = 1$ ; $C_i(x, y)$ 为分量比值调整因子; $\beta$ 为增益常量; $\alpha$ 为一个非线性强度的调节参数因子。

### 2.2 NSCT

小波变换基函数的支撑区间为不同尺寸大小的正方形,只适合于描述各向同性的点状奇异性,不能最优地表示图像结构奇异性,且无法精确地表达图

像边缘方向信息。轮廓小波变换(CT)改进了小波变换的不足,其基函数具有方向性和各向异性,增加了不同尺度上的方向选择,利用少量系数即可有效地表达光滑的曲线。但是,CT 在图像分析的过程中需要进行上下采样,缺乏平移不变性,尤其在图像的奇异点附近会出现伪 Gibbs 现象。NSCT 由非下采样金字塔(NSP)和非下采样方向滤波器组(NSDFB)两部分组成,具有平移不变性,不存在频谱混叠,能够抑制 Gibbs 现象。NSCT 具有良好的时频局部化特征和近似的平移不变性,能更清晰、准确地描述图像的细节<sup>[13]</sup>。对输入图像进行 $N$ 级 NSCT 分解后得到一个低频子带和 $\sum_{j=1}^N 2^j$ 个高频子

带,其中  $l_j$  为尺度  $j$  下的方向分解级数,NSCT 示意图如图 1 所示。

### 3 基于 NSCT 增强的显著性检测算法

从粗到精的显著性检测模型建立在 NSCT 的基础上。首先,将输入图像转换到 CIELAB 空间,随后进行非下采样轮廓小波分解,将分解得到的低

频分量经过 MSRCR 增强,并对其进行显著性检测,得到粗糙显著图;将分解得到的高频分量经过非线性增强,并采用逆变换计算高频特征图,在粗糙显著图的基础上对高频信息进行全局和局部显著性检测,融合二者的检测结果得到最终的精细显著图。算法流程如图 2 所示。

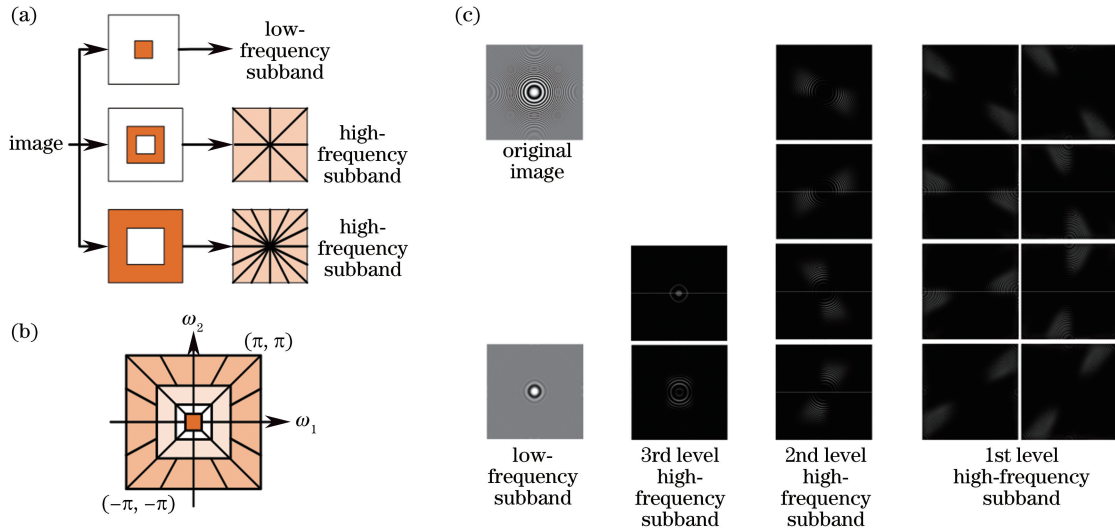


图 1 (a) NSCT 滤波器;(b)理想频率分解图;(c)三级 NSCT 分解图

Fig. 1 (a) NSCT filter; (b) schematic of ideal frequency decomposition; (c) schematic of three-level NSCT decomposition

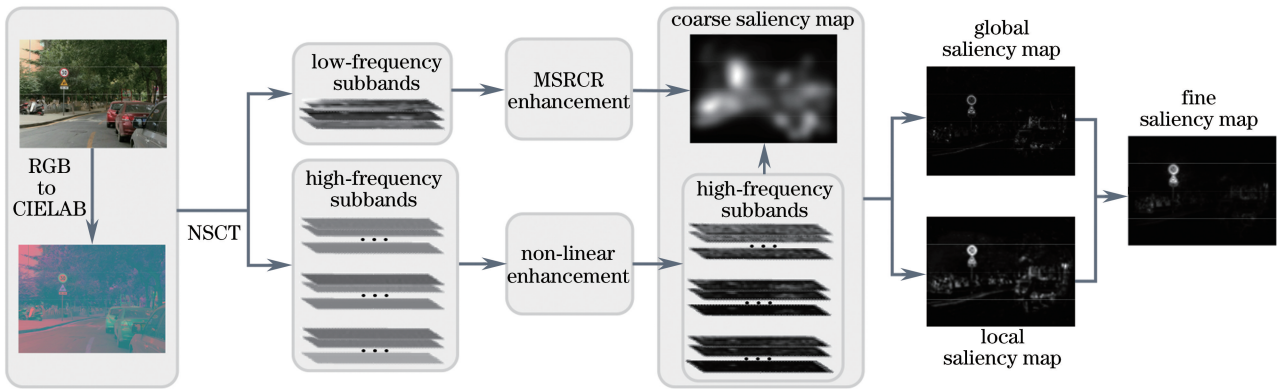


图 2 本文算法流程图

Fig. 2 Flow chart of proposed algorithm

#### 3.1 色彩空间与 NSCT 分解

首先将输入图像  $I$  由 RGB 颜色空间转换到 CIELAB 颜色空间,这主要基于两方面的考虑:1)CIELAB空间的色域比 RGB 空间更宽,色彩分布更均匀,更符合人类视觉系统感知,对于基于视觉感知的显著性提取更有利;2)后续进行 Retinex 算法增强时,相比其他空间(如 HSV 或 YCbCr 色彩空间)而言,CIELAB 空间的亮度和色度通道是分开的,不会因为亮度值的改变而引起色度值的变化。运用 NSCT 变换对 CIELAB 图像的三个通道( $L^*$ ,

$a^*$ ,  $b^*$ )进行分解,即

$$\{A_j, D_{j,k}^{l_j}\}^c = \text{NSCT}_J(I_{\text{Lab}})^c, \quad (3)$$

式中: $c$  代表三个通道( $L^*$ ,  $a^*$ ,  $b^*$ ); $A_j$  代表  $J$  层分解后得到的低频子图, $J=4$ ;  $D_{j,k}^{l_j}$  代表每层分解得到的高频子图, $j=1 \sim J, 0 \leq k \leq 2^{l_j} - 1, l_j=3$ ,即每层分解为  $2^3$  个方向。

#### 3.2 低频分量增强及粗糙显著图

利用 NSCT 对图像进行分解,得到了一个低频子图和若干个高频子图,其中照射分量主要集中在低频子图中,因此对低频分量进行 MSRCR 增强。

在 CIELAB 空间,亮度和色度值是分开的,将低频的  $L^*$  分量  $A_{j,L^*}$  作为输入,按 (1)、(2) 式对其进行增强,色度保持不变以免产生颜色偏移。将增强后的低频  $L^*$  分量定义为  $A_{j,L^*}^{MSR}$ ,将增强后的低频子图定义为  $A_j^{MSR}$ ,使用 GBVS<sup>[14]</sup> 中实现 Itti 显著图的方法计算粗糙显著图  $S_{Mc}$ ,即

$$S_{Mc} = IT(A_j^{MSR}), \quad (4)$$

式中:IT( $\cdot$ )代表 Itti 显著图计算。

图 3(a)~(e)给出了增强前后得到的粗糙显著图的对比示例。图 3(a)为原始图像,自行车示例中含有光照造成的阴影,道路交通标志示例中光照条件不佳;图 3(b)为 CIELAB 空间图像及其 Itti 显著图;图 3(c)~(e)依次为低频子图、MSR 增强后的低频子图以及 MSRCR 增强后的低频子图和各自对应的经过 Itti 算法得到的粗糙显著图。通过对比可以看出,经过 MSRCR 增强后,得到的显著区域更加精确,背景噪声更少,显著区域高亮得也更加均匀,验证了 MSRCR 对低频子图的增强能在显著性检测中抑制光照带来的影响。

### 3.3 高频分量增强及特征图的生成

经过 NSCT 变换后,高频子带包含的是图像的边缘细节信息和噪声,对高频子带进行显著性计算的同时要考虑噪声的影响。通常针对 NSCT 高频分量的增强算法利用了贝叶斯萎缩阈值法。高频分量可分为三类:强边缘、弱边缘和噪声<sup>[15]</sup>。这种阈值的选取只考虑了 NSCT 变换系数尺度间的相关性,忽略了尺度内系数之间的相关性。采用自适应的贝叶斯阈值  $\lambda_{j,k}$  来弥补这一不足<sup>[16]</sup>,其表达式为

$$\lambda_{j,k} = \frac{\bar{D}_{j,k} - D_{j,\min}}{\bar{D}_j - D_{j,\min}} \times \frac{\sigma_{\text{noise}}^2}{\sigma_{j,k}^2}, \quad (5)$$

式中: $\bar{D}_j$  代表 NSCT 变换后第  $j$  层高频系数的平均值; $\bar{D}_{j,k}$  代表第  $j$  层  $k$  方向高频系数的平均值; $D_{j,\min}$  代表第  $j$  层  $k$  方向高频系数的最小值; $\sigma_{\text{noise}}^2$  和  $\sigma_{j,k}^2$  分别为噪声方差和系数方差。

利用

$$D_{j,k}' = \begin{cases} D_{j,k}^{l_j}, & \bar{D}_{j,k}^{l_j} \geq h\lambda_{j,k} \\ E(x), & \bar{D}_{j,k}^{l_j} < h\lambda_{j,k} \ \& \ D_{\max} \geq h\lambda_{j,k}, \\ s \cdot D_{j,k}^{l_j}, & \bar{D}_{j,k}^{l_j} < h\lambda_{j,k} \ \& \ D_{\max} < h\lambda_{j,k} \end{cases} \quad (6)$$

将高频分量划分为三类,其中

$$E(x) = e \cdot [\sqrt{a \cdot D_{j,\max}^2 - (|x| - b \cdot D_{j,\max})^2} - d \cdot D_{j,\max}] \cdot \text{sgn}(x), \quad (7)$$

式中: $D_{j,\max}$  代表某一尺度下高频系数的最大值; $e$  代表增强因子; $a$ 、 $b$  和  $d$  满足  $a = b^2 + d^2$  以及  $d = b - 1$ <sup>[17]</sup>; $\bar{D}_{j,k}^{l_j}$  代表不同子带的同一位置所有像素点的平均值; $D_{\max}$  代表所有像素点的最大值; $h$  为调节参数,取值范围为 1~5。利用文献[17]设计的非线性增益函数对不同分量进行增强处理。当  $\bar{D}_{j,k}^{l_j} \geq h\lambda_{j,k}$  时,表示高频分量属于强边缘,不进行操作;当  $\bar{D}_{j,k}^{l_j} < h\lambda_{j,k} \ \& \ D_{\max} \geq h\lambda_{j,k}$  时,表示高频分量属于弱边缘,按 (7) 式进行增强操作;当  $\bar{D}_{j,k}^{l_j} < h\lambda_{j,k} \ \& \ D_{\max} < h\lambda_{j,k}$  时,表示高频分量属于噪声,进行抑制操作,不同于文献[17],这里对噪声设置了一个抑制参数  $s$  以防止计算过程中出现“NaN”的情况。对每个分解层处理后的 NSCT 高频系数进行 NSCT 逆变换,得到该层对应的特征图,即

$$f_j^c = \text{INSCT}(D_{j,k}^{l_j}{}^c), \quad (8)$$

式中  $\text{INSCT}(\cdot)$  表示非下采样轮廓小波逆变换<sup>[8]</sup>。

### 3.4 精细显著图的生成

在计算精细显著图之前,首先在粗糙显著图上选择相应的高频特征图:

$$f_j^c = S_{Mc} * f_j^c. \quad (9)$$

在此基础上,从全局和局部两个角度出发,分别构造全局和局部显著图,全局显著性是综合所有特征图进行显著性检测,局部特征图是在每一层的每一幅特征图上进行显著性检测,最后融合成精细显著图。全局显著图是在全局概率密度分布的基础上构建的,高斯概率密度函数可表示为<sup>[7]</sup>

$$p(x, y) = \frac{1}{(2\pi)^{\frac{n}{2}} |\boldsymbol{\Sigma}|^{\frac{1}{2}}}$$

$$\exp\left\{-\frac{1}{2} |[\mathbf{f}(x, y) - \boldsymbol{\mu}]^T \boldsymbol{\Sigma}^{-1} [\mathbf{f}(x, y) - \boldsymbol{\mu}]|\right\}, \quad (10)$$

式中: $\mathbf{f}(x, y) = [f_1^c, f_2^c, \dots, f_j^c]^T$  是所有高频特征图组成的特征向量; $\boldsymbol{\Sigma} = E\{[\mathbf{f}(x, y) - \boldsymbol{\mu}][\mathbf{f}(x, y) - \boldsymbol{\mu}]^T\}$ 、 $E(\mathbf{f})$  和  $\boldsymbol{\mu} = [E_1, \dots, E_j]^T$  分别为特征图的协方差矩阵、期望和期望向量。全局特征图  $S_G(x, y)$  可定义为

$$S_G(x, y) = \{\lg[p(x, y)^{-1}]\}^{\frac{1}{2}}. \quad (11)$$

局部显著图构建在局部香农自信息的基础上<sup>[18]</sup>,首先在每层各个通道的特征图上计算所有点的概率密度值,即

$$p_j^c(x, y) = \frac{1}{\sqrt{2\pi}\sigma_j^c} \cdot \exp\left\{-\frac{1}{2(\sigma_j^c)^2}[f^{c'}(x, y) - \mu_j^c]^2\right\}, \quad (12)$$

式中  $\sigma_j^c$  和  $\mu_j^c$  分别为特征图  $f^{c'}(x, y)$  的方差和期望。局部自信息和局部显著图的定义为

$$\Phi_j^c(x, y) = - \sum_{N(x, y, r)} \lg p_j^c(x, y), \quad (13)$$

$$S_L(x, y) = - \left[ \sum_{j, c} W_j^c * \Phi_j^c(x, y) \right], \quad (14)$$

式中:  $N(x, y, r)$  是指某像素点周边  $(2r + 1) \times (2r + 1)$  的邻域;  $W_j^c$  为权重。

将全局和局部显著图按

$$S'(x, y) = \{N[S_L(x, y)] \times \exp\{N[S_G(x, y)]\}\}^{\ln\sqrt{2}/\sqrt{2}} \quad (15)$$

进行融合, (15) 式中  $N(\cdot)$  为  $[0, 1]$  范围内的归一化操作, 非线性指数项  $(\cdot)^{\ln\sqrt{2}/\sqrt{2}}$  的目的是削弱运算放大效应的影响。在此基础上引入上下文修正, 从(15)式得到的显著图中提取最受注意的局

部区域, 对距离关注点较近的像素赋予较高的显著度, 对距离关注点较远的像素赋予较低的显著度, 从而提高显著目标附近的显著性值, 降低背景区域的显著性值。最终的精细显著图的计算公式为

$$S(x, y) = S'(x', y')[1 - d_{FOA}(x, y)], \quad (16)$$

式中  $d_{FOA}(x, y)$  为点  $(x, y)$  与其最近的注意焦点  $(x', y')$  间的欧式距离。精细显著图示例如图 3(f) 所示。

精细显著图 3(f) 是在粗糙显著图 3(e) 的基础上对图像的高频信息进行分析得到的, 由于结合了低频和高频两部分信息, 相比于粗糙显著图, 其显著区域的细节更为细致, 显著物体的轮廓更加清晰。由于低频信息主要包含照度和色度信息, 对低频进行增强得到的粗糙显著区域消除了光照的影响; 高频信息包含了图像的纹理细节, 对高频信息进行增强和去噪能够使得最终的显著图细节更加细致。




图 3 粗糙与精细显著图。(a)原始图像;(b) CIELAB 空间图像及其 Itti 显著图;(c)低频子图;(d) MSR 增强后的低频子图;(e) MSRCR 增强后的低频子图;(f)精细显著图

Fig. 3 Coarse and fine saliency maps. (a) Original images; (b) images in CIELAB space and their Itti saliency maps; (c) low-frequency sub-images; (d) MSR-enhanced low-frequency sub-images; (e) MSRCR-enhanced low-frequency sub-images; (f) fine saliency maps

## 4 实验结果及分析

为了对所提算法进行验证, 在三个通用的数据集 MSRA-1000、DUT-OMRON 和 MSRA-10K 上进行测试。MSRA-1000 数据集包含 1000 张图像<sup>[19]</sup>, FT 算法<sup>[2]</sup>给出了该数据集的二值化的标准显著图; DUT-OMRON 数据集包含 5168 张图像, 显著区域标定既有眼动数据标注、边框界定, 又有二

值化的标准显著图; MSRA-10K 数据集含有 10000 张图像, 是 Cheng 等<sup>[3]</sup>为了进行更为广泛和准确的评价, 从 MSRA 数据库<sup>[20]</sup>随机选择了 10000 张图像并且给出了二值化的标准显著图。对比算法选取了 GB<sup>[14]</sup>、SR<sup>[21]</sup>、FT<sup>[2]</sup>、HFT<sup>[22]</sup>、WT<sup>[7]</sup> 和 RC<sup>[3]</sup> 6 种方法, 实验中 ENT 代表所提算法。所提算法是在 Intel(R) Core(TM) i7-6500 处理器、16G RAM 的 Win64 操作系统下运行的, 实验环境为

Matlab2017a。

#### 4.1 定性评测

图 4 给出了不同算法在不同数据集上的显著性

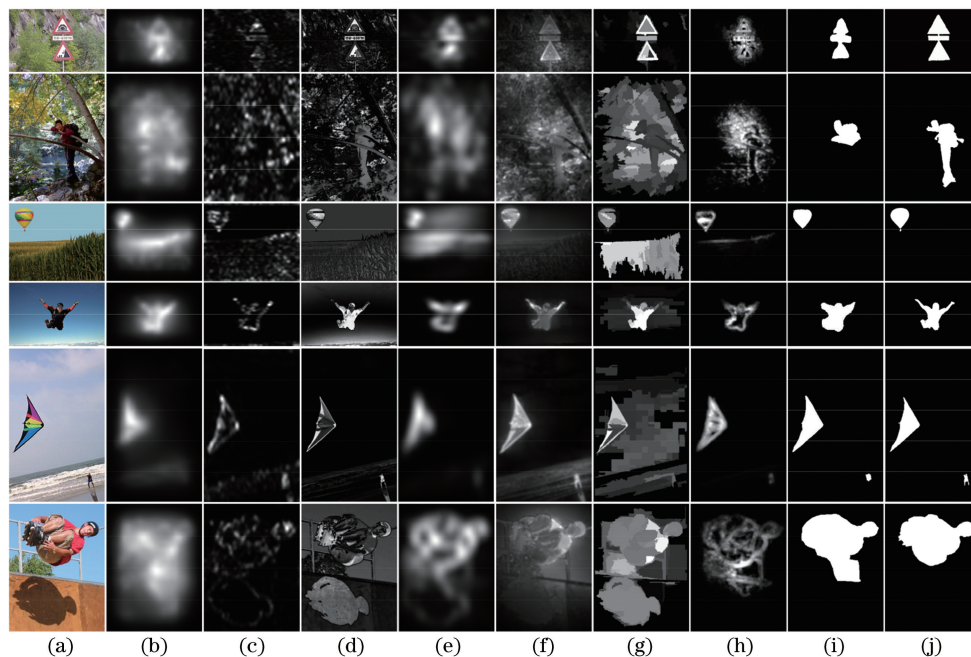


图 4 原图和所有方法的显著图对比。(a)原图;(b) GB 显著图;(c) SR 显著图;(d) FT 显著图;(e) HFT 显著图;(f) WT 显著图;(g) RC 显著图;(h) ENT 显著图;(i) ENT 显著区域的二值图;(j)标准显著图

Fig. 4 Comparison among original image and saliency maps by all methods. (a) Original images; (b) GB saliency maps; (c) SR saliency maps; (d) FT saliency maps; (e) HFT saliency maps; (f) WT saliency maps; (g) RC saliency maps; (h) ENT saliency maps; (i) binary maps of ENT salient region; (j) standard saliency maps

由于所提算法采用由粗到精的显著区域检测策略,先经过低频分量粗检测确定粗糙显著区域,在此基础上通过对高频分量的分析进行细检测,因此最后的显著图要比其他方法的更精确。对于背景简单的第 1,4,5 行图而言,所有方法的检测效果都不错,所提算法的显著图的显著区域更突出且背景噪声更少。对于背景复杂的第 2,3 行图而言,部分方法失效,而所提算法依然能突出显著区域。对于光照不均匀的第 2 行图和有阴影的第 6 行图而言,FT 和 RC 算法都将阴影部分高亮,但本文方法依然有效。对估计得到的显著图进一步进行显著区域分割,由于所提算法得到的显著图轮廓比较清晰、完整,因此采用结合边缘检测和区域生长的方法对显著图进行分割,结果如图 4(i)所示。

#### 4.2 定量评测

为了客观评价所提算法,在准确率-召回率( $P-R$ )曲线和  $F$  度量 ( $F$ -measure)评价指标下进行实验对比和分析。 $F$ -measure 定义为

$$F_{\beta} = \frac{(1 + \beta^2)h_P h_R}{\beta^2 h_P + h_R}, \quad (17)$$

检测结果,每个数据集选取两个示例(共 6 张图)进行展示,数据集依次为 MSRA-1000、DUT-OMRON 和 MSRA-10K。

式中: $h_P$  和  $h_R$  分别代表精度和召回率; $\beta^2$  设置为 0.3。

图 5 所示为不同方法在三个数据集下的  $P-R$  曲线,是通过得到的灰度显著图进行不同阈值(0~255)下的二值分割得到的,当阈值为 0 时召回值最大,这时所有像素都被认为是前景。图 6 所示为不同方法在三个数据集下的平均精度、召回率以及  $F$ -measure 对比。

由图 4 可以看出,所提算法呈现的显著区域中的显著物体具有清晰高亮(灰度值高)的轮廓,因此不同阈值下计算  $P-R$  曲线时,经过简单的腐蚀填充能够得到比较理想的结果。GB 算法的  $P-R$  曲线要高于 SR 算法,从图 4 可以看出,GB 算法在包含背景较多的情况下基本能高亮出显著区域;RC 算法与 FT 算法相比,虽然都受背景干扰较多,但 RC 算法得到的显著区域的高亮更集中;HFT、WT 算法和所提的 ENT 算法都属于基于频域空间的显著性检测方法,ENT 算法运用了 NSCT 良好的曲线描述性和前期的 MSRRC 增强去除光照的影响,其检测效果中背景干扰更少,显著物体也具有一致高

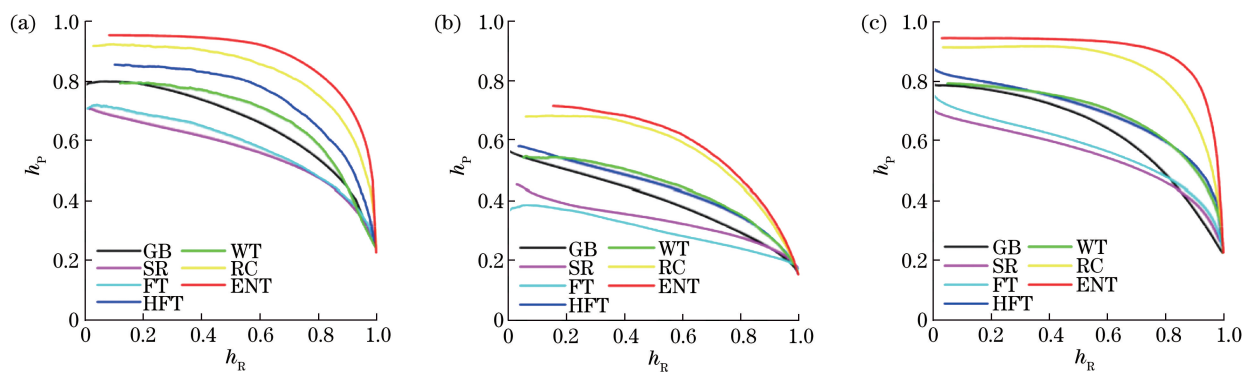


图 5 所有方法的  $P$ - $R$  曲线对比。(a) MSRA-1000; (b) DUT-OMRON; (c) MSRA-10K

Fig. 5  $P$ - $R$  curves comparison among all methods. (a) MSRA-1000; (b) DUT-OMRON; (c) MSRA-10K




图 6 所有方法的  $F$ -measure 对比。(a) MSRA-1000; (b) DUT-OMRON; (c) MSRA-10K

Fig. 6  $F$ -measure comparison among all methods. (a) MSRA-1000; (b) DUT-OMRON; (c) MSRA-10K

亮的轮廓。因此在定性评测中所提算法具有相对较高的精度和召回率。

同时,为了对比算法运行时间,将 MSRA-1000 中的图像归一化尺寸到  $512 \text{ pixel} \times 512 \text{ pixel}$ ,使用各个算法对源代码进行测试,计算处理一幅图像所

需的平均时间如表 1 所示。RC 算法是用 C++ 实现的,其处理速度较快;GB 算法是基于图模型的,其速度比 SR、FT 算法慢,基于频域的 HFT、WT 和 ENT 算法涉及到较为复杂的图像变换,速度较慢,同时 ENT 算法中还包含增强处理,速度更慢。

表 1 各算法的运行时间

Table 1 Running time for different algorithms

Algorithm	GB	SR	FT	HFT	WT	RC	ENT
Time /s	1.672	0.071	0.142	13.877	7.853	0.279	18.746
Code type	Matlab	Matlab	Matlab	Matlab	Matlab	C++	Matlab

## 5 结 论

提出一种基于非下采样轮廓小波增强的显著性检测方法,将图像经过 NSCT 分解后,在增强的低频分量上进行粗糙显著性检测,在此基础上对增强后的高频分量进行精细显著性检测,获取最终的显著图。在 MSRA-1000、DUT-OMRON 和 MSRA-10K 数据集上进行定性和定量评测,验证了所提算法的可行性和有效性。

所提算法虽然在图像显著性检测中取得了良好的效果,但仍存在一些问题。提高对纹理复杂图像

的显著区域检测精确度以及更加快速充分地利用非下采样轮廓小波进行显著性检测是今后重点研究的方向。

## 参 考 文 献

- [1] Itti L, Koch C, Niebur E. A model of saliency-based visual attention for rapid scene analysis [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1998, 20(11): 1254-1259.
- [2] Achanta R, Hemami S, Estrada F, et al. Frequency-tuned salient region detection [J]. IEEE Conference on Computer Vision and Pattern Recognition, 2009:

- 1597-1604.
- [3] Cheng M M, Mitra N J, Huang X L, *et al.* Global contrast based salient region detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37(3): 569-582.
- [4] Li G, Yu Y. Visual saliency detection based on multiscale deep CNN features[J]. IEEE Transactions on Image Processing, 2016, 25(11): 5012-5024.
- [5] Liu F, Shen T S, Lou S L, *et al.* Deep network saliency detection based on global model and local optimization[J]. Acta Optica Sinica, 2017, 37(12): 1215005.  
刘峰, 沈同圣, 娄树理, 等. 全局模型和局部优化的深度网络显著性检测[J]. 光学学报, 2017, 37(12): 1215005.
- [6] Guo C, Zhang L. A novel multiresolution spatiotemporal saliency detection model and its applications in image and video compression [J]. IEEE transactions on Image Processing, 2010, 19(1): 185-198.
- [7] Imamoglu N, Lin W S, Fang Y M. A saliency detection model using low-level features based on wavelet transform [J]. IEEE Transactions on Multimedia, 2013, 15(1): 96-105.
- [8] Da Cunha A L, Zhou J, Do M N. The nonsubsampling contourlet transform: theory, design, and applications[J]. IEEE Transactions on Image Processing, 2006, 15(10): 3089-3101.
- [9] Land E H, McCann J J. Lightness and retinex theory [J]. Journal of the Optical Society of America, 1971, 61(1): 1-11.
- [10] Yang A P, Bai H H. Nighttime image defogging based on the theory of Retinex and dark channel prior [J]. Laser & Optoelectronics Progress, 2017, 54(4): 041002.  
杨爱萍, 白煌煌. 基于 Retinex 理论和暗通道先验的夜间图像去雾算法[J]. 激光与光电子学进展, 2017, 54(4): 041002.
- [11] Jobson D J, Rahman Z, Woodell G A. Properties and performance of a center/surround retinex [J]. IEEE Transactions on Image Processing, 1997, 6(3): 451-462.
- [12] Jobson D J, Rahman Z, Woodell G A. A multiscale retinex for bridging the gap between color images and the human observation of scenes [J]. IEEE Transactions on Image processing, 1997, 6(7): 965-976.
- [13] Wu Y Q, Shi J P. Image enhancement in non-subsampling Contourlet transform domain based on multi-scale Retinex [J]. Acta Optica Sinica, 2015, 35(3): 0310002.  
吴一全, 史骏鹏. 基于多尺度 Retinex 的非下采样 Contourlet 域图像增强 [J]. 光学学报, 2015, 35(3): 0310002.
- [14] Harel J, Koch C, Perona P. Graph-based visual saliency [C]. Advances in Neural Information Processing Systems, 2007: 545-552.
- [15] Liu D M, Chang F L, Liu C S. Salient object detection fusing global and local information based on nonsubsampling contourlet transform [J]. Journal of the Optical Society of America A, 2016, 33(8): 1430-1441.
- [16] Chang S G, Yu B, Vetterli M. Spatially adaptive wavelet thresholding with context modeling for image denoising [J]. IEEE Transactions on Image Processing, 2000, 9(9): 1522-1531.
- [17] Zhang L, Zhu Z D. A novel nonlinear method for image enhancement based on non-subsampling contourlet transform [J]. Journal of Electronics & Information Technology, 2009, 31(8): 1786-1790.  
张林, 朱兆达. 基于非降采样 Contourlet 变换的非线性图像增强新算法 [J]. 电子与信息学报, 2009, 31(8): 1786-1790.
- [18] Bruce N D B, Tsotsos J K. Saliency, attention, and visual search: An information theoretic approach [J]. Journal of Vision, 2009, 9(3): 5.
- [19] Wang Z S, Li B X. A two-stage approach to saliency detection in images [C]. IEEE International Conference on Acoustics, Speech and Signal Processing, 2008: 965-968.
- [20] Liu T, Yuan Z J, Sun J, *et al.* Learning to detect a salient object [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2011, 33(2): 353-367.
- [21] Hou X, Zhang L. Saliency detection: a spectral residual approach [J]. IEEE Conference on Computer Vision and Pattern Recognition, 2007: 9738156.
- [22] Li J, Levine M D, An X J, *et al.* Visual saliency based on scale-space analysis in the frequency domain [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2013, 35(4): 996-1010.