

文章编号: 1001- 2486(2010) 06- 0053- 06

基于主导拮抗抑制的多尺度边缘检测*

孟祥林, 王正志

(国防科技大学 机电工程与自动化学院, 湖南 长沙 410073)

摘要: 图像边缘检测算子的抑噪能力和定位精度是一对矛盾, 从视觉神经生理学角度出发, 提出一种基于主导拮抗抑制的多尺度边缘检测模型。该模型将主导拮抗抑制机制拓展到多尺度处理, 通过引入侧膝体拮抗通道的强抑制机制达到自适应抑噪的效果, 获得的对比度信息经过简单细胞子域的非线性整合得到锐化的边缘输出, 最后将多个尺度的处理结果进行融合, 获得最终的边界轮廓。理论和实验证明通过主导拮抗抑制机制和多尺度处理的结合, 获得抑噪能力强、定位精度高的边缘检测模型, 该模型具有生理学基础, 结构简单, 计算效率高。

关键词: 主导拮抗抑制; 边缘检测; 简单细胞; 多尺度

中图分类号: TP391. 41 **文献标识码:** A

Multi-scale Edge Detection with Dominating Opponent Inhibition

MENG Xiang lin, WANG Zheng zhi

(College of Mechatronics Engineering and Automation, National Univ. of Defense Technology, Changsha 410073, China)

Abstract: Noise suppression conflicts with high accuracy in image edge detection. A multi-scale edge detection model with dominating opponent inhibition was proposed from physiological point of view. The presented model made extension of dominating opponent inhibition mechanism to processing at multiple scales. Image noise can be adaptively suppressed by dominating inhibition from the opponent path of lateral geniculate nucleus. Sharp edges were obtained through the non-linear combination of simple cell subfields. Finally multi-scale processing results were combined to obtain boundary contour. Theoretical analysis and experimental results indicate that the proposed model performs well in noise suppression and accurate edge detection through the combination of dominating opponent inhibition and multi-scale processing. Meanwhile, it is biologically plausible, simple and efficient.

Key words: dominating opponent inhibition; edge detection; simple cell; multiple scales

图像的边缘检测一直是图像处理、计算机视觉和模式识别领域的热点问题, 并相继出现了诸如 Prewitt、Sobel 以及 Canny 和 Marr-Hildreth 等经典算法, 特别地, 由于小波变换的多分辨特性, 近年来标准的小波变换已成为图像处理的一个有效工具。最近, Zhang 等提出一种基于方向小波变换的边缘检测方法^[1], 在保留传统小波变换优点的基础上, 重新定义了梯度幅值并提出一种新的非最大抑制算法; 土耳其学者 Basturk 等^[2]提出一种细胞神经网络 CNN, 利用微分进化算法进行优化, 可有效提取数字图像的边缘; 复旦大学的 Yu 等^[3]提出一种新的核各向异性扩散方法, 用于检测低信噪比图像的边缘; 还有学者提出对照度不敏感的图像边缘检测算法^[4], 对照度变化的图像可得到不变的边缘检测结果。另外, 印度学者 Chaira 将模糊集理论应用于图像的边缘检测^[5], 提出一种称为直观模糊散度的距离度量。

然而, 能够像人一样去看是机器视觉一直追求的目标。人类对于自然图像的感知是一个多层次的视觉信息处理过程, 对图像边界轮廓的提取是视觉处理的重要步骤, 通常认为这一过程发生在大脑皮层的 V1 区, 处于视觉信息处理的早期阶段。1962 年, Hubel 和 Wiesel 在对猫的视皮层研究中, 发现存在于 V1 区的简单细胞的感受野具有方向选择性, 这一特性构成了人类对于自然场景轮廓感知的生理基础。早期关于视觉处理的经典模型认为简单细胞的 on 子域接收来自 LGN ON 细胞的激励性输入, off 子域接收 LGN OFF 细胞的激励性输入。近年来的神经生理研究表明简单细胞的每一个子域在接收来自同一

* 收稿日期: 2010- 07- 09

基金项目: 国家自然科学基金资助项目(60835005); 国防科技大学科研计划资助项目(JC09- 03- 04)

作者简介: 孟祥林(1982-), 男, 博士生。

通路的激励性输入的同时,也接收来自拮抗通路的抑制性输入。而且,大量实验研究发现简单细胞接收的抑制性输入要强于激励性输入^[6-7]。基于这一发现,Hansen等提出一种具有主导拮抗抑制机制的简单细胞模型^[8],模型解释了简单细胞的有关实验数据。Marr从神经生理学和心理物理学出发,指出人的视觉前期处理中有多个分辨率的轮廓算子对图像作卷积,各边缘检测算子输出的组合能提高定位精度,减少噪声干扰,其中体现的就是多尺度处理的思想。

基于上述分析,本文在Hansen的简单细胞模型基础上提出一种基于主导拮抗抑制的多尺度边缘检测模型,将其拓展到多尺度处理,用于复杂图像的边缘检测,并对其性能进行了定量分析。不同于Canny等经典算法,该模型具有神经生理学基础,可以作为视觉处理的早期阶段的模型。

1 模型描述

多尺度边缘检测模型如图1所示,为一自底向上的前向处理神经网络,实心圆表示神经细胞,旁边的图形为感受野示意图。模型在小、中、大三个尺度上对图像进行处理,不同尺度对应的感受野大小不同,处理过程完全相同,每个尺度通道间是相互独立的。首先,输入图像经过视网膜和LGN细胞的处理,产生输入图像的对比度信息,然后,简单细胞完成不同方向上的局部对比度检测,复杂细胞对相反极性的简单细胞进行整合,输出方位敏感、极性不敏感的边界信息,最后,对三个不同尺度上的处理结果进行求和,产生最终的边界轮廓输出。

1.1 ON细胞和OFF细胞处理阶段

ON细胞和OFF细胞处理阶段是由对应于视网膜和侧膝体的ON通道和OFF通道的中心-周边相互作用组成的。在生物视觉系统中,“中心激励,周边抑制”的ON细胞和“中心抑制,周边激励”的OFF细胞对照明的影响进行了补偿,它们敏感于每个细胞的感受野所张成的局部图像区域的对比度分布。

神经细胞的响应特性可以建立一个分流方程模型,也称膜电位方程:

$$\frac{dV}{dt} = -\alpha V + (\beta - V) E_{exc} - (\gamma + V) I_{inh} \tag{1}$$

其中, V 为细胞活性, α 是细胞活性衰减因子, β, γ 分别是细胞活性的上界和下界,实现视觉图像局部对比度和整体动态范围的自适应规范化,减弱视觉信号获取过程中环境的照明条件等因素对后续处理过程的影响^[9]。 E_{exc} 和 I_{inh} 分别是细胞的激励性输入和抑制性输入。通常认为分流方程可以很快达到稳态,所以只考虑其稳态解,令方程(1)右端等于0可以解得:

$$V(E_{exc}, I_{inh}) = \frac{\beta E_{exc} - \gamma I_{inh}}{\alpha + E_{exc} + I_{inh}} \tag{2}$$

为叙述方便,以下所有方程和变量均略去尺度标注,不同尺度的计算可类似得出。每个ON细胞同时接受来自感受野中心区域的激励信号和周边区域的抑制信号,建立输入图像 I 与高斯核的卷积滤波模型,即

$$I_c = I * G_c, \quad I_s = I * G_s \tag{3}$$

其中,“*”表示卷积运算:

$$G_c(p, q) = A_1 \exp\left(-\frac{p^2 + q^2}{2\sigma_c^2}\right), \quad G_s(p, q) = A_2 \exp\left(-\frac{p^2 + q^2}{2\sigma_s^2}\right) \tag{4}$$

σ_c, σ_s 为高斯核的标准差,对于三个尺度分别选择 $\sigma_c = \{1, 1.5, 2\}$, $\sigma_s = \{3, 4, 5\}$, (p, q) 为空间位置, A_1, A_2

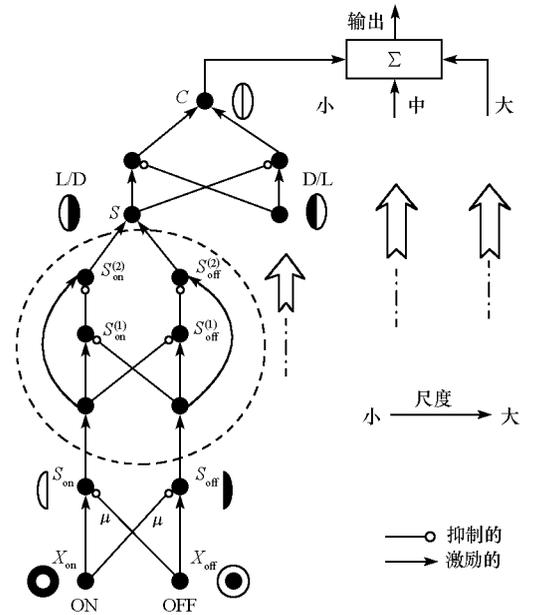


图1 多尺度边缘检测模型
Fig.1 Multi scale edge detection

A_2 为规范化增益因子,使得每个高斯核的和为 1。由分流方程得

$$x_{on} = V(I_c, I_s) \quad (5)$$

而 OFF 细胞接受来自周边区域的激励信号和中心区域的抑制信号,因此

$$x_{off} = V(I_s, I_c) \quad (6)$$

亮度均匀区域的对比度应为 0, Neumann 提出可利用 ON 通道和 OFF 通道的相互抑制作用实现^[10]:

$$X_{on} = [x_{on} - x_{off}]^+, \quad X_{off} = [x_{off} - x_{on}]^+ \quad (7)$$

其中 $[\cdot]^+$ 表示半波整流。

1.2 简单细胞处理阶段

简单细胞完成有向对比滤波功能,对来自 LGN 的对比度信息具有方向选择性。简单细胞的感受野有两个相邻的子域, on 子域和 off 子域, on 子域敏感于亮度增加,而 off 子域敏感于亮度降低。子域的感受野是具有方向性的,本文选择总方位数 $K = 12$ 。 θ 方位的感受野记为 G_θ , 建立 5 个等距排列的各向同性的高斯核^[8]模型,排列方向就是感受野的主轴方向 θ , 排列间距为高斯核标准差 σ 的两倍,三种尺度的高斯标准差分别选择为 $\sigma = \{0.5, 1.5, 2.5\}$ 。

主导拮抗抑制机制认为,简单细胞 on 子域在接收来自 ON 通道的 LGN 激励性输入的同时,还受到 OFF 通道的强抑制作用,同样,off 子域也受到拮抗通道的强抑制作用,且抑制的强度要大于激励的强度,如图 1 所示,抑制增益常数 $\mu > 1$,因此称为主导拮抗抑制。 θ 方位的子域响应为

$$S_{on,\theta} = [(X_{on} - \mu X_{off}) * G_\theta]^+ \quad (8)$$

$$S_{off,\theta} = [(X_{off} - \mu X_{on}) * G_\theta]^+ \quad (9)$$

这种机制的引入使得简单细胞的子域响应呈现一种“一对多”的情形,比如 on 子域只有在 ON 通道的输入大于 OFF 通道的 μ 倍时才会响应。这一机制也可解释为投票决策,激励性和抑制性输入分别表示投票支持和投票反对子域响应与否的决策。对于 $\mu = 1$ 的均衡抑制情形,有半数的支持票,就会使得简单细胞的子域做出响应。而对于 $\mu > 1$ 的强抑制情形,就要求有超过半数的支持票,即支持票占总票数的 $\mu/(\mu+1)$ 时,才会引起细胞子域的响应。比如, $\mu = 2$ 时,就要求有 $2/3$ 的大多数支持票,细胞子域才会响应。这一主导拮抗抑制机制得到很多生理实验数据的支持,且对抑制图像噪声起到重要作用,将在后面给出证明。

基本的线性简单细胞模型中 on 子域和 off 子域的响应是简单的相加关系,即

$$S_{in} = S_{on} + S_{off} \quad (10)$$

本文的简单细胞模型中的子域整合为非线性方式,目的是生成锐化的边缘。为使得简单细胞在图像边缘处产生锐化的响应,要求两个子域同时被激活时响应得到增强,类似于一个软“与”门。如图 1 中虚线圆包含的部分,模型使用分流方程来描述两个子域同时被激活时子域响应的去抑制作用^[8],稳态时 ON 通道的响应为

$$S_{on}^{(1)} = \frac{S_{on}}{\alpha_S + \beta_S S_{off}}, \quad S_{on}^{(2)} = \frac{S_{on}}{\gamma_S + \delta_S S_{on}^{(1)}} \quad (11)$$

OFF 通道的相应方程可通过对上式中的下标 on 和 off 互换得到。此处所有的变量及方程都是针对所有方位的,为叙述简单,略去了方位下标。最后,对 ON 和 OFF 通道的处理结果求和,得到

$$\begin{aligned} S &= S_{on}^{(2)} + S_{off}^{(2)} \\ &= \frac{S_{on}(\alpha_S + \beta_S S_{off})}{\gamma_S(\alpha_S + \beta_S S_{off}) + \delta_S S_{on}} + \frac{S_{off}(\alpha_S + \beta_S S_{on})}{\gamma_S(\alpha_S + \beta_S S_{on}) + \delta_S S_{off}} \\ &= \frac{\gamma_S \beta_S \alpha_S (S_{on} + S_{off}) + 2\beta_S (S_{on} S_{off})}{\alpha_S \gamma_S + \beta_S \gamma_S (S_{on} + S_{off})} \end{aligned} \quad (12)$$

上式中,令 $\delta_S \triangleq \gamma_S \beta_S$, $\alpha_S = 1$, $\beta_S = 10000$, $\gamma_S = 0.01$, $\delta_S = 100$ 。结果为加性的线性项和乘性的非线性项的组合。简单细胞敏感于对比极性,即亮-暗和暗-亮。通过对有向高斯核沿主轴 θ 的垂直方向分别移位 $\pm \tau$, 得到亮-暗和暗-亮简单细胞响应 $S_{ld,\theta}$, $S_{dl,\theta}$ 。

1.3 复杂细胞处理阶段

具有相反对比极性的简单细胞相互抑制,如图1所示。复杂细胞对于对比方位敏感而对于对比极性不敏感,因此其响应为相反极性简单细胞的响应之和:

$$C_0 = [S_{\text{ld},0} - S_{\text{dl},0}]^+ + [S_{\text{dl},0} - S_{\text{ld},0}]^+ = |S_{\text{ld},0} - S_{\text{dl},0}| \quad (13)$$

对所有方位的复杂细胞响应求和得到对应尺度的图像边界轮廓:

$$C^{(s)} = \sum_{\theta} C_0 \quad (14)$$

其中上标 s 表示对应的尺度参数,最后,对所有尺度的处理结果求和就得到最终的多尺度边缘输出:

$$C = \sum_s C^{(s)} \quad (15)$$

2 数学分析

这里从数学角度说明主导拮抗抑制机制的引入可以自适应地抑制噪声。假设 I 是具有均匀灰度的输入图像,被加性高斯噪声污染, X 是 LGN 处理后的对比度信息输出,可近似为高斯差分滤波器对输入图像 I 的滤波结果。由于高斯差分滤波是线性运算,因此 X 也是一个高斯过程^[11]。在图像中的每一个位置, X 都可以表述为一个概率密度函数 $f_x(x)$ 为高斯分布 $g^o(x)$ 的随机变量 x ,那么主导拮抗抑制机制的相互作用过程可以写成

$$y = x_{\text{out}} - \mu x_{\text{in}} = [x]^+ - \mu[-x]^+ = \begin{cases} x & \text{if } x \geq 0 \\ \mu x & \text{if } x < 0 \end{cases} \quad (16)$$

根据概率密度函数的基本变换公式得到 y 的概率密度函数为

$$f_y(y) = \begin{cases} f_x(y) = g^o(y) & \text{if } y \geq 0 \\ \frac{1}{\mu} f_x(\frac{1}{\mu}y) = g^{\text{ou}}(y) & \text{if } y < 0 \end{cases} \quad (17)$$

下一步处理就是 y 和简单细胞子域的有向感受野进行卷积,实现空间邻域内的加权平均。在各态历经的假设前提下,均匀区域的空间平均对应于每一个位置单元的均值。那么, y 的均值为

$$\begin{aligned} E\{y\} &= \int_{-\infty}^{\infty} y f_y(y) dy = \int_{-\infty}^0 y g^{\text{ou}}(y) dy + \int_0^{\infty} y g^o(y) dy \\ &= -\frac{1}{\sqrt{2\pi}} \sigma \mu + \frac{1}{\sqrt{2\pi}} \sigma = -\frac{1}{\sqrt{2\pi}} \sigma (\mu - 1) \end{aligned} \quad (18)$$

由上式可以看出,当 $\mu > 1$ 时, y 的均值为负,且均值和主导拮抗抑制参数 $\mu - 1$ 以及噪声水平 σ 成正比。以上分析表明主导拮抗抑制机制对于噪声的抑制程度依赖于噪声的水平,当噪声比较大时,在 $\mu > 1$ 的情况下均值就更小,也就是负值更大,导致后续的半波整流过程处理得到的正活性更低。这意味着噪声越大的地方,抑制就越强,体现了对噪声的自适应抑制。

噪声的抑制和图像细节的保留是一对矛盾,为了抑制噪声往往选取较大的细胞感受野参数,这通常会导致图像的边缘细节模糊化,甚至被遗漏;而选取较小的感受野又往往会使得去噪效果不理想。因此,本文将主导拮抗抑制拓展到多尺度处理,可以在去噪和边缘定位方面取得权衡,较单一尺度的处理具有更好的边缘检测性能。

3 实验及结果分析

3.1 人工合成图像测试

首先对人工图像进行了仿真实验,对主导拮抗抑制、子域非线性整合以及多尺度处理在抑制噪声和边缘定位方面的作用进行了分析。图2(a)所示为一幅被加性高斯噪声污染的人工合成图像,图2(b)为子域线性整合的边缘检测结果,图2(c)为基于主导拮抗抑制的,子域线性整合的仿真结果,灰度越深表示细胞活性越强,和图2(b)进行比较,可以看出主导拮抗抑制具有很强的抑噪作用。图2(d)、3(e)分别为子域非线性整合、基于主导拮抗抑制的子域非线性整合的边缘检测结果,同样,通过对比这两个结果

发现强抑制具有很好的抗噪性能。对比图 2(b) 和(d), 以及图 2(c) 和(e) 发现非线性整合起到了锐化轮廓响应的作用, 这和前面的理论分析是一致的。因此, 在对多尺度边缘检测的仿真实验中采用基于主导拮抗抑制的子域非线性整合, 图 2(f)~(h) 分别为小尺度、大尺度和多尺度的边缘检测结果, 可见小尺度边缘检测能提取灰度发生的细变化, 边缘定位准确, 但对噪声非常敏感; 而大尺度的抑噪能力好, 能检测图像灰度的粗变化, 但边缘定位不准, 而且可能会导致一些小尺寸的物体轮廓被忽略, 比如图 2(g) 中的小物体轮廓模糊不清。通过对不同尺度的边缘检测结果融合, 可以取长补短, 既能得到较为准确的边界轮廓, 又可以抑制噪声, 如图 2(h) 所示。

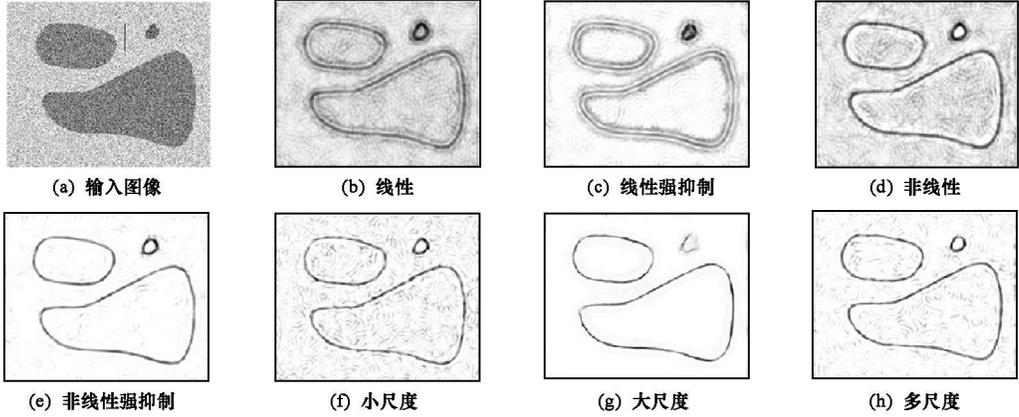


图 2 合成图像实验结果

Fig. 2 Experimental results of synthetic image

3.2 真实图像测试

为进一步验证模型的有效性, 本文对真实图像进行了仿真, 并对其性能进行了定量分析。图像来源于南佛罗里达大学(USF)提供的图像数据库^[12], 包含“objects”和“aerial”两类图像及每幅图像的边缘真值图。真值图为由人工绘制的三值边缘图, 黑色为边缘像素, 白色为非边缘像素, 灰色为不确定像素, 不予考虑^[12]。图 3 为对其中一幅图像的仿真结果, 分别对简单细胞子域线性整合、非线性整合、基于主导拮抗抑制的子域非线性整合和多尺度的情况进行了对比实验, 由实验结果可以看到子域非线性整合可以锐化边缘, 强抑制可以抑制噪声, 多尺度处理的边缘检测效果最好。

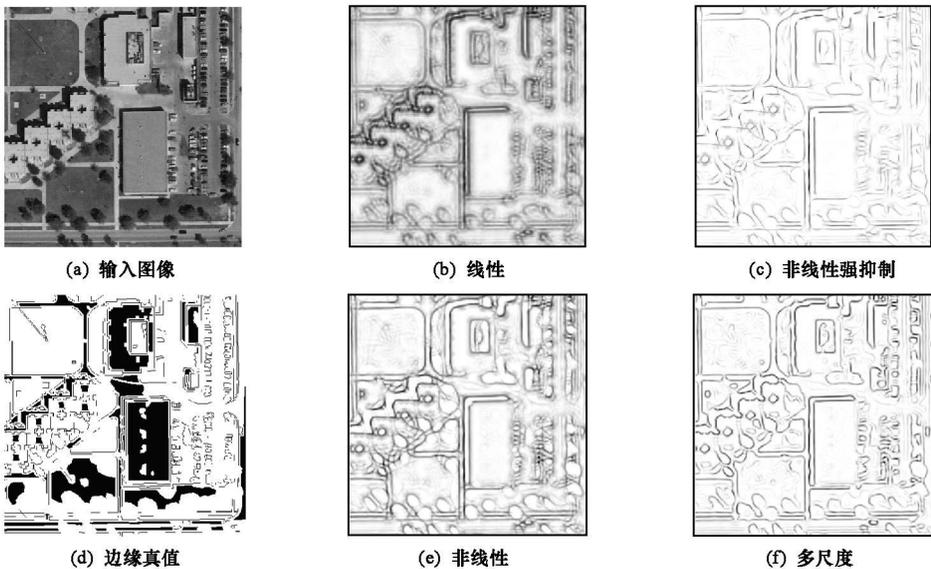


图 3 真实图像实验结果

Fig. 3 Experimental results of real image

由于生成的边缘图为连续的细胞活性图, 而真值图为二值图(灰色区域不考虑), 为了定量比较边缘

检测性能,每个边缘图看作一个二值分类器,对于给定阈值,响应活性大于阈值的像素归为边缘,小于阈值的像素为非边缘。这样,每一个阈值对应的二值边缘图同真值图比较就得到一组命中率TP和误警率FP,通过改变阈值就可以得到一条受试者工作特性曲线(ROC),曲线下的面积(AUC)反应了分类器的性能,AUC越大表示边缘检测性能越好。

对来自USF图像数据库的10幅图像进行了测试,测试结果见表1。由表1可知,对所有测试图像的边缘检测,基于主导拮抗抑制的多尺度处理方法表现出最好的性能,AUC最大,其次是单一尺度的非线性强抑制、非线性和线性的情况,表明简单细胞子域的非线性整合、拮抗通道的强抑制和多尺度融合对于边缘检测的性能的改善,同人工图像的测试结果相符。而且对于“objects”和“aerial”两类图像的测试结果是一致的,说明得到的结论并不受限于图像类别。

表1 图像测试结果(AUC)

Tab. 1 Images test results (AUC)

测试图像	线性整合	非线性整合	非线性强抑制	多尺度处理
101	0.5628	0.6215	0.6302	0.6382
103	0.6630	0.7056	0.7142	0.7271
131	0.6678	0.7131	0.7211	0.7348
133	0.7364	0.7772	0.7896	0.8060
36	0.7215	0.7506	0.7587	0.7762
buildings	0.7571	0.7860	0.7952	0.8168
largebuilding	0.6586	0.6909	0.7091	0.7278
pitcher	0.6622	0.6995	0.7179	0.7370
school	0.6765	0.7249	0.7393	0.7584
series	0.6751	0.6944	0.7163	0.7396

4 结论

本文从视觉生理学的角度出发,提出一种基于主导拮抗抑制的多尺度边缘检测方法。主导拮抗抑制机制的引入可以自适应的抑制噪声,鲁棒地提取图像对比度信息,多尺度融合在一定程度上解决了抑噪和边界定位之间的矛盾。模型具有神经生理学基础,可以作为视觉处理的早期阶段的模型,为更高级的视觉认知过程提供前端输入,且该方法为单纯的前向处理,结构简单,可操作性强,在机器视觉和仿生学领域具有广阔的应用前景。然而,模型没有考虑双极细胞的合作组群,存在边缘不连续的问题,这将是后续研究的方向之一。

参考文献:

- [1] Zhang Z, Ma S, Liu H, et al. An Edge Detection Approach Based on Directional Wavelet Transform [J]. Computers and Mathematics with Applications, 2009, 57: 1265-1271.
- [2] Basturk A, Gunay E. Efficient Edge Detection in Digital Images Using a Cellular Neural Network Optimized by Differential Evolution Algorithm [J]. Expert Systems with Applications, 2009, 36: 2645-2650.
- [3] Yu J, Wang Y, Shen Y. Noise Reduction and Edge Detection Via Kernel Anisotropic Diffusion [J]. Pattern Recognition Letters, 2008, 29: 1496-1503.
- [4] Arandiga F, Cohen A, Donat R, et al. Edge Detection Insensitive to Changes of Illumination in the Image [J]. Image and Vision Computing, 2010, 28: 553-562.
- [5] Chaira T, Ray A K. A New Measure Using Intuitionistic Fuzzy Set Theory and Its Application to Edge Detection [J]. Applied Soft Computing, 2008, 8: 919-927.
- [6] Heggelund P. Receptive Field Organization of Simple Cells in Cat Striate Cortex [J]. Experimental Brain Research, 1981, 42: 89-98.
- [7] Hirsch J A, Alonso J M, Reid R C, et al. Synaptic Integration in Striate Cortical Simple Cells [J]. The Journal of Neuroscience, 1998, 18 (22): 9517-9528.
- [8] Hansen T, Neumann H. A Simple Cell Model with Dominating Opponent Inhibition for Robust Image Processing [J]. Neural Networks, 2004, 17: 647-662.
- [9] Grossberg S, Todorović D. Neural Dynamics of 1-D and 2-D Brightness Perception: A Unified Model of Classical and Recent Phenomena [J]. Perception & Psychophysics, 1988, 43: 241-277.
- [10] Neumann H, Pessoa L, Hansen T. Interaction of ON and OFF Pathways for Visual Contrast Measurement [J]. Biological Cybernetics, 1999, 81: 515-532.
- [11] Hansen T. A Neural Model of Early Vision: Contrast, Contours, Corners and Surfaces [D]. Ulm, 2003.
- [12] Bowyer K, Kranenburg C, Dougherty S. Edge Detector Evaluation Using Empirical ROC Curves [C]//Proceedings IEEE CVPR, 1999: 354-359.