

弱正则化边缘检测¹⁾

李文彪 潘士先

(北京航空航天大学 206 信箱 北京 100083)

摘要

提出一种新的边缘检测方法,称为弱正则化法。它包括图象的弱正则化重建(WRR)和边缘提取(EF)两级处理。WRR 的特点是在重建泛函中引入一个受控平滑性稳定子,使平滑性约束的强弱依图象各处边缘存在的可能性而调整。EF 主要是一个边缘修剪算法,它通过一个度量边缘局部几何结构合理性的代价函数的最小化实现最佳修剪。文中给出了实验结果。

关键词: 边缘检测, 正则化, 弱正则化, 受控平滑性稳定子, 边缘修剪。

1 引言

自从 Marr-Hildreth 边缘检测理论^[1]问世以来, 平滑-空间导数法在边缘检测的研究和应用中占了统治地位, 陆续出现了诸如 Canny^[2] 和沈俊^[3,4]边缘检测的理论和算法。在这类方法中, 图象平滑是通过某种意义上最佳的线性滤波实现的, 例如高斯平滑。线性平滑之所以吸引人是由于其简单和有效的抗噪性, 并且具有收放自如的尺度特性。但是, 线性平滑的一个固有问题是边缘定位误差或称边缘偏移^[2,5,6]。边缘偏移随滤波核尺度的增大而愈趋严重。优化滤波核的形式只能减小但不能消除定位误差。对于一定形式的滤波核, 其抗噪性能和定位精度的综合度量大致不变^[2], 这可以说是一种不确定性原理。边缘位移产生的原因常被归于台阶边缘形状的非理想^[5], 另一个重要的原因是当平滑跨越若干个边缘时它们的相互干扰。

边缘位移引起视觉处理的许多麻烦。众多研究者提出了许多对策, 特别是 Perona 和 Malik 的非均匀弥散法^[7]和 Saint-Marc 等的自适应平滑^[8]。这两种方法都通过阻抑跨越边缘的平滑而获得良好的定位精度, 但其算法不能自行收敛而需外部监控。

为了在获得良好抗噪性的同时保证定位精度, 本文提出一种边缘检测方法。这种方法是依照正则化理论导出的, 称之为弱正则化(WR)边缘检测。它由两级处理组成。第一级是图象的弱正则化重建(WRR), 第二级是边缘提取(EF)。

WRR 的基本策略。依照 Poggio 等的初级视觉的正则化理论^[9], 为使边缘检测问题正则化, 须由已给图象数据重建平滑的图象强度函数。他们在其重建泛函中使用了定常的正则化参数 $\lambda^{[6]}$, 这意味着全局一致的平滑约束, 结果使平滑重建基本上等价于线性平

1) 国家教委博士基金资助。
本文于 1994 年 5 月 10 日收到

滑,由此产生边缘偏移。在 WRR 中,设 $e(x, y)$ 为图象平面上 (x, y) 处边缘出现概率的一个估计, $0 \leq e(x, y) < 1$ 。令正则化参数为 $(l - e)\lambda$ 。于是各处平滑性约束的强弱是依 e 值调整的,边缘存在的可能性越大,平滑性约束越松。这就使图象中潜在的边缘不致受到过度的平滑,从而提高边缘定位的精度。EF 的主要特点是一个优化边缘局域几何结构的修剪算法。整个算法自行收敛,所有计算均局域化且可并行实现,特别是 WRR 可用局域连接的模拟网络实现。

2 弱正则化边缘检测

2.1 弱正则化重建

令 $\Omega = \{(x, y) | (x, y) \in R^2\} \subset R^2$ 为图象平面。设 $L_0 \subset \Omega$ 是 Ω 上的一个等间隔采样网格, $L_0 = \{(i, j) | i, j \in I, 0 \leq i < r, 0 \leq j < c\}$, 其中 I 为整数集合。令 $d = \{d_{i,j} | (i, j) \in L_0\}$ 为 L_0 上的图象数据。令 $f: \Omega \rightarrow [0, I_m] \in R^+$ 为基于 d 的正则化重建。记 f 在 L_0 上的样本为 $\{f_{i,j}\}$ 。引入函数 $e: \Omega \rightarrow [0, 1] \in R^+$ 。 $e(x, y)$ 之值表示图象在 (x, y) 处出现边缘可能性的大小。其值越近于 1, 此可能性越大, 但不允许 e 等于 1。

2.1.1 弱正则化泛函

WRR 表示为下列能量泛函的最小化解:

$$E_d(f, e) = \lambda D(f, d) + \beta P(f, e) + \alpha U(e). \quad (1)$$

其中 $D(f, d)$ 为距离泛函, 依常规取为

$$D(f, d) = \sum_{(i,j) \in L_0} (f_{i,j} - d_{i,j})^2. \quad (2)$$

$P(f, e)$ 称为受控平滑性稳定子, $U(e)$ 为边缘罚泛函; λ, β 和 α 为权系数。

由于实际成象系统都具有有限带宽, 无噪图象应是处处平滑的。因此, 重建 f 应具有相当高阶的连续导数。但就台阶边缘检测而言, 只限制一阶导数在一定程度上是合理的。这样做可能使重建的平滑性有所降低, 但可使计算大为简化。如此, 取

$$P(f, e) = \iint_{\Omega} (1 - e)(\nabla f)^2 dx dy, \quad (3)$$

式中梯度幅值 $(\nabla f)^2 = f_x^2 + f_y^2$ 给出 f 在 (x, y) 处的最大变化率。这一稳定子意味着平滑性约束将依 e 值的大小而松紧。但是, 不允许 $e(x, y) = 1$, 因为这将容许 $(\nabla f)^2$ 变为无限大—— f 出现间断, 式(3)形式的稳定子令人想起 Terzopoulos^[10] 的受控连续性稳定子, 不过其中 e 是取值为“0”或“1”的二值函数。

如果式(1)右方没有第三项, $E_d(f, e)$ 的最小化将产生无意义的解 $f_{ij} = d_{ij}, (i, j) \in L_0$ 和 $e(x, y) = 1, (x, y) \in \Omega$ 。所以要加入第三项来对 $e \neq 0$ 施于惩罚, 以抑制过多边缘的产生。采用如下的边缘罚泛函:

$$U(e) = \iint_{\Omega} J(e) dx dy, \quad (4)$$

式中 J 称为边缘罚函数。函数 J 的选择是一个关键。为了保证泛函 $U(e)$ 的一阶和二

阶变分存在,设 $J'(t)$ 和 $J''(t)$ 在 $t \in (0,1)$ 中存在且连续。 J 应具有下列性质: $J'(t) > 0$ 和 $J''(t) > 0$, $t \in (0,1)$ ——罚函数及其导数单调增以抑制过大 e 值的产生; $J(0^+) = \lim_{t \rightarrow 0^+} J(t) = 0$, 以便最大限度地鼓励图象均匀区域上的平滑; $J(1^-) = \lim_{t \rightarrow 1^-} J(t) = 1$, 即罚函数当 $e \rightarrow 1^-$ 时有界; $J'(1^-) = \lim_{t \rightarrow 1^-} J'(t) = +\infty$, 即当 e 增加一个无穷小量达到 1 时, 应使罚值具有无限大的增长率以迫使它小于 1, 从而保证重建是平滑的。

满足上列要求的函数不是唯一的, 取

$$J(t) = (1 - \sqrt{1-t})^2, \quad t \in (0,1). \quad (5)$$

容易验证, 它满足上列所有要求。由式(1)–(4), 取 $\beta = 1$, 有

$$E_d(f, e) = \lambda \sum_{(i,j) \in L_0} (f_{ij} - d_{ij})^2 + \iint_{\Omega} (1-e)(\nabla f)^2 dx dy + \iint_{\Omega} \alpha J(e) dx dy. \quad (6)$$

2.1.2 重建泛函的简化

泛函 $E_d(f, e)$ 具有两个函数变量 f 和 e , 其最小化解 (f^*, e^*) 满足

$$E_d(f^*, e^*) = \min_{f,e} E_d(f, e).$$

但显然有 $\min_{f,e} E_d(f, e) = \min_f \{ \lambda D(f, d) + \min_e [P(f, e) + U(e)] \}$ 。故可先解下列最小化问题:

$$\begin{aligned} \min_e [P(f, e) + U(e)] &= \min_e \iint_{\Omega} \{(1-e)(\nabla f)^2 + \alpha J(e)\} dx dy \\ &= \iint_{\Omega} \alpha \cdot \min_e \{(1-e)(\nabla f/\sqrt{\alpha})^2 + J(e)\} dx dy. \end{aligned}$$

若令 $\nabla f/\sqrt{\alpha} = u$, 则问题转化为求 $\inf_{0 \leq e \leq 1} [(1-e)u^2 + J(e)]$ 。对此可导出如下结果: 设变量 u 的二次函数族 $g(u, e) = (1-e)u^2 + J(e)$, 其中 $u \in (-\infty, +\infty)$, 参数 $e \in [0, 1]$, 函数 J 满足前述所有性质, 则有 (i) $\inf_{0 \leq e \leq 1} g(u, e)$ 存在且在唯一的点 e^* 处达到, 其中

$$e^* = \begin{cases} (J')^{-1}(u^2) & u^2 \neq 0, \\ 0 & u^2 = 0, \end{cases}$$

且有 $g(u, 0) \geq g(u, e^*) < g(u, 1^-)$, 当且仅当 $u = 0$ 时等式成立; (ii) 令 $\varphi(u) = g(u, e^*)$, 则 φ' 在 $(-\infty, +\infty)$ 上存在且连续。

由上述结果可得

$$\min_e \iint_{\Omega} \{(1-e)(\nabla f)^2 + \alpha J(e)\} dx dy = \iint_{\Omega} h(f_x^2 + f_y^2) dx dy. \quad (7)$$

式中

$$h(f_x^2 + f_y^2) = \alpha \left\{ \left[1 - q \left(\frac{f_x^2 + f_y^2}{\alpha} \right) \right] \cdot \frac{f_x^2 + f_y^2}{\alpha} + J \left[q \left(\frac{f_x^2 + f_y^2}{\alpha} \right) \right] \right\}, \quad (8)$$

q 是 J' 的反函数。由以上结果 (ii) 知, h 在 $(-\infty, +\infty)$ 上是连续可导的。令

$$F_d(f) = \lambda \cdot D(f, d) + \iint_{\Omega} h(f_x^2 + f_y^2) dx dy, \quad (9)$$

则双变量泛函 $E_d(f, \epsilon)$ 的最小化等价于单变量泛函 $F_d(f)$ 的最小化, 即

$$\min_{f, \epsilon} E_d(f, \epsilon) = \min_f F_d(f). \quad (10)$$

2.1.3 泛函最小化

由于 h 是非线性函数, $F_d(f)$ 非凸, 求全局极小要求复杂的计算, 故放弃全局优化而利用变分法导出欧拉方程, 然后用梯度下降法寻找最靠近初始数据的极小点。

为了推导欧拉方程, 先设 d 是 Ω 上的连续数据, 导出欧拉方程后再将它在 L_0 上离散化。这样, 可用变分法导出 $F_d(f)$ 的欧拉方程如下:

$$\lambda(f - d) - \frac{\partial}{\partial x} \left\{ f_x \left[1 - q \left(\frac{f_x^2 + f_y^2}{\alpha} \right) \right] \right\} - \frac{\partial}{\partial y} \left\{ f_y \left[1 - q \left(\frac{f_x^2 + f_y^2}{\alpha} \right) \right] \right\} = 0, \quad (x, y) \in \Omega, \quad (11)$$

令 $\partial\Omega$ 为 Ω 的边界并取绝热边界条件, 有

$$\left[1 - q \left(\frac{f_x^2 + f_y^2}{\alpha} \right) \right] \cdot \frac{\partial f(x, y)}{\partial n} = 0, \quad (x, y) \in \partial\Omega. \quad (12)$$

式中 n 为边界外法向。

求欧拉方程的闭合解是不现实的, 所以引入时间 t , 并令 $1 - q(t) = g(t)$, 于是式 (11), (12) 的解对应下列动力学系统的平衡状态:

$$\begin{aligned} \frac{\partial f(x, y, t)}{\partial t} &= \lambda [d(x, y) - f(x, y, t)] + \frac{\partial}{\partial x} \left[f_x g \left(\frac{f_x^2 + f_y^2}{\alpha} \right) \right] (x, y, t) \\ &\quad + \frac{\partial}{\partial y} \left[f_y g \left(\frac{f_x^2 + f_y^2}{\alpha} \right) \right] (x, y, t), \quad (x, y) \in \Omega, \quad t > 0; \end{aligned} \quad (13)$$

$$g \left(\frac{f_x^2 + f_y^2}{\alpha} \right) \frac{\partial}{\partial n} f(x, y, t) = 0, \quad (x, y) \in \partial\Omega, \quad t > 0. \quad (14)$$

一般说来, 初始条件可为任意状态, 但只要数据 d 有足够的可信度, 可取

$$f(x, y, 0) = d(x, y), \quad (x, y) \in \Omega. \quad (15)$$

现在来推导式(13), (14)在 L_0 上的离散近似。首先有 $[d(x, y) - f(x, y)]|_{(i,j)} = d_{ij} - f_{ij}$, $(i, j) \in L_0$ 。用如下有限差分近似偏导数:

$$\begin{aligned} \frac{\partial}{\partial x} \left[f_x g \left(\frac{f_x^2 + f_y^2}{\alpha} \right) \right]|_{(i,j)} &\approx \left[f_x g \left(\frac{f_x^2 + f_y^2}{\alpha} \right) \right]|_{(i-\frac{1}{2}, j)}^{(i+\frac{1}{2}, j)}, \\ \frac{\partial}{\partial y} \left[f_y g \left(\frac{f_x^2 + f_y^2}{\alpha} \right) \right]|_{(i,j)} &\approx \left[f_y g \left(\frac{f_x^2 + f_y^2}{\alpha} \right) \right]|_{(i, j-\frac{1}{2})}^{(i, j+\frac{1}{2})}; \end{aligned}$$

同时取

$$\begin{aligned} f_x|_{(i+\frac{1}{2}, j)} &\approx f_{i+1, j} - f_{i, j} \triangleq \nabla_S f_{i, j}, \quad f_x|_{(i-\frac{1}{2}, j)} \approx f_{i, j} - f_{i-1, j} \triangleq -\nabla_N f_{i, j}, \\ f_y|_{(i, j+\frac{1}{2})} &\approx f_{i, j+1} - f_{i, j} \triangleq \nabla_E f_{i, j}, \quad f_y|_{(i, j-\frac{1}{2})} \approx f_{i, j} - f_{i, j-1} \triangleq -\nabla_W f_{i, j}, \\ (\nabla f)^2|_{(i+\frac{1}{2}, j)} &\approx (f_{i+1, j} - f_{i, j})^2 = |\nabla_S f_{i, j}|^2, \quad (\nabla f)^2|_{(i-\frac{1}{2}, j)} \approx (f_{i-1, j} - f_{i, j})^2 = |\nabla_N f_{i, j}|^2, \\ (\nabla f)^2|_{(i, j+\frac{1}{2})} &\approx (f_{i, j+1} - f_{i, j})^2 = |\nabla_E f_{i, j}|^2, \quad (\nabla f)^2|_{(i, j-\frac{1}{2})} \approx (f_{i, j-1} - f_{i, j})^2 = |\nabla_W f_{i, j}|^2. \end{aligned}$$

于是对非边界象素得

$$\begin{aligned} \frac{\partial f_{i,j}}{\partial t} = & \lambda(d_{i,j} - f_{i,j}) + \nabla_s f_{i,j} g\left(\frac{|\nabla_s f_{i,j}|^2}{\alpha}\right) + \nabla_N f_{i,j} g\left(\frac{|\nabla_N f_{i,j}|^2}{\alpha}\right) \\ & + \nabla_E f_{i,j} g\left(\frac{|\nabla_E f_{i,j}|^2}{\alpha}\right) + \nabla_W f_{i,j} g\left(\frac{|\nabla_W f_{i,j}|^2}{\alpha}\right), \quad 0 < i < r-1, \quad 0 < j < c-1. \end{aligned} \quad (16)$$

对于边界象素,以上方程需按绝热边界条件稍作修改。例如,在顶点(0,0)处有

$$\frac{\partial f_{0,0}}{\partial t} = \lambda(d_{0,0} - f_{0,0}) + \nabla_s f_{0,0} g\left(\frac{|\nabla_s f_{0,0}|^2}{\alpha}\right) + \nabla_E f_{0,0} g\left(\frac{|\nabla_E f_{0,0}|^2}{\alpha}\right) \quad (17)$$

等。

2.1.4 模拟网络实现

方程式(16),(17)可用图1所示的模拟网络来实现。每一节点上连接着一个增益为

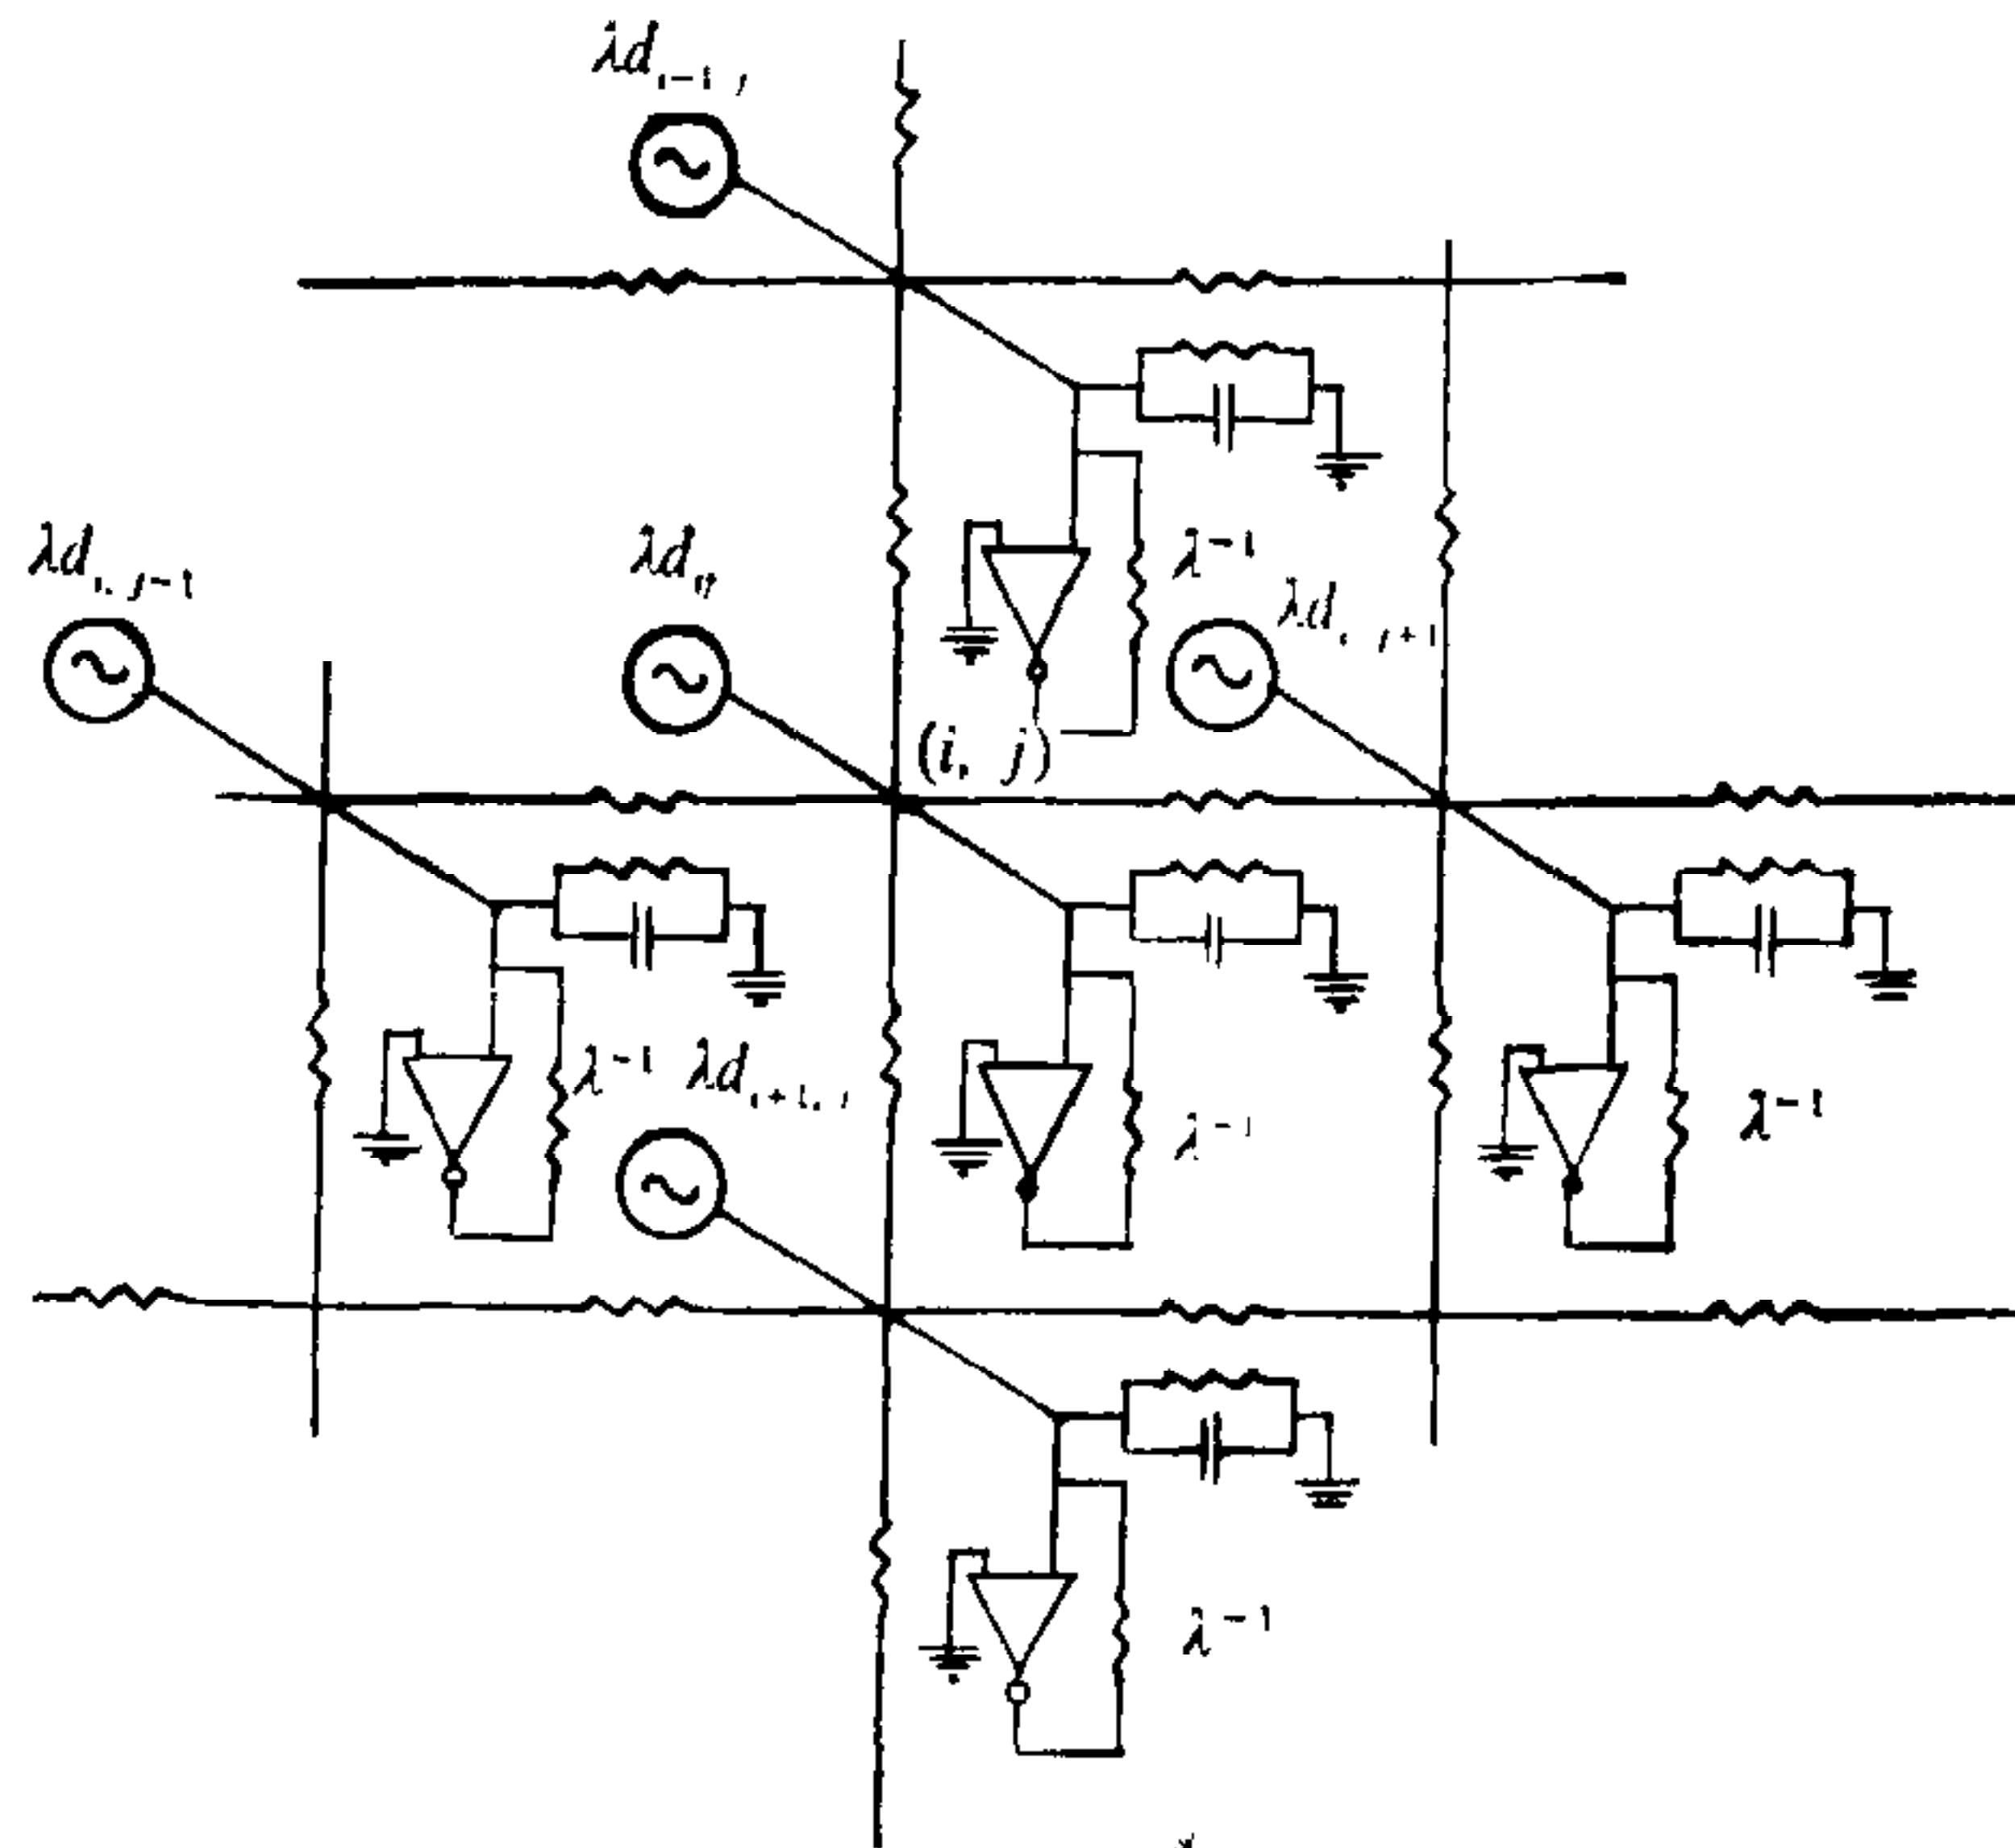


图1 实现 WRR 的模拟网络

1的运算放大器,其反相端经电阻 λ^{-1} 反馈到输入端。每个节点上还连接着一个RC网络和一个恒流源(λd)。前者规定网络的动力学行为,后者作为网络的外部输入。每个节点与其4个最邻近节点各通过一个压控电阻相联,节点(i,j)与(i+1,j)的连接电阻为 $R_{(i+\frac{1}{2},j)} = \left[g\left(\frac{|f_{i+1,j} - f_{i,j}|^2}{\alpha}\right)\right]^{-1}$ 。每个节点(i,j)上的电压代表 $f_{i,j}$ 。给定初始状态 d ,网络将自行收敛到一个稳定平衡态。这个状态被解释为重建图象。

2.2 边缘提取

边缘提取分为两步完成:先产生初始边缘图,然后加以修剪。

用简单的差分算子如 Roberts 算子计算重建图象 f 各点的梯度幅值 $|\nabla f_{i,j}|$ 和方向 $\varphi_{i,j}$ 。将 $\varphi_{i,j}$ 在 180° 的范围内均匀量化为4个方向 d_n , $n=1, 2, 3, 4$ 。设在(i,j)处 $\varphi_{i,j}=d_n$,用 (i_1, j_1) 和 (i_2, j_2) 分别表示它在 $+d_n$ 和 $-d_n$ 方向上的邻接点。仿照文献

[5,12], 定义 (i,j) 上存在边缘的概率为

$$C_{i,j} = \begin{cases} F(|\nabla f_{i,j}|), & |\nabla f_{i,j}| > 3, |\nabla f_{i,j}| - |\nabla f_{i_1,j_1}| > 1.0, \\ & |\nabla f_{i,j}| - |\nabla f_{i_2,j_2}| > 1.0, \\ 0, & \text{否则.} \end{cases} \quad (18)$$

式中 F 为一分段线性单调增的归一化函数, 例如对 256 个灰度级的情形,

$$F(x) = \begin{cases} \frac{x}{2\theta_0}, & x \leq 1.8\theta_0, \\ 0.9 + 0.1 \times (x - 1.8\theta_0)/(255 - 1.8\theta_0) & \text{否则.} \end{cases} \quad (19)$$

式中 θ_0 为对比度阈值。可以看出, 当 $|\nabla f_{i,j}| \geq \theta_0$ 时, $C_{i,j} \geq 0.5$ 。令初始边缘图为

$$e_{i,j}^0 = \begin{cases} 1, & C_{i,j} > 0, \\ 0, & C_{i,j} = 0, \end{cases} \quad (i,j) \in L_0. \quad (20)$$

不能通过 $C_{i,j}$ 的简单阈值(例如 0.5)操作获得良好的边缘图, 而需将阈值操作与改善边缘局部几何结构的修剪结合起来。一般说来, 勾画出图象特征的物理边缘应满足下述几何结构约束: 边缘一般应形成连续和较少分叉的细线^[13]。基此构造了一个最小代价修剪算法。从概念上说, 若删除某些小 C 值的边缘点造成边缘断裂, 则代价值将增大, 故代价最小化将使这些边缘点得以保留。反之, 若保留某些大 C 值的边缘点产生孤立边缘点或形成过多分叉, 则代价值也将增大, 故代价最小化将使它们被删除。定义边缘像素集合 $B_0 = \{l = (i,j) | e_l^0 = 1, l \in L_0\}$ 。对于任意的 $l \in B_0$, 依照 l 处梯度量化方向 $\varphi_l = d_1, d_2, d_3$ 和 d_4 , 分别考察图 2 中 (l_1, l_2, l_3) 和 (l_4, l_5, l_6) 各点上的边缘分布, 这些点各为 l 在 e_l^0 朝向两侧的邻接点, 这些点上的边缘分布影响着删除或保留 e_l^0 的决策。设 $S = \{e_l | l \in B_0\}$ 为修剪后的边缘集合, 要求 S 使下列代价函数最小化:

$$\begin{aligned} C(S) = & \sum_{l \in B_0} (1 - e_l) C_l + W_e \sum_{l \in B_0} e_l \\ & + W_s \sum_{l \in B_0} e_l [(1 - e_{l_1} - e_{l_2} - e_{l_3})^2 + (1 - e_{l_4} - e_{l_5} - e_{l_6})^2]. \end{aligned} \quad (21)$$

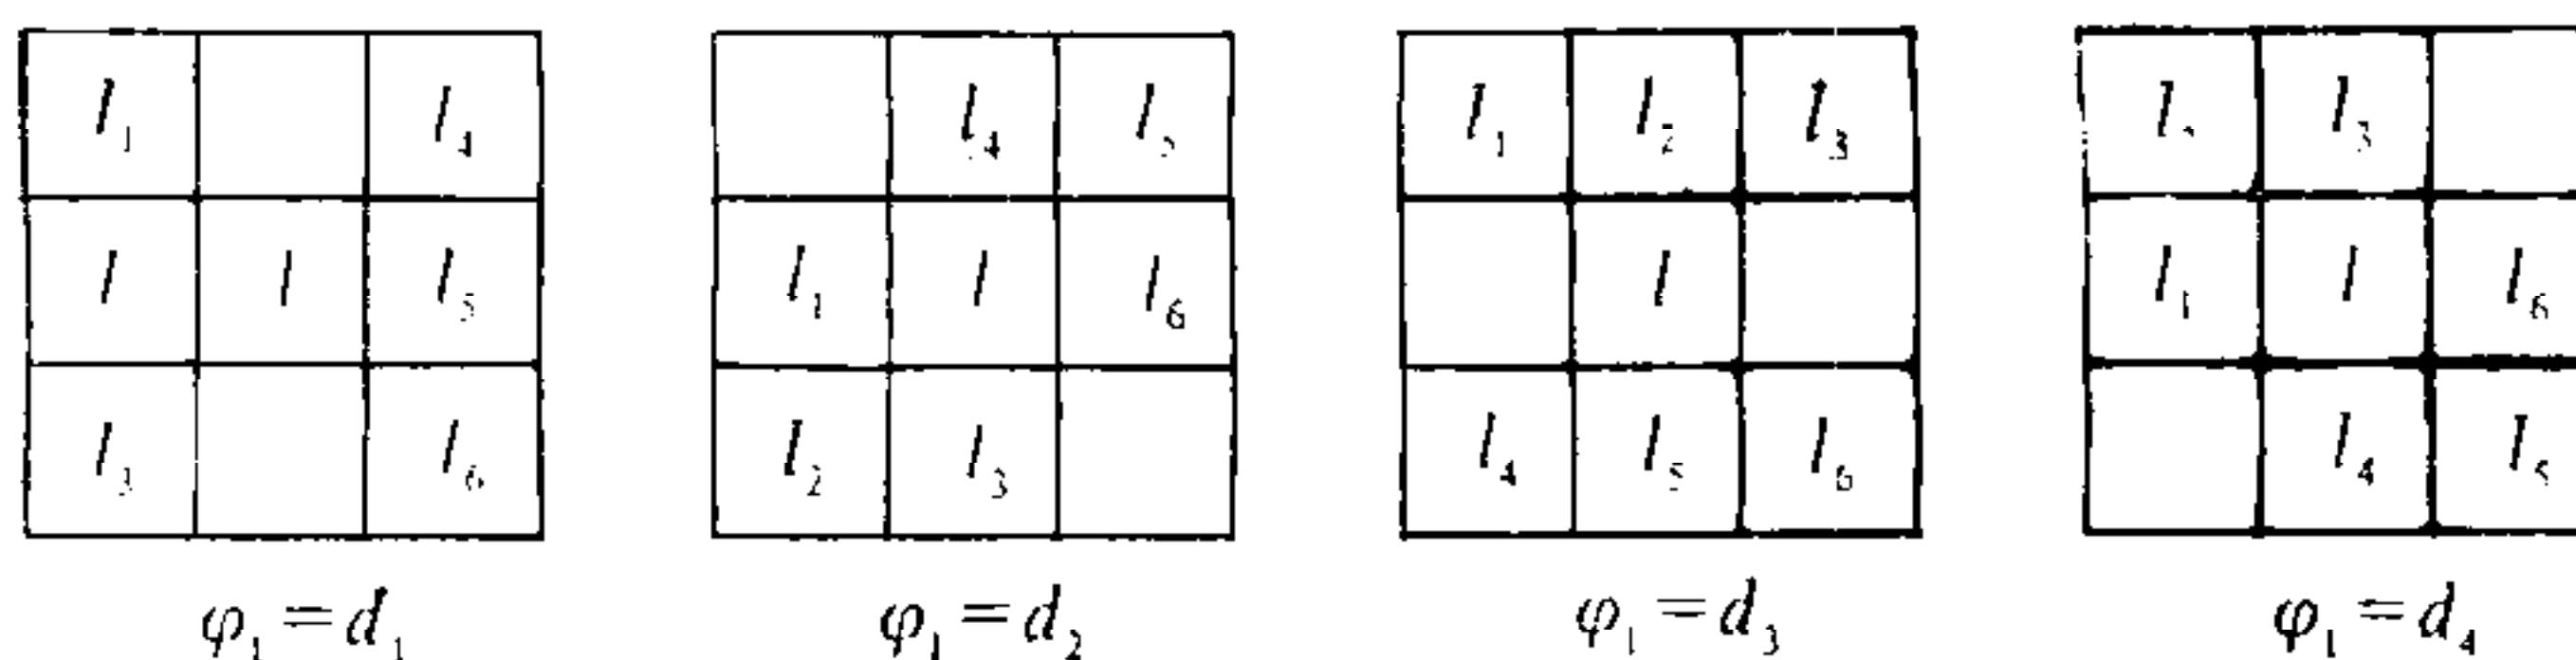


图 2 计算代价函数的邻域位置

式中若 $l_i \notin B_0, i = 1, 2, \dots, 6$, 则令 $e_{l_i} = 0$ 。 $C(S)$ 的第一项为修剪代价, 每从 B_0 中删除一个边缘点都需付出与其 C 值成比例的代价。第二项给每一边缘点一个罚值 W_e 以避免保留过多边缘。不考虑第三项时, l 处存在边缘的充要条件是 $C_l > W_e$, 故 W_e 的合理取值为 0.5。第三项用于惩罚边缘断裂和分叉以体现几何结构约束。

函数 $C(S)$ 的全局最小化需复杂的计算, 故采用下述简单的代价比较算法来求得一个极小值。令 $S = \{e_l^0 | l \in B_0\}$, 将 S 中一元素置零以产生新状态 S' 并计算 $\Delta C(S, S') =$

$C(S) - C(S')$. 若 $\Delta C(S, S') > 0$, 令 $S = S'$, 否则 $S = S$. 所有元素如此更新一遍后再进行第二遍, 直到 S 的状态不变为止. 因 e^0 本身已是边缘图的一个良好估计, 这样一个极小值是令人满意的. 由于 ΔC 的计算至多只需评价状态更新点及其 6 个邻接点上的点代价, 所以计算是局域的. 在实验中取 $W_s = 0.1, 10$ 次迭代即可收敛.

3 实验

实验是在 SGI-4D25 工作站上完成的. 采用 SOR 算法^[11] (松弛因子 $\omega = 1.0$) 对图 1 的网络作模拟计算. 在所有实验中, $\alpha = 80, \theta_0 = 8.0, \lambda$ 则有所不同. 但实验结果

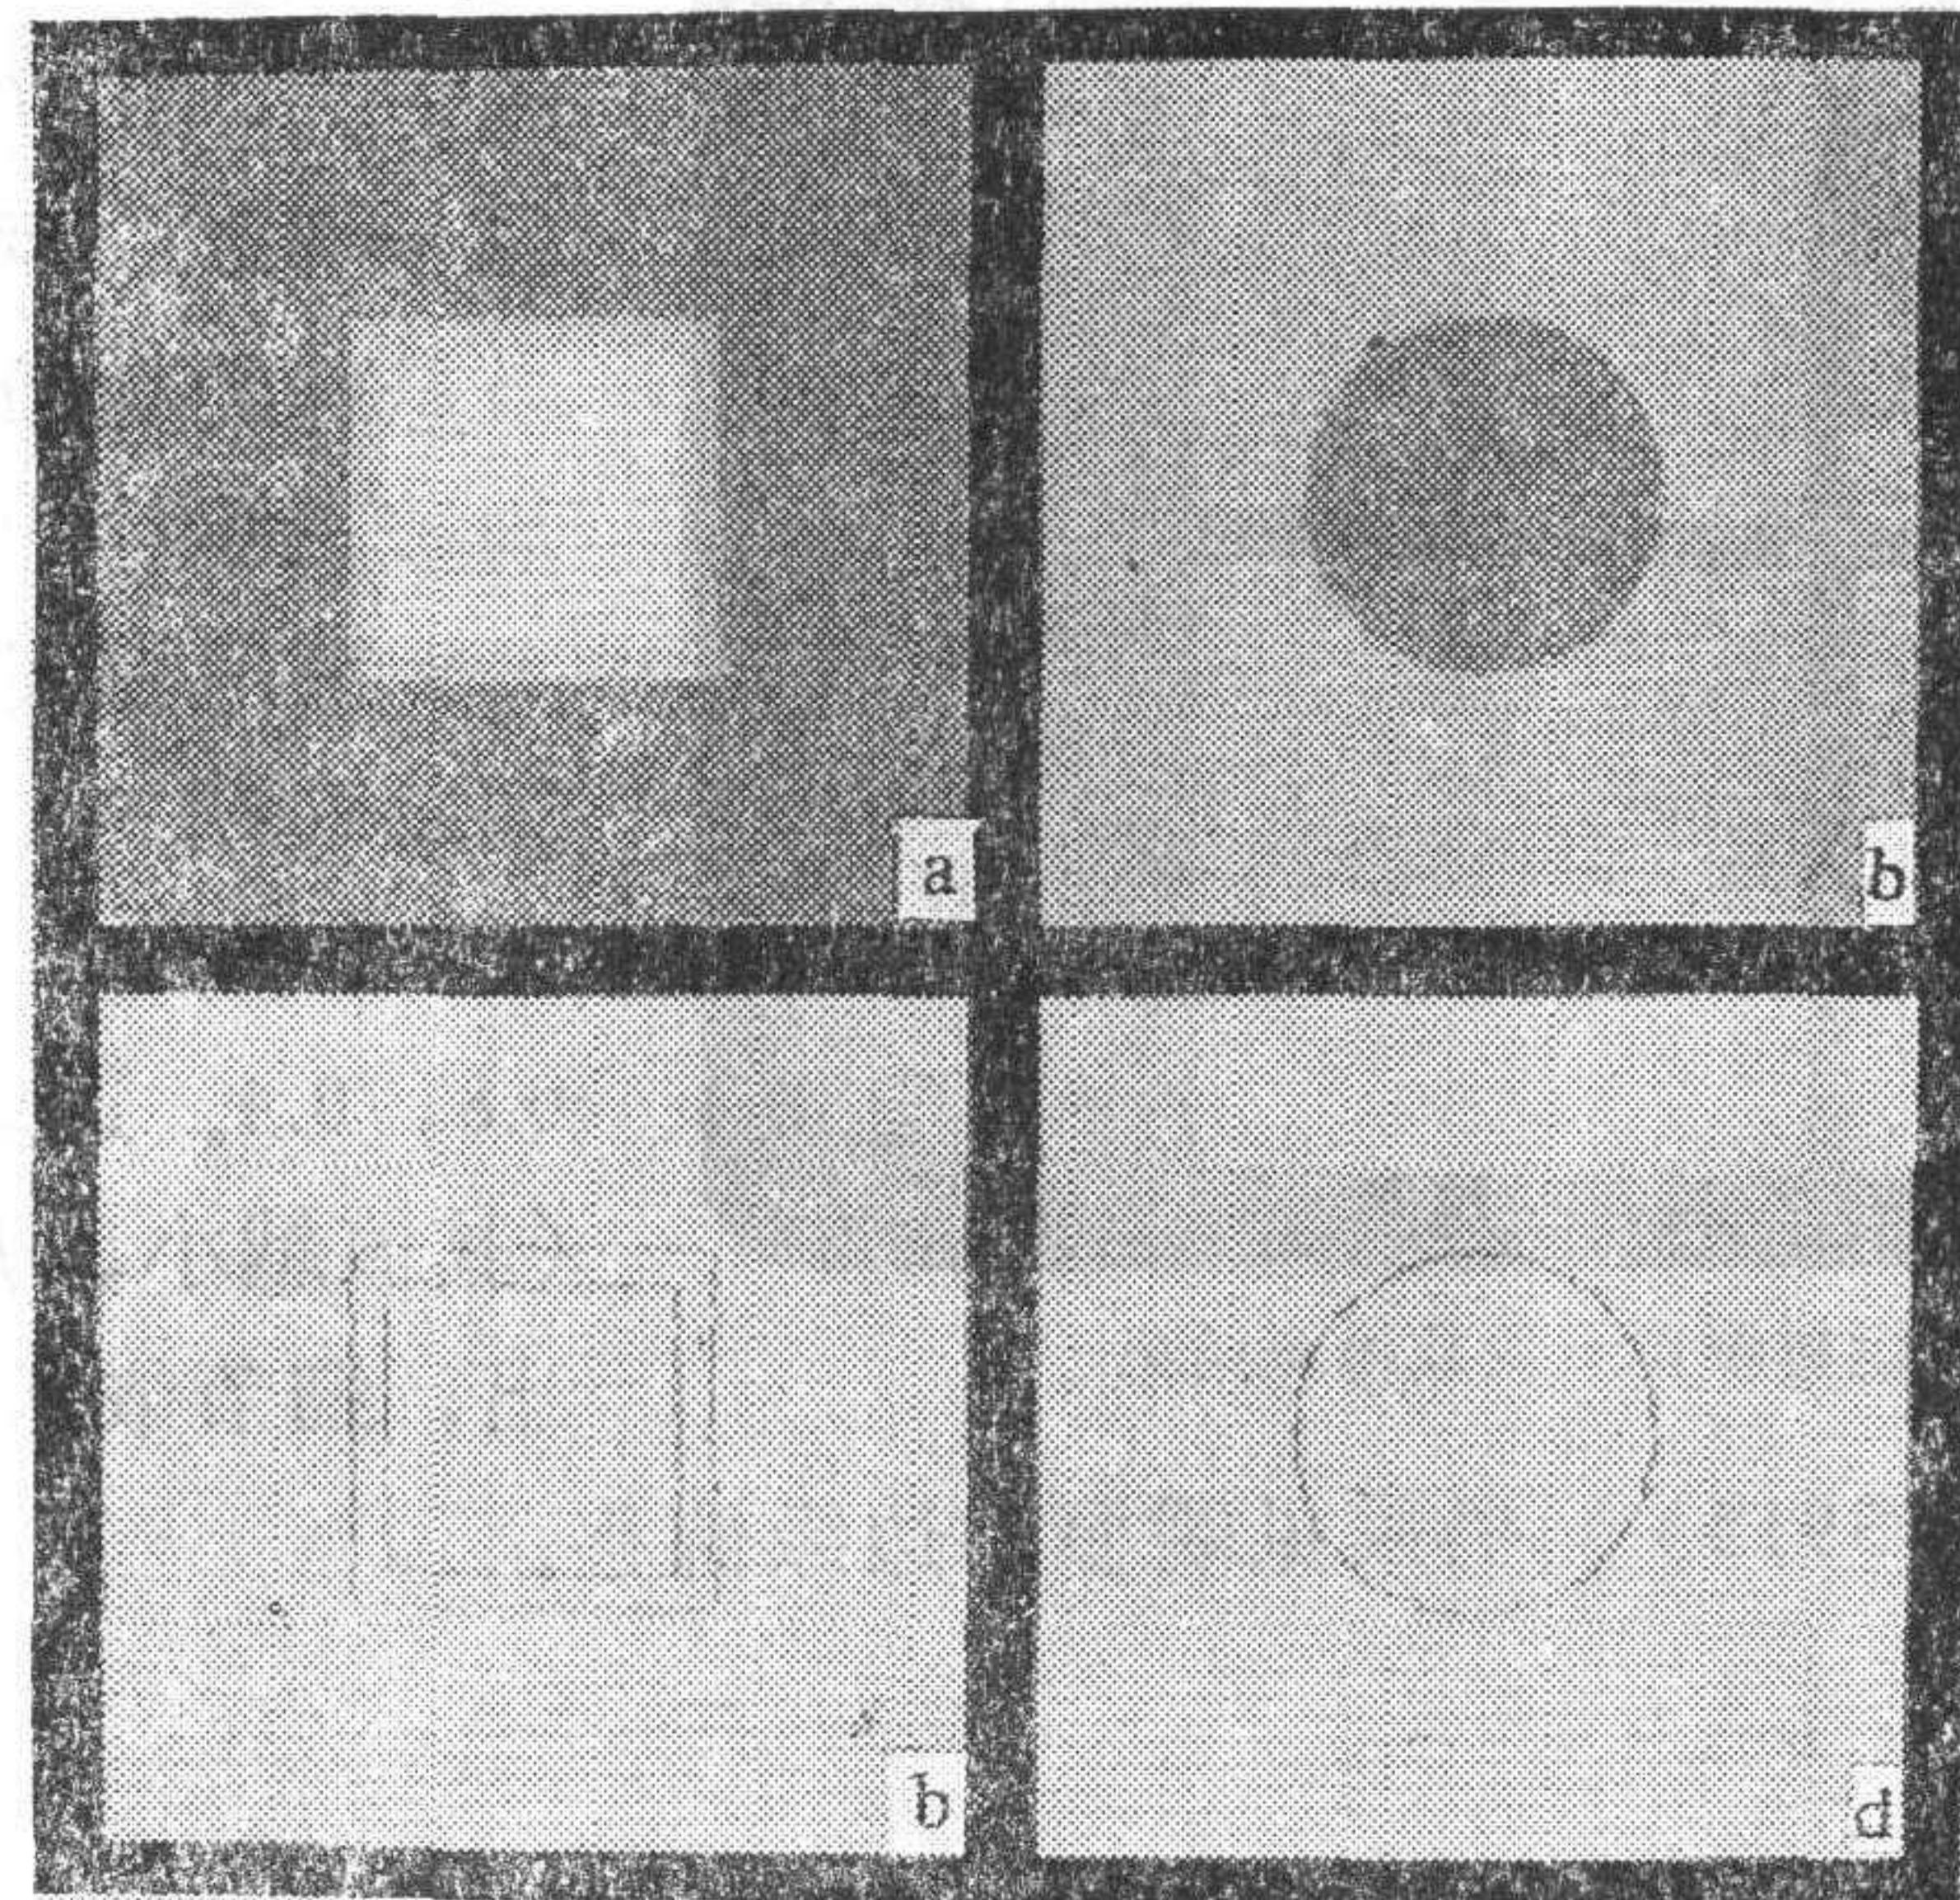


图 3 方台图象检测结果(左下角 b 图应为 c 图)

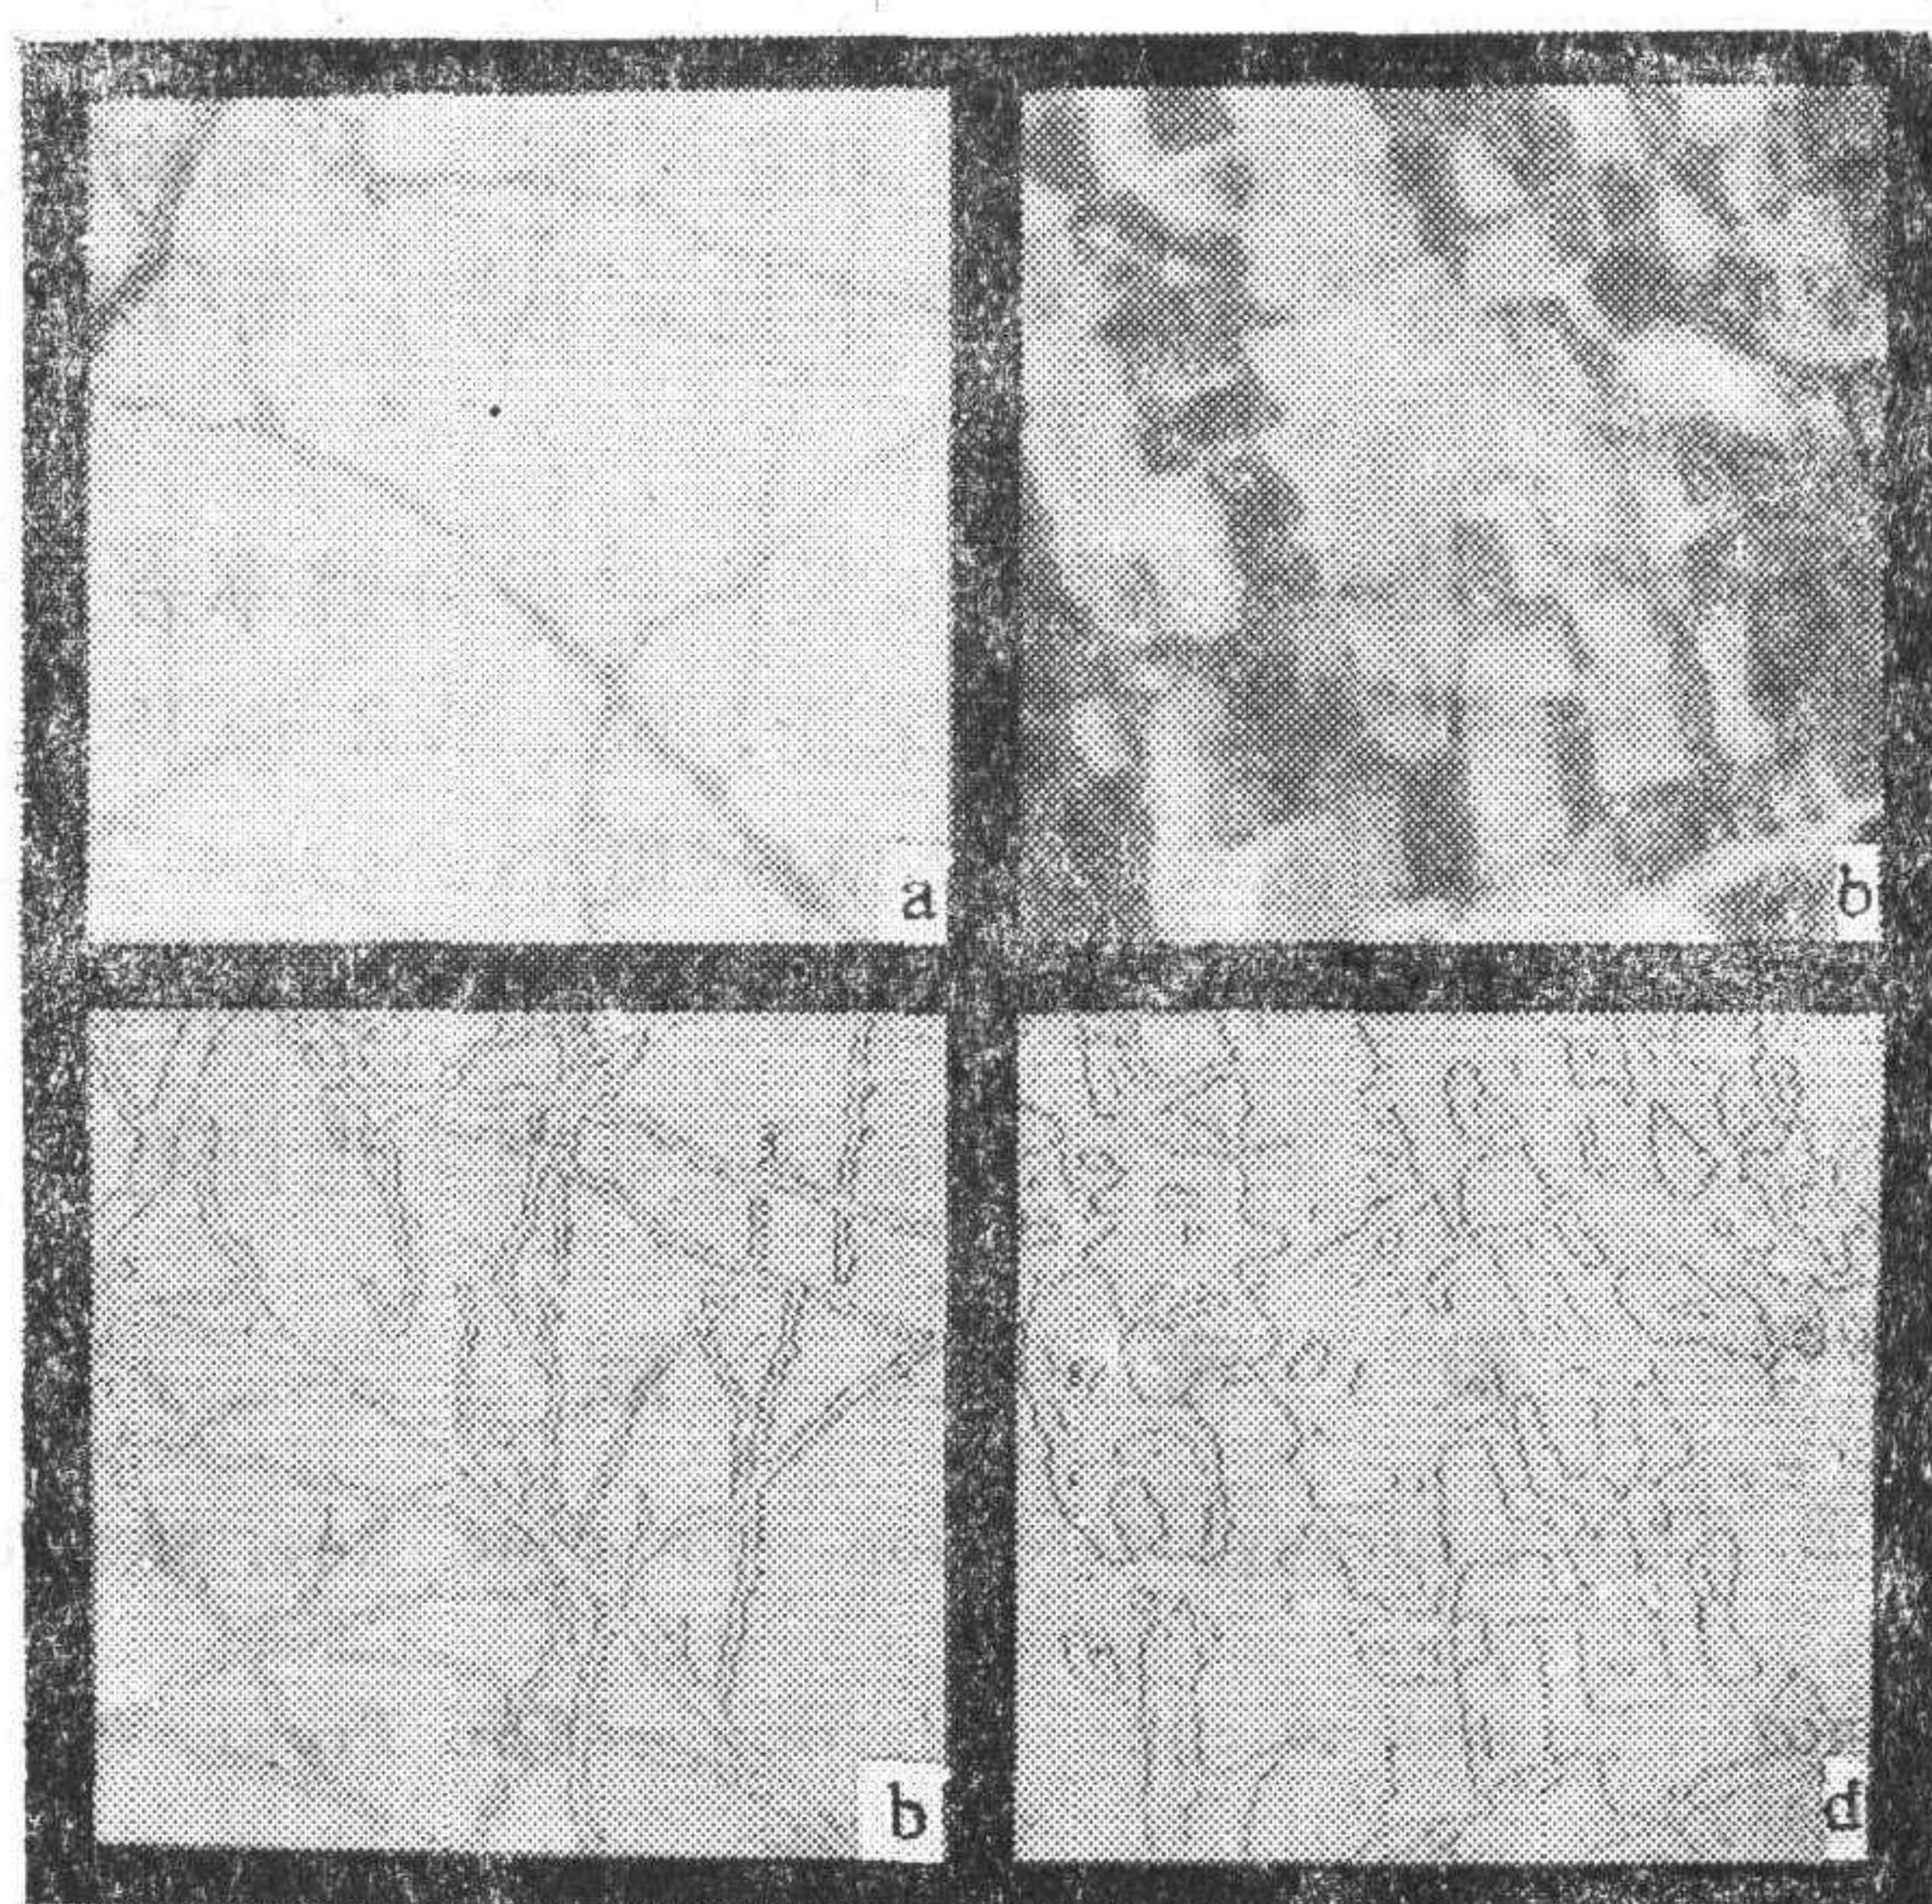


图 4 树枝图象及检测结果(左下角 b 图应为 c 图)

对这些参数的变化并不很敏感。

方台和圆盘图象。图 3(a)是一两层方台图象(先在灰度为 50 的背景上生成灰度各为 100 和 150 的两层方台,再用 5×5 的高斯模板将其模糊并加入 $N(0, 30^2)$ 的白噪声)。图 3(b)为圆盘图象。图 3(c,d)是检测结果($\lambda = 0.25$)。可以看出,方台和圆盘的边界被正确检出,特别是两层方台边界间的距离准确且诸顶角均被清晰地检出($\nabla^2 G$ 和 Canny 的 $\nabla \cdot G$ 算子通常难以检出顶角)。

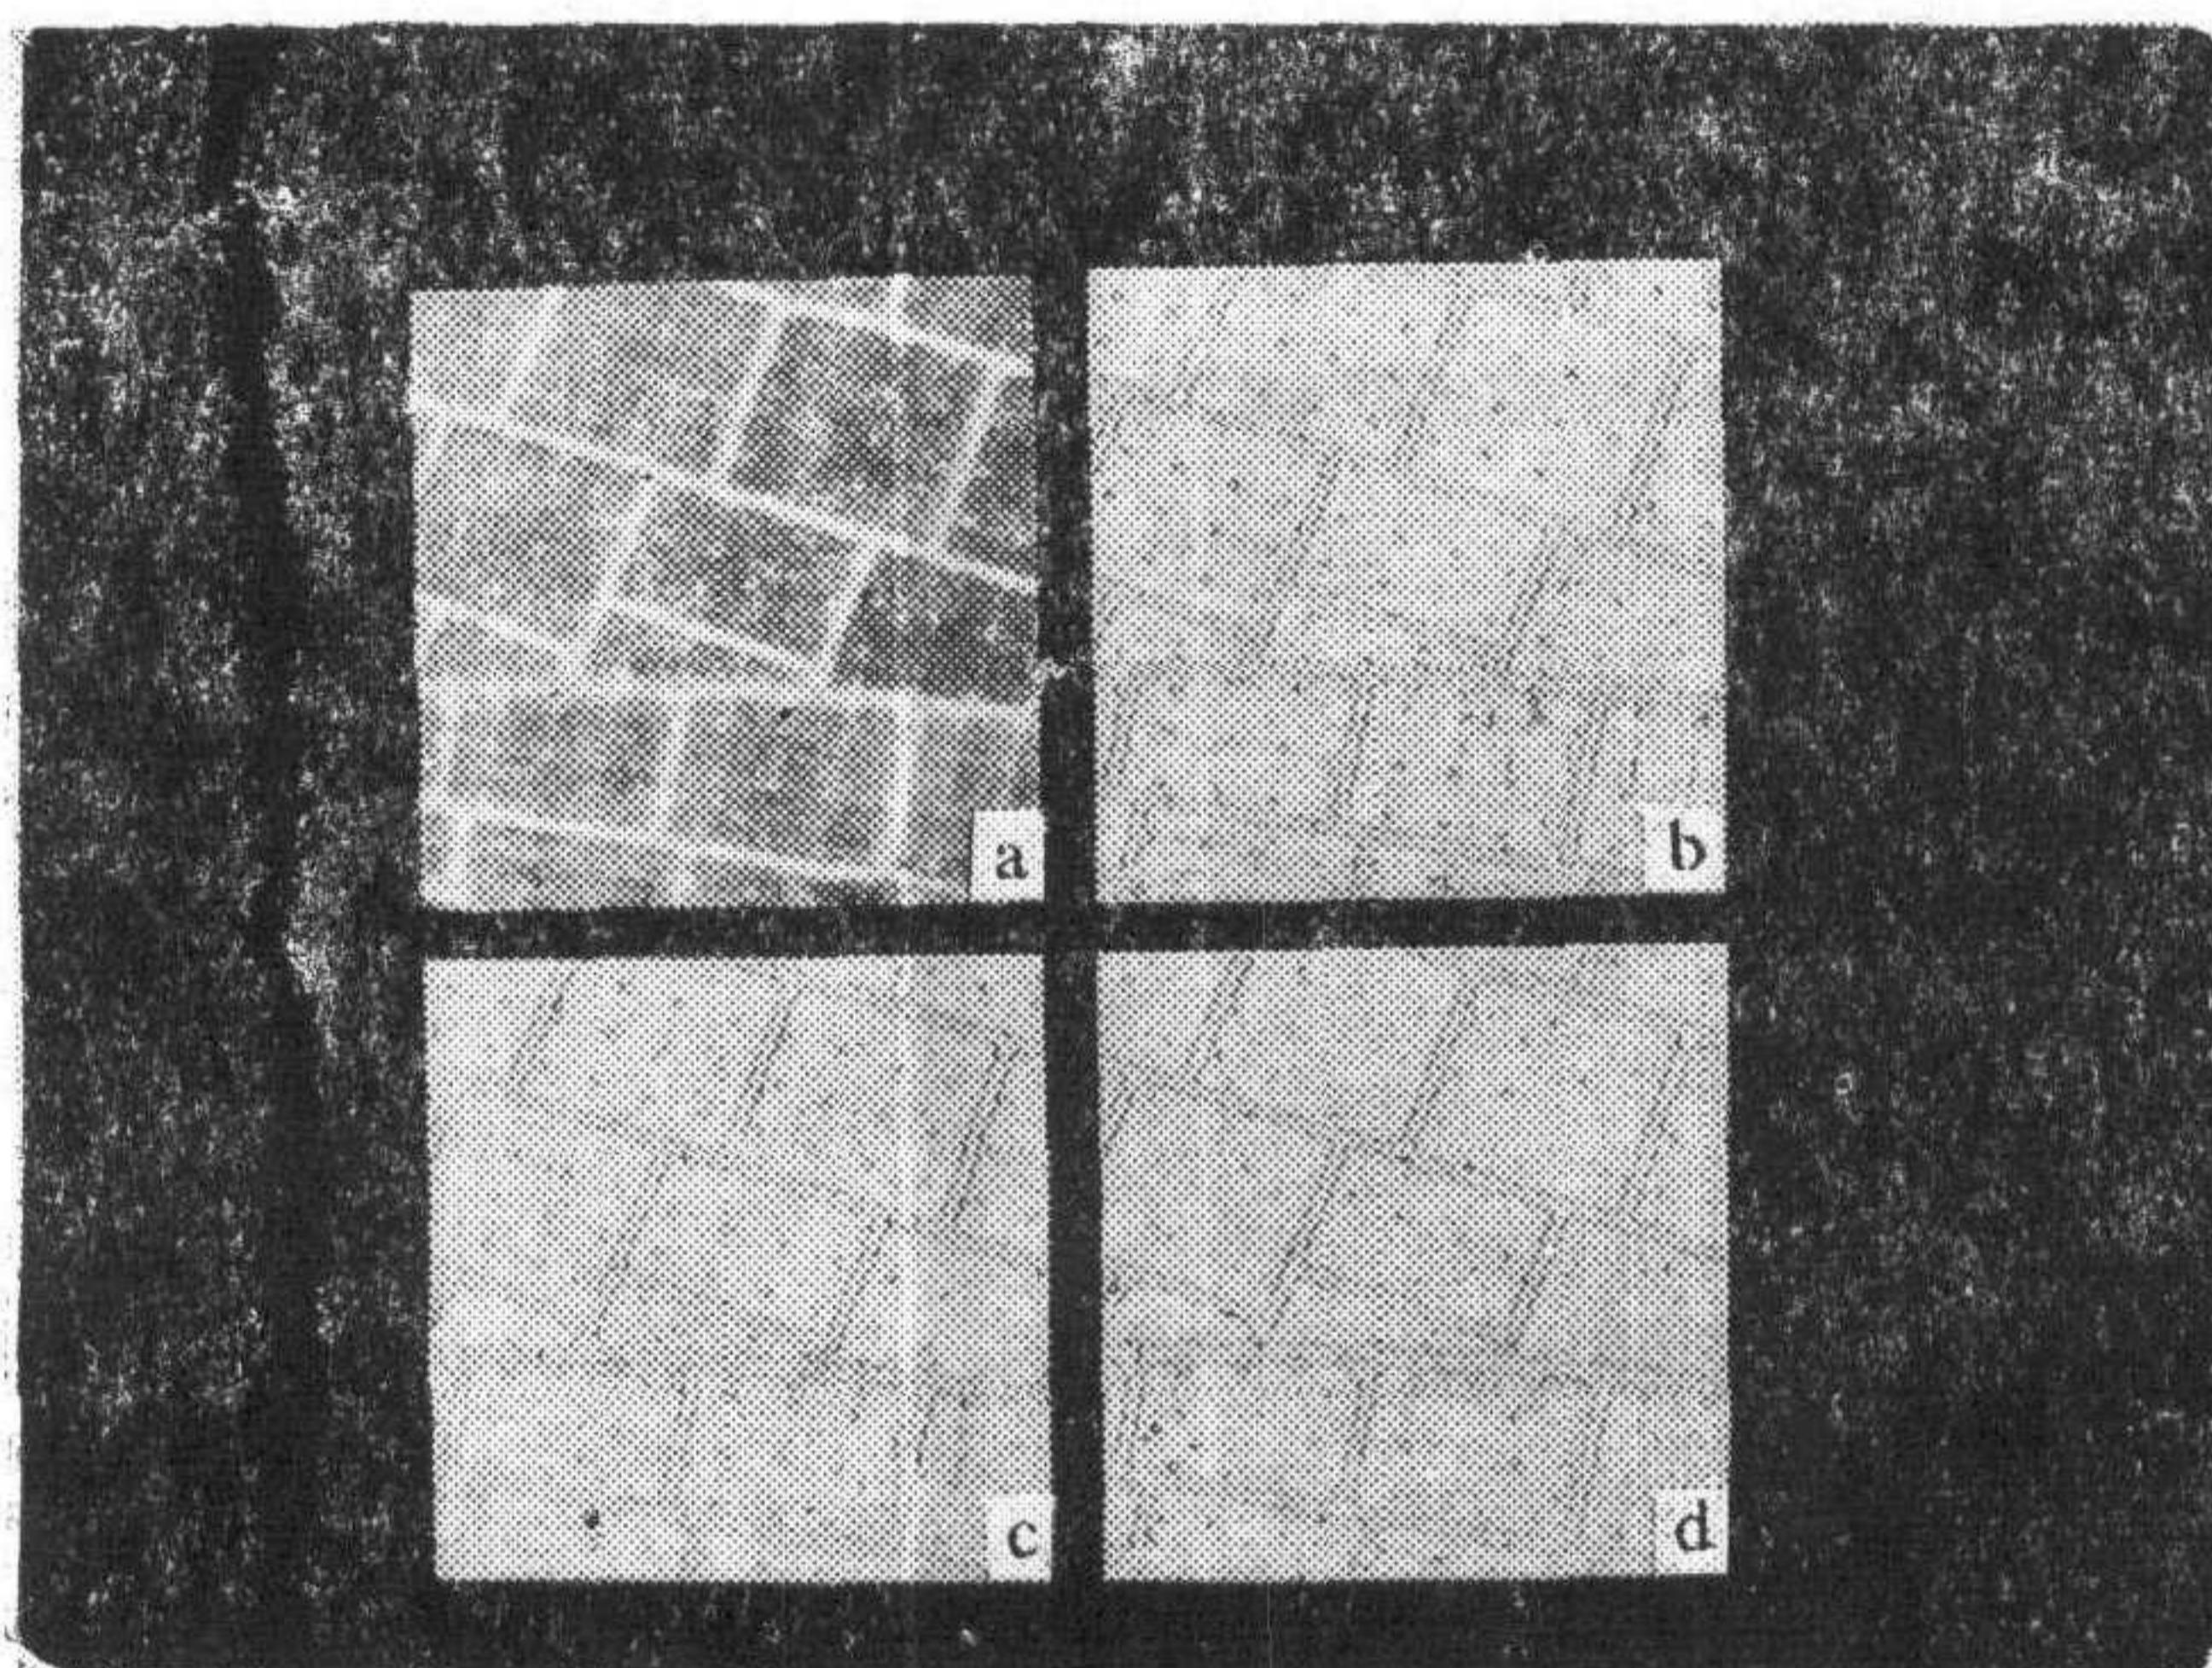


图 5 慕尼黑奥运村屋顶图象及检测结果

树枝和石墙图象¹⁾见图 4(a), (b)用来检验 WR 方法发现对比度在很大范围内变化的细条特征的能力,图 4(c),(d)为检测结果($\lambda = 0.8$)。可以看到,对比度相当悬殊的树枝和枝桠及石块轮廓均被正确检出。

慕尼黑奥运村有机玻璃屋顶图象²⁾(图 5(a))及检测结果(图 5(b),(c),(d))。 λ 分别为 1.4, 0.8, 0.4。这里 λ 作为尺度参数(其值越小,尺度越大)。可以看出,细节依次逐渐减少(边缘点

数依次为 5000, 4585 和 3915)而仍未见明显的边缘偏移。

4 结语

如果希望边缘准确地反映物理间断的形状和位置,在边缘检测中单靠平滑性约束是不够的,还须引入空间定位(边缘具有确定的空间位置)和几何结构约束。WRR 同时体现了平滑和空间定位约束,其效果相当于非线性自适应平滑,而 EF 中的修剪算法则在一定程度上体现了几何结构约束。

在多分辨率分析中,平滑不只是为了抗噪,也是产生多分辨率表示的基本手段。如果边缘定位精度必须依靠阻抑跨越边缘的平滑来保证,那么 WR 以及其它的自适应平滑是否不如线性平滑那样具有在任意范围内收放自如的尺度特性?这一点有待于进一步考察。

弱正则化可说是介于标准正则化和保留间断的正则化^[10]之间的一种中间形式,本文给出了它的一种模拟网络表达。弱正则化在初级视觉处理中也许有更广泛的应用。

参 考 文 献

- [1] Marr D and Hildreth E. Theory of edge detection, In: Proc. Roy. Soc. London, 1980, B207: 187—217.
- [2] Canny J. A computational approach to edge detection, IEEE Trans Pattern Anal. Machine Intell., 1989, 11: 191—198.

1), 2) 选自国际摄影测量和遥感学会提供的立体图对。

- [3] 沈俊. 边缘探测最佳线性算子, 模式识别与人工智能, 1989, 1(1): 86—103.
- [4] 沈俊. 基于多边界模型的边缘检测, 模式识别与人工智能, 1989, 1(2): 121—127.
- [5] Nalwa V S and Binford TO. On detecting edges, *IEEE Trans. Pattern Anal. Machine Intell.*, 1986, 8: 699—714.
- [6] Torre V and Poggio T. On edge detection, *IEEE Trans. Pattern Anal. Machine Intell.*, 1986, 8: 147—163.
- [7] Perona P and Malik J. Scale-Space and edge detection using anisotropic diffusion, *IEEE Trans. Pattern Anal. Machine Intell.*, 1990, 12: 629—639.
- [8] Saint-Marc and et al. Adaptive smoothing: a general tool for early vision, *IEEE Trans. Pattern Anal. Machine Intell.*, 1991, 13: 514—529.
- [9] Poggio T and et al. Computational vision and regularization theory, *Nature*, 1985, 317: 314—319.
- [10] Terzopoulos D. Regularization of inverse visual problems involving discontinuities, *IEEE Trans. Pattern Anal. Machine Intell.*, 1986, 8: 413—424.
- [11] 王德人, 非线性方程组解法与最优化方法, 北京: 人民教育出版社, 1979.
- [12] Fleck M M. Some defects in finite-difference edge finders, *IEEE Trans. Pattern Anal. Machine Intell.*, 1992, 14: 337—345.
- [13] Tan H L and et al. A comparative cost function approach to edge detection, *IEEE Trans. Syst. Man, Cybern.*, 1989, 19: 1337—1349.

EDGE DETECTION BY WEAK REGULARIZATION

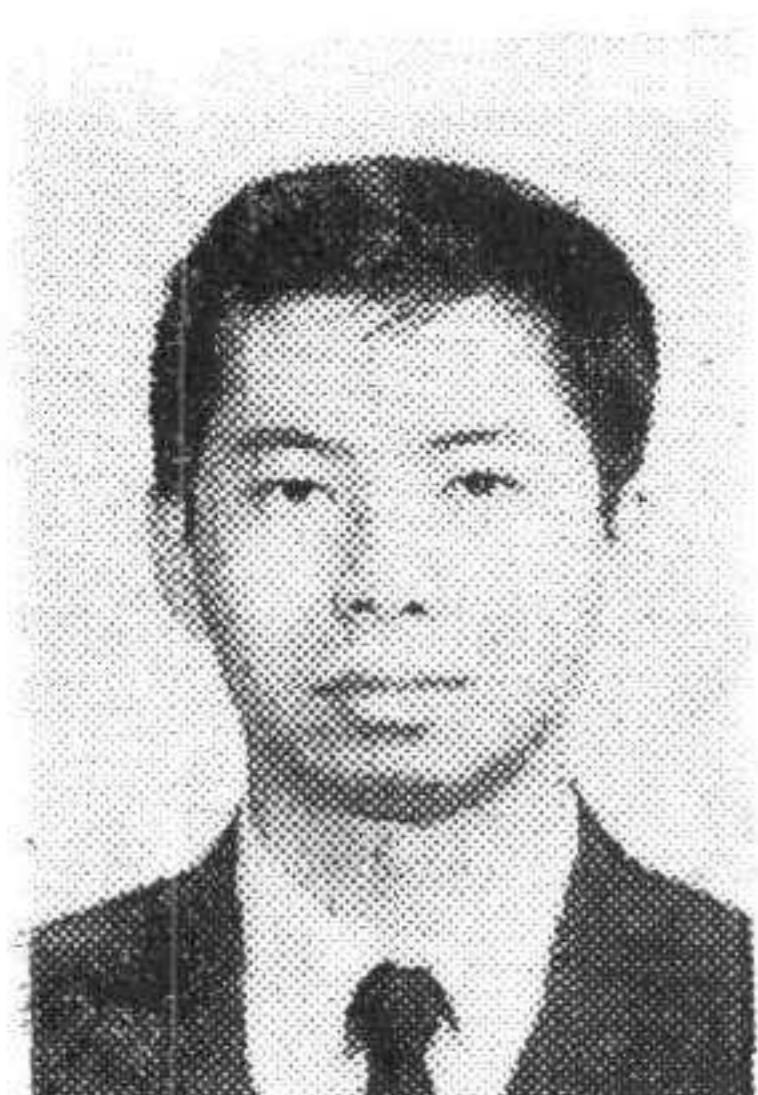
LI WENBIAO PAN SHIXIAN

(P. O. Box 206, Beijing University of Aero. & Astro., Beijing 100083)

ABSTRACT

A new technique of edge detection which called weak regularization approach is presented. The technique consists of two stages. The first is a weakly regularized reconstruction (WRR) of image functions, the second is an edge finding (EF) procedure. The WRR is characterized by a controlled-smoothness stabilizer in the reconstruction functional by means of which smoothness constraint on the reconstructed image is adjusted (released or tightened) with the possibility of occurrence of edges in the underlying image. What is new in the EF is an edge pruning technique that yields optimal pruning by minimizing a cost function for the evaluation of local geometrical structure of edges. Experiment results that demonstrate the performance of the technique are given.

Key words: Edge detection, regularization, weak regularization, controlled-smoothness stabilizer, edge pruning.



李文彪 1965年出生于云南昆明。1987年、1990年和1994年在北京航空航天大学电子工程系分别获得学士、硕士和博士学位。现在国防科工委科学技术部从事科技管理工作。

潘士先 照片、简历见于本刊第18卷第4期。