

噪声图象中提取边界的随机启发式搜索方法

韩军伟 郭雷

(西北工业大学自动控制系, 西安 710072)

摘要 在噪声图象中如何有效地提取边界是图象分析领域中的难点。启发式搜索的方法常常用于提取边界,但是,这种方法由于采用固定的起始点、固定的引导度量以及对图象仅进行一次性搜索,对噪声往往很敏感,为此提出了一种随机启发式搜索算法,该方法随机地选取起始点,并依照引导度量的概率反复地进行随机搜索获得各种可能的边界轨迹,然后进行各搜索轨迹的积累自增强,最后根据自增强积累统计结果获得边界。大量的实验结果证明,在噪声图象中,随机启发式搜索方法可以在提取出有意义边界的同时有效地抑制噪声。

关键词 边界提取 启发式搜索 随机启发式搜索 积累

中图分类号: TP391 **文献标识码**: A **文章编号**: 1006-8961(2001)12-1184-07

A Stochastic Heuristic Search Method for Extracting Edge in Noise Image

HAN Jun-wei, GUO Lei

(Department of Automatic Control, Northwestern Polytechnical University, Xi'an 710072)

Abstract Edges of objects often provide important features in pattern recognition application. How to extract the edge effectively in noise image is a difficult problem in the field of image analysis. Heuristic search algorithm is often used to extract edge, but because this method utilizes the fixed start points, fixed guide measurement and processes one-off search, it is often very sensitive to noise. In this paper, a stochastic heuristic search method is presented. It firstly uses repetitive random searches to obtain various possible independent-edge trajectories, then self-reinforces and accumulates the search trajectories respectively, at last, extracts the edges relying on the result of the accumulation of self-reinforcement. Lots of experiments show that our method can extract edges effectively and suppress the noise at the same time. Comparing with heuristic search algorithm, we find that our method is superior.

Keywords Edge extraction, Heuristic search, Stochastic heuristic search, Accumulation

0 引言

如何在噪声图象中很好地提取边界是图象处理中的热点问题, Martelli^[1,2]最早使用了启发式搜索技术来提取边界,他在边界检测后引入了搜索连接的过程,通过上下文信息来引导搜索,把边界检测后的孤立边界点连接成有意义的边界曲线,同时根据曲线搜索的连续性抑制噪声。

如图1所示,启发式搜索算法一般包括两个部分:

(1) 边界检测 其功能是为后面的搜索提供引导信息。

(2) 搜索算法 由边界检测得到的边界信息结合先验知识及上下文信息推导出一个引导度量,然后依据引导度量引导每一步搜索,把上一步检测出的边界元素连接成边界曲线。

在图象中,搜索的具体过程可以看成是按照树




图 1 启发式搜索算法流程图

型结构组织的,如图 2 所示,首先根据先验知识在图象中选取一个点作为树的根节点(即搜索的起始点),下一步搜索的扩展点是在图象中与根节点相邻的 8 个点,然后这 8 个点又各自有 8 个可扩展的点,依次扩展下去,直至达到终止点,这样就形成了一个树型结构。在树型结构中,根节点被称为是第 0 层,依次下去是第 1 层、第 2 层……。




图 2 搜索算法的树型组织结构

启发式搜索的目的是在此树型结构中优化一个最佳路径。这就需要用一个引导度量来作为启发式信息,而每一步搜索都对应着一个度量代价。例如 $n_0, n_1, n_2, n_3, \dots, n_k$ 代表从根节点 n_0 出发,沿着第 i 条路径到达树结构第 k 层的一列节点, m_j^i 代表第 i 条路径上,从第 $j-1$ 节点扩展到第 j 节点的度量代价,所谓的最佳路径就是在搜索中能保证每一步搜索的度量代价 m_j^i 都是最佳的(最大或最小)。

尽管启发式搜索结合了上下文信息,并利用搜索的连续性来消除噪声。但是,这种方法仍然存在一些问题,第一,按照固定的开始点和固定的度量引导搜索不能获得更多的上下文信息;第二,仅进行一次搜索,这就要求每一步搜索必须绝对正确和最优,这使得搜索很难在高噪声图象中进行;第三,需要提前对边界位置进行估计,当遇到复杂图象时,估计很难准确;第四,根据估计的边界位置信息进行分块搜索,加之搜索起始点固定,会出现断点和漏搜索的边界。为此,提出了一种随机启发式搜索方法。

1 随机启发式搜索算法

图 3 为随机启发式搜索方法的框图。其包括以下几个部分:




图 3 随机启发式搜索方法流程框图

(1) 边界检测 为后面的启发式搜索提供引导度量信息。

(2) 启发式搜索 目的是追迹可能的边界,为以后的处理提供边界轨迹。

对于启发式搜索来说,引导度量的选择至关重要,好的引导度量应该既要考虑全局信息,又要兼顾局部信息,由于边界上的点在局部区域具有一致的相位,而且边界点的幅度往往较大,因此,从这两点出发,选取象素点的相位和幅度信息的加权来作为引导度量。

要求一次搜索的轨迹精确得与完整边界吻合是非常困难的,也是不必要的,因为一条完整的边界可分成不同的组成部分。根据随机选取的起始点,每一次搜索仅需跟踪边界的一个部分,不同搜索轨迹的积累就能组合成完整的曲线(图 4)。这种统计方法放松了对一次搜索的要求,可以忍受偶然的搜索错误,能够在高噪声图象中应用。




图 4 一条完整的边界 a 可由对它的各部分进行多次搜索的积累获得

在文献[1]~文献[6]中,许多学者采用预先估计边界的位置来引导搜索,并且按照估计的边界位置来分块搜索,这样带来的后果是无法处理复杂图象,对噪声极其敏感,容易形成断点和搜索盲区。

与一般启发式搜索不同的是,算法中所使用的引导度量不是固定的,而是依照度量代价的概率随机选取扩展点,这也就保证了搜索路径的不固定,于是可以根据多次搜索的路径统计出正确路径。

(3) 搜索轨迹独立自增强 为了算法在高噪声图象中也能很好地应用,仅仅依靠搜索的连续性和局部的相位、幅度信息是不行的,而必须使用全局信息,为此,引入了搜索轨迹独立自增强方法,即每次搜索完一条边界曲线,同一搜索轨迹上的各像素都进行相互增强,用自己本身的上下文信息来增强自己,长轨迹可以连续地搜索并得到增强,而噪声却没有增强。

(4) 标记边界点,提取边界 反复进行随机启发式搜索,直到累积器能够区别噪声和边界,被明显累积的点标记为边界点。

1.1 边界检测

边界检测为后面的随机启发式搜索提供引导信息,选取定位性能比较好的 Sobel 算子(如图 5 所示)来获取边界信息。

-1	0	+1
-2	0	+2
-1	0	+1

-1	-2	-1
0	0	0
1	2	1

图 5 X,Y 方向上的 Sobel 算子

设图象的灰度函数为 $F(x,y)$, x,y 表示像素的坐标, $f_x(x,y)$, $f_y(x,y)$ 分别表示由 Sobel 算子得到的 $F(x,y)$ 沿 x,y 方向上的变化率,由此可得像素 (x,y) 的幅度和相位角为

$$f(x,y) = (f_x(x,y)^2 + f_y(x,y)^2)^{1/2} \quad (1)$$

$$\tan\theta = f_y(x,y)/f_x(x,y) \quad 0 \leq \theta \leq 2\pi \quad (2)$$

1.2 边界引导的随机启发式搜索

随机启发式搜索的过程包括 3 步:开始点的选择,扩展点的选择和终止点的确定(图 6)。




图 6 搜索边轨迹的流程圖

设一条长度为 Q 的搜索轨迹 T 由轨迹坐标和组成它的象素的图象坐标表达

$$T = \{(x,y)_0, (x,y)_1, \dots, (x,y)_{Q-1}\} \\ = \{t_0, t_1, \dots, t_{Q-1}\} \quad (3)$$

一个轨迹上的象素表示为 t_i 或 $(x,y)_i, 0 \leq i \leq Q-1$, 下标 i 表示该点在轨迹中的编号数, t_0 或 $(x,y)_0$ 表示随机搜索的起点。

1.2.1 开始点的选择

如果一个输入边界点的幅度值(即边界检测器的输出幅度)超过给定幅度阈值 f_{min} , 则它被称为潜在开始点, 搜索的开始点只从潜在开始点中选择。

对每个潜在开始点引入一个连续随机变量称为活动变量, 例如 v_i 是潜在开始点 q_i 的活动变量, 它表示潜在开始点 q_i 被选为开始点的优先级, 此连续随机变量 v_i 的概率密度函数为与对应潜在开始点的边界幅值有关的指数分布

$$p_i(v_i) = \begin{cases} f_i e^{-f_i v_i} & v_i \geq 0 \\ 0 & v_i < 0 \end{cases} \quad (4)$$

其中, f_i 为潜在开始点 q_i 的边界幅值(由式(1)计算), 由此可见, 概率是依赖边界的, 从方程(4)可知, v_i 的均值(数学期望)为

$$\bar{v}_i = \frac{1}{f_i} \quad (5)$$

这意味着潜在开始点的边界幅值越大, 则活动变量的均值越小。

为选择开始点, 首先, 标记上述所有的潜在开始点, 并将活动变量赋予每个潜在开始点, 设 L 为潜在开始点的总数, 反复以下两个步骤:

(1) 每一个活动变量 $v_i \in V(1 \leq i \leq L)$ 都由它的随机变量产生器产生一个实现值 u_i , 这里 u_i 是 v_i 的实现值。

(2) 扫描所有的实现值, 寻找具有最小值的 u_j , 即 $u_j = \min(u_1, u_2, \dots, u_L), j \in \{1, 2, \dots, L\}$ (6)

然后这个潜在开始点 q_j 被定为开始点, 以 $(x,y)_0$ 表示, 选择开始点的过程非常简单, 不需要任何先验信息, 这体现了此算法的灵活性。

f_1, f_2, \dots, f_L 代表潜在开始点的边界幅值, 计算一个给定的潜在开始点 q_j 被选择为开始点的概率

$$P_j = \int_{\Omega_j} p^L(v_1, v_2, \dots, v_L) dv_1 dv_2, \dots, dv_L \\ j \in \{1, 2, \dots, L\} \quad (7)$$

p^L 是 L 维联合概率密度函数, Ω_j 是积分域, 活动变量 v_i 和 $v_k (i \neq k)$ 相互独立, 所以通过式(7)中潜在开始点

的活动变量 $v_i (i \in \{1, 2, \dots, L\})$ 的分布, 可以得到

$$\begin{aligned}
 P_i &= f_i \int_{-\infty}^{\infty} e^{-f_i v_i} \left[\prod_{j \neq i} f_j \int_{-\infty}^{\infty} e^{-f_j v_j} dv_j \right] dv_i \\
 &= f_i \int_{-\infty}^{\infty} e^{-\sum_{j=1}^L f_j v_j} dv_i = \frac{f_i}{f_1 + f_2 + \dots + f_L} \\
 j &\in \{1, 2, \dots, L\} \quad (8)
 \end{aligned}$$

从式(8)不难看出, 象素点的幅度越大, 该象素点选为开始点的概率越大. 因为边界上的点往往幅度较大, 所以开始点以大概率集中于强边界, 即由边界引导. 上述结论同时表明大幅度的长连续边界比小幅度的短边界有更多的开始点, 所以连续边界被更多次地搜索. 这在增强长的连续边界和抑制短的噪声边界中起着关键作用.

1.2.2 搜索扩展点的选择

搜索扩展点的选择主要依靠引导度量. 在随机启发式搜索中, 扩展点是在一个 3×3 邻域内随机选择的. 选择需根据邻域象素的边界信息(包括相位和幅度信息)并满足曲线方向连续性约束. 假设有一条搜索轨迹如式(3)所述, 用 m_i 表示这条轨迹上从 t_{i-1} 扩展到 t_i 的度量代价, 定义为

$$m_i = \alpha f_i + \beta (1/|\theta_i - \theta_{i-1}|) \quad 0 \leq \theta_i, \theta_{i-1} \leq 2\pi \quad (9)$$

其中, α, β 为常数且 $\alpha + \beta = 1$, f_i 为第 i 点的幅度值, θ_i, θ_{i-1} 分别为第 i 点和第 $i-1$ 点的相位角.

为了选择扩展点, 对搜索轨迹上第 i 个象素点 $t_i (0 \leq i \leq Q-1)$ 的 8 个相邻象素引入 8 个连续随机变量 $s_k (k=0, 1, \dots, 7)$, 称之为方向活动变量(如图 7). s_k 表示将第 k 个邻域象素作为搜索扩展象素的优先级, 它的概率密度函数为

$$\begin{aligned}
 p_k(s_k) &= m_k e^{-m_k s_k} \\
 s_k &> 0, k=0, 1, \dots, 7, 0 \leq i \leq Q-1 \quad (10)
 \end{aligned}$$

m_k 是 t_i 的第 k 个邻域象素的度量代价(由式(9)计




图 7 一个边界象素的 3×3 邻域

算).

为了以后方便表达, 引入 $d_k (k=0, 1, \dots, 7)$ 表示象素点的 8 个邻域的相对坐标. 相对坐标的定义如图 7.

开始点和非开始点间的扩展点的选择有些区别. 首先介绍开始点的扩展点的选择. 开始点 t_i 的 8 个方向活动变量是 $s_k, k=0, 1, \dots, 7$.

选择搜索扩展点按下述步骤进行: 首先, 每一个方向活动变量 $s_k^i (k=0, 1, \dots, 7)$ 都由它的随机变量产生器产生一个实现值 z_k^i ; 接着, 发现最小的实现值, 例如 z_j^0

$$z_j^0 = \min(z_0^0, z_1^0, \dots, z_7^0), j \in \{0, 1, \dots, 7\} \quad (11)$$

这样第 j 个邻域象素即作为搜索扩展象素, 它是搜索轨迹上的第 2 个点, 用 t_1 表达, 它的图象坐标为

$$(x, y)_1 = (x, y)_0 + d_j, j \in \{0, 1, \dots, 7\} \quad (12)$$

用式(10)计算第 j 个邻域象素被选为搜索扩展象素的概率, 可以得到类似式(8)的结果

$$P_j = \frac{m_j^0}{m_0^0 + m_1^0 + \dots + m_7^0}, j \in \{0, 1, \dots, 7\} \quad (13)$$

这个结果很简单, 它表示了有与父节点最一致的相位和有最大幅值的子节点(度量代价最大)被选为扩展象素的概率最大.

在确定了开始点 t_0 和第一个扩展象素 t_1 以后, 就获得了轨迹的最初搜索方向. 接下来扩展点的选择要依照曲线方向连续性规则, 以保持搜索轨迹像曲线一样连续. 实际上, 局部的边界曲线变化是平滑的, 很少有从水平到垂直或从水平到倾斜等频繁变化. 因此在给定开始点和开始方向以后, 就限制了边界上象素可能的转变. 对于搜索轨迹上的任意 3 个连续点, 由前两个点定义的方向和由后两个点定义的方向之间的夹角小于或等于 $\pi/4$, 即扩展点只是从 3 个与以前搜索方向夹角不超过 $\pi/4$ 方向的邻域中选择的. 图 8 显示了一个例子.




图 8 方向连续性规则的一个例子
(自底向上搜索只能以实箭头方向进行)

考虑象素 t , 如果相对于 t_{j-1} 的相对坐标是 d_j , 也就是说 d_j 满足

$$(x, y)_j = (x, y)_{j-1} + d_j, j \in \{0, 1, \dots, 7\} \quad (14)$$

则 t_j 的 3 个候选扩展象素的相对坐标是

$$\{d_{(j-3)\bmod 8}, d_{(j-4)\bmod 8}, d_{(j+5)\bmod 8}\} \quad (15)$$

赋予的 3 个方向活动变量是

$$\{s'_{(j-3)\bmod 8}, s'_{(j-4)\bmod 8}, s'_{(j+5)\bmod 8}\} \quad (16)$$

它们的概率密度函数如式(10), 每个方向活动变量取实现值, 然后取最小实现值, 例如 z'_k , 则第 k 个方向被选为扩展象素

$$z'_k = \min \{z'_{(j-3)\bmod 8}, z'_{(j-4)\bmod 8}, z'_{(j+5)\bmod 8}\}, k \in \{(j+3)\bmod 8, (j+4)\bmod 8, (j+5)\bmod 8\} \quad (17)$$

当扩展点确定后, 搜索轨迹被扩展为

$$T = \{(x, y)_0, \dots, (x, y)_j, (x, y)_{j+1}\} = \{t_0, \dots, t_j, t_{j+1}\} \quad (18)$$

扩展过程不断重复直到下一个象素点是目标或停止点。

类似于式(13)的分析, 可以得到第 k 个邻域点被选为扩展象素的概率

$$P_k = \frac{m_k}{m_{(j-3)\bmod 8} + m_{(j+4)\bmod 8} + m_{(j+5)\bmod 8}}, k \in \{(j+3)\bmod 8, (j+4)\bmod 8, (j+5)\bmod 8\} \quad (19)$$

应该说明的一点是, 根据曲线的平滑变化可限制扩展点的方向, 这样就节省了搜索时间, 例如: 对于一条长度为 N 的曲线 (N 表示曲线上点的个数), 一般的启发式搜索扩展的候选点共有 $8+7^{N-2}$ 个, 而本文方法仅有 $8+3^{N-2}$ 个。这是因为一般的启发式搜索是一次性的, 因此必须兼顾方向变化剧烈的情况。本文的方法却同样适用于方向变化剧烈的情况, 对于方向变化剧烈的边界, 一次搜索可能无法完整搜索, 但是分段搜索可组合出一条边界曲线。

1.2.3 终止点的选择

对于终止点的选择, 这里遵循这样的原则: 如果某点的所有扩展点度量代价都过小, 则此点为终止点。为了描述这个方法, 考虑一个不完全的搜索轨迹如式(4)所述, 下一个选择的扩展点将是 t_{j+1} , 设 t_j 所有可能的扩展邻域集合为 H_j 。如上所述, 如果是一个起始点, H_j 包含 8 个可能的扩展方向; 如果 t_j 是一个非起始点, H_j 包含 3 个可能的扩展方向。从方向活动变量 s_k 中选择一个具有最小实现值的点, 并以此作为扩展点。事实上在做这一步操作前, 必须决定 t_j 是否是终止点。

若对所有的 $k, k \in H_j, s_k$ 的实现值 z'_k 满足

$$z'_k > s_{max} \quad (20)$$

其中, $s_{max} > 0$ 是停止阈值, 则搜索在象素点 t_j 处停止, 象素点 t_{j-1} 不加入到搜索轨迹中。

通过简单的分析, 能获得搜索在第 $i+1$ 个象素点 t_i 停止的概率

$$P_i = e^{-\sum_{k \in H_i} m_k} \quad (21)$$

$M_i = \sum_{k \in H_i} m_k, m_k$ 是轨迹上第 $i+1$ 个象素 t_i 的第 k 个邻域象素的度量代价, 从式(21)中得到一点的邻域的度量代价越小, 则搜索在该点停止的概率越大。

这样当搜索到达曲线的端点时, 3 个扩展象素的相位没有与父节点一致的且其幅值几乎都很小, 所以在曲线的端点搜索停止的概率很大。

1.3 搜索轨迹自增强的积累

其实边界提取的困难绝大部分来自于噪声的影响, 最好的去噪声的方法是把边界上下文信息恰当地融合到边界提取过程中。本文方法中, 边界的增强是基于各自的搜索轨迹, 只有同一搜索轨迹上的各象素才互相增强。利用搜索轨迹的自增强, 最后要得到的是边界的幅度图象, 因此仅仅使用边界幅值信息来增强和积累就足够了。

假设有一条搜索轨迹如式(4)所述, 它的增强可以用如下的公式表达, 对于轨迹上的每点, 例如 $t_k \in T, k \in \{0, 1, \dots, Q-1\}$, 它的积累增量定义为

$$\Delta A_{(x,y)_k} = \sum_{(x,y) \in T} f_{(x,y)}(x, y) \quad (22)$$

象素的增强用轨迹坐标表示, 然而象素的积累器必须用图象坐标表示, 因为不同的边界可能有同一个积累器。这样在 (x, y) 点的积累器可以记为 $A_{(x,y)}$, 它基于图象坐标进行修改, 即

$$A_{(x,y)} = A_{(x,y)} + \Delta A_{(x,y)_k}, k \in \{0, 1, \dots, Q-1\}, (x, y)_k = (x, y) \quad (23)$$

在原始图象上的每一点均须进行上述计算的积累。最初积累器被设为零, 上式进行了从轨迹坐标到图象坐标的转化。

反复次数 n 是一个重要的参数, 多次的实验表明, 当 n 取为 $L/2$ 时, 可以获得理想的结果。

1.4 边界或非边界标记的确定

当随机启发式搜索和自增强反复进行到一定的次数时, 长的连续边界上的点将获得强的积累, 而产生噪声的短边界上的点将只有很弱的积累。这样, 就达到了增强边界和抑制噪声的目的。

综上所述, 点的积累值反映了边界信息, 所以如

果该点的积累器 $A_{(x,y)}$ 满足

$$A_{(x,y)} \geq A_{\min} \quad (24)$$

则此点就被标记为真实边界点,否则被标记为非边界点,其中 $A_{\min} > 0$ 是判断门限.最后根据标记的点提取边界.

1.5 完整的算法流程

- (1) 指定潜在开始点的边缘幅值大于阈值 f_{\min} ;
- (2) 赋予每个潜在开始点一个活动变量 v_i ;
- (3) 对所有潜在开始点的活动变量计算各自的实现值;
- (4) 选择最小实现值的点作为搜索的起始点,并认为是新轨迹 T 的第 1 个点;
- (5) 根据处理点 t , 是否为开始点来赋予其方向活动变量 s_i . 如果是开始点,则赋予 8 个活动变量,如果是非开始点则赋予 3 个活动变量;
- (6) 对所有方向活动变量计算各自的实现值;
- (7) 选择具有最小实现值的相邻点;
- (8) 通过检查实现值是否大于终止阈值来确定相邻点是否为终止点,如果是终止点,转至第 9 步,否则此点作为扩展点,并作为处理轨迹 T 的下一个点,然后转至第 5 步;
- (9) 计算轨迹上所有像素输入的边缘幅值,并把结果加入轨迹上每一个像素点的积累器中;
- (10) 确定搜索是否重复,如果不,转至第 3 步,否则,转至第 11 步;
- (11) 通过比较累积值和阈值 A_{\min} 的大小来确

定是否为边缘点.

2 实验结果及分析

实验中, f_{\min} 取为原始边界点中最大幅值的 1/4; 搜索次数 n 取为潜在起始点总数的一半,终止点阈值 s_{\max} 取为 0.5. 在所有的实验中,阈值 A_{\min} 取为 10, α, β 为 0.7 和 0.3.

2.1 与一般启发式搜索法的对比实验

图 9 是由数码相机摄入的原始图象,图 10 是加入方差为 50 的高斯噪声后的图象,图 11 是使用了随机启发式搜索方法提取的边界图象,图 12 是使用了文献[5]中的启发式搜索方法提取的边界图象.图 13 是加入了方差为 50 的高斯噪声的“Lena”图象.图 14 和图 15 分别是用本文和文献[5]方法提取的边界.正如先前所分析的那样,一般的启发式搜索确实造成了边界上出现很多断点及漏搜索的边界,说明了这种方法对噪声十分敏感.而本文的方法对于噪声图象,可以提取出真实的边界,对噪声的鲁棒性相当强.

2.2 计算复杂度的比较

所有的算法在 VC++ 6.0 下编写,运行于 P III 800 单机上.一般的启发式搜索采用了文献[5]中的方法.两种方法处理各图的时间对比如表 1 所示.通过表中的数据可以看出,本文方法在计算复杂度上也略优于一般启发式搜索的方法.




图 9



图 10




图 11



图 12



图 13



图 14



图 15

表1 一般启发式方法与本文方法实验耗时表

方法	单位: s	
	图10	图13
一般启发式搜索方法	5.1	31
本文方法	4.1	25

3 结 论

本文提出了一种随机启发式搜索方法,其核心思想是通过对边界检测后图象的反复随机搜索来获得各种所有可能的独立边界轨迹,然后对所得的每条边界进行独立自增强,最后根据积累增强的结果来提取边界。

与一般的启发式搜索相比,文中方法进行了如下的改进:(1)采用随机启发式搜索,起始点随机选取,搜索轨迹也是随机的,而不是固定的;(2)搜索是由边界信息引导的,搜索的轨迹在概率意义上与边界吻合;(3)搜索反复进行,以获得不同的搜索轨迹;(4)引入积累机制,所有的搜索轨迹依据图象坐标进行积累,一次搜索的结果对最终结果只产生微小的贡献。通过积累可以增强边界同时抑制噪声。

最后能被提取出的边界,意味着有许多搜索反复在这条边界上进行,而一次偶然的搜索轨迹不能产生足够的积累强度。这个算法并不依赖于每次搜索的每个局部操作的绝对正确,它只要求绝大多数搜索是正确的。通过反复搜索的边界,将得到反复的积累,而噪声将很少获得积累,从而达到滤除噪声的目的,这是文中方法能很好地高噪声图象中应用的关键原因。

此外,本文方法可说是利用上下文信息抑制噪声的又一尝试,使用什么样的上下文信息,如何融合使用不同的上下文信息将是今后继续研究的方向。

参 考 文 献

- 1 Martelli A. Edge detection using heuristic search methods[J]. Comput. Vision Graphics, Image Process., 1972, 1(2): 169~182.
- 2 Martelli A. An application of heuristic search methods to edge and contour detection[J]. Commun ACM, 1976, 19(1): 73~83.
- 3 Law T, Itoh H, Seki H. Image filtering, edge detection, and edge tracing using fuzzy reasoning[J]. IEEE Trans. Pattern Analysis and Machine Intelligence, 1996, 18(5): 220~227.
- 4 Farag A A, Delp E J. Edge linking by sequential search[J]. Pattern Recognition, 1995, 28(5): 611~633.
- 5 Ashkar G, Modestino J. The contour extraction problem with biomedical applications[J]. Comput. Graphics Image Process., 1978, 7(6): 331~355.
- 6 Eichel P H, Delp E J, Korak K *et al.* A method for fully automatic detection of coronary arterial edges for cineangiograms[J]. IEEE Trans. Medical Image, 1988, 12(5): 313~320.



韩军伟 24岁,西北工业大学自动控制系在读博士生,主要从事计算机视觉、图象处理、图象检索、图象理解等方面的研究。



郭雷 45岁,西北工业大学自动控制系教授、博士生导师,主要从事神经计算、计算机视觉、图象处理等领域的研究,完成了国家自然科学基金、863等项目十余项,发表论文60多篇。