

# 基于分水岭变换和遗传算法的自动目标检测

余莉 韩方剑

(国防科技大学电子科学与工程学院,长沙 410073)

**摘要** 提出了一种新的直接从图像中检测特定目标的算法。算法分为3个步骤。首先用分水岭变换对图像作“过分割”,得到标注的积水盆地和堤坝。实际目标可能是其中一个或多个盆地的组合。然后对盆地进行初步筛选,删除不可能是目标的盆地,并用区域邻接图(RAG)表示剩下的盆地。最后针对问题特点定义能量函数,提出一种启发式遗传算法,用来在RAG中检测使得能量函数极小化的子图,子图对应的区域就是目标。实验结果表明了该算法的有效性。

**关键词** 目标检测 分水岭变换 区域邻接图 能量函数优化 遗传算法

中图法分类号:TP391.41 文献标识码:A 文章编号:1006-8961(2008)09-1713-07

## Automatic Object Detection Based on Watershed and Genetic Algorithm

YU Li, HAN Fang-jian

(College of Electronic Science and Engineering, National University of Defense Technology, Changsha 410073)

**Abstract** In this paper, a new method for detecting specific objects in the image is presented. It consists of three steps. Firstly, a watershed transformation (WT) is used for over-segmenting the image in different small basins and dams. The desired object should be one of these basins or the combination of some ones. Secondly, the basins which are most impossible to be the objects are deleted, and then the neighboring relationships between the remainders are analyzed to construct a region adjacency graph (RAG). Finally, an energy function is constructed and a heuristic genetic algorithm (GA) is proposed to extract the optimized sub-graphs from the RAG. The regions corresponding to the sub-graphs are the desired objects. Experiment results demonstrate the feasibility of this approach.

**Keywords** object detection, watershed transform, region adjacency graph, energy function optimization, genetic algorithm

## 1 引言

从复杂场景中检测分割特定目标是计算机视觉和图像理解中一个很重要但又极其困难的任务<sup>[1]</sup>。数十年来,针对此类问题人们开发了大量的算法。这些算法大致可以分为两大类:自底向上的数据驱动模型和自顶向下的知识驱动模型。

对于自底向上的数据驱动模型,一般先对原始图像进行分割、标识和特征抽取等底层处理,然后将每个带标识的已分割区域的特征矢量与

目标模型相匹配<sup>[2]</sup>。在这类方法中,对图像进行准确分割是非常关键的,而实际上,由于目标本身灰度不均匀,以及成像设备聚焦不良和各种噪声等的影响,要将目标准确地分割是非常困难的。另外,在分割、标记和特征抽取等底层处理的过程中,由于缺乏知识的指导,盲目性较大,因而工作量大,检测效率低。

自顶向下的知识驱动模型<sup>[3]</sup>利用目标的先验知识直接从图像中检测出目标,从而回避了图像分割问题。相关匹配是其中的经典算法。它一般是用一个匹配窗口扫描整幅图像,在每一点计算模板与窗口内区域的相似性度量,以此得到目标是否出现

收稿日期:2006-11-13; 改回日期:2007-04-09

第一作者简介:余莉(1977~),女。讲师。2005年获国防科技大学信息与通信工程专业博士学位。主要研究方向为图像分析与理解、目标识别等。E-mail:yuli@nudt.edu.cn

的置信度。文献[4]给出了模板匹配的快速算法。Hough 变换<sup>[5]</sup>及其改进算法也被广泛地应用于目标提取。然而,由于自然物体形状的多样性、复杂性以及图像噪声等多种因素的影响,上述固定模板匹配的应用十分有限。变形模板匹配技术<sup>[6]</sup>能够较好地解决这一问题。相对于固定模板来说,变形模板使得自己发生变形以匹配到显著的图像特征。但是,由于它对初始位置敏感,需要依赖其他机制将模板放置在目标附近,因此在目标检测中的应用并不多见。

本文采取数据和知识驱动相结合的模型,提出了一种新的直接从图像中检测识别目标的算法。鉴于目前尚无完美的分割算法,先对图像进行无监督的“过分割”,实际的目标则是其中一个或多个区域的组合。分水岭变换(WT)<sup>[7,8]</sup>是一种被广泛应用的形态学图像分割算法,其缺陷是会导致“过分割”,因此在这里将作为预分割的工具;然后,用区域邻接图(RAG)来描述“过分割”标记图;最后,通过模拟水流淹没地形表面和泄洪的过程,定义了一个能量函数,并在 RAG 中求解使得能量函数极小的子图,子图对应的区域就是目标。遗传算法<sup>[9]</sup>是近年来提出的一种新型优化算法,它具有并行搜索、群体寻优等优点,已被应用于目标检测识别中。文献[10]提出了基于神经网络和遗传算法的目标检测算法,能够同时检测识别多类目标,但是识别是基于像素的,没有利用到高层特征信息,使得检测能力受限。本文提出了一种启发式遗传算法,针对问题特点采用启发式编码,设计了合适的选择、交叉和变异算子,寻求优化解。将算法用于多种实验图像,可以得到满意的检测结果。

## 2 检测思路

由于算法是建立在 WT 的基础之上,因此首先对其进行简单的叙述。WT 是一种基于拓扑理论发展起来的数学形态学图像分割方法,一般通过对水流淹没模拟(IS)来实现。其基本思想是把图像看作某个地形表面的数字海拔模型(DEM),此时像素的灰度表示地形中对应点的海拔高度。称地形表面中高度相同的连通点集为该高度处的区域,若与它相邻的区域的高度均大于它的高度,则称它为底。淹没过程首先刺破地形表面上的所有底,然后使水位从最小高度开始逐渐上涨,水流从这些底中溢出并逐渐淹没其周围的区域并最终形成该底的盆地

(Catchment Basin);在发源于不同底的水流的相会处筑堤坝(Dams)以防止它们合并,当水位到达地形的最大高度时,所有的堤坝就构成了地形表面的分水线。称每个连通的水流覆盖的区域为一个流域。图 1 示例说明了这些概念。

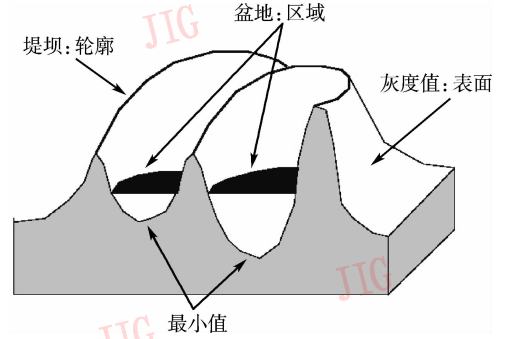


图 1 分水岭算法示意图

Fig. 1 Illustration of watershed transform

分水岭变换是图像分割的强有力的形态工具,但对复杂图像来说往往存在“过分割”的问题,且目标本身灰度并不一定均匀,因此有意义的区域由若干个邻接盆地组成。在地形图中表现为对某些盆地拆除部分堤坝,向邻接盆地泄洪后水流覆盖的区域(流域),其中满足目标特性的流域被认为是检测出的目标。我们想象流域具有内部能量和外部能量,并有一个硬约束项作用在流域上。

(1) 内能  $E_{\text{image}}$  由图像本身的特征决定。流域内部的区域特征一致性越高,则被认为越稳定,  $E_{\text{image}}$  值越小;

(2) 外能  $E_{\text{object}}$  该项受目标先验模型的约束。流域与目标模板的匹配度越高,则它是目标的可能性越大,  $E_{\text{object}}$  值越小;

(3) 硬约束项  $E_{\text{scale}}$  该项控制流域的尺寸,只有当其尺寸满足目标要求时,流域才有可能成为目标。

由此设计流域  $W$  的能量函数如下:

$$E(W) = E_{\text{scale}}(W) + \lambda E_{\text{image}}(W) + (1 - \lambda) E_{\text{object}}(W) \quad (1)$$

式中,  $\lambda \in (0, 1)$  是权值,控制内能和外能在能量函数中所占的比例。能量函数越小的流域越稳定,使目标的置信度越高。于是,目标检测被转化为在盆地标记图中寻求能量函数极小化的流域。求解过程将借助 RAG 来描述盆地标记图,然后在 RAG 中用遗传算法搜索使得能量函数优化的子图。子图对应的区域就是目标。

### 3 具体实现

检测算法具体分 3 步实现:(1)用 WT 对图像作“过分割”,得到盆地标记图;(2)用 RAG 来描述标记图,为简化运算,事先对盆地进行初步筛选,删除不可能是目标的区域,并选出置信度高的盆地作为种子区,其对应的节点为种子点;(3)用遗传算法在 RAG 中寻求优化子图,使得子图对应流域的能量函数极小。图 2 给出了算法框图。

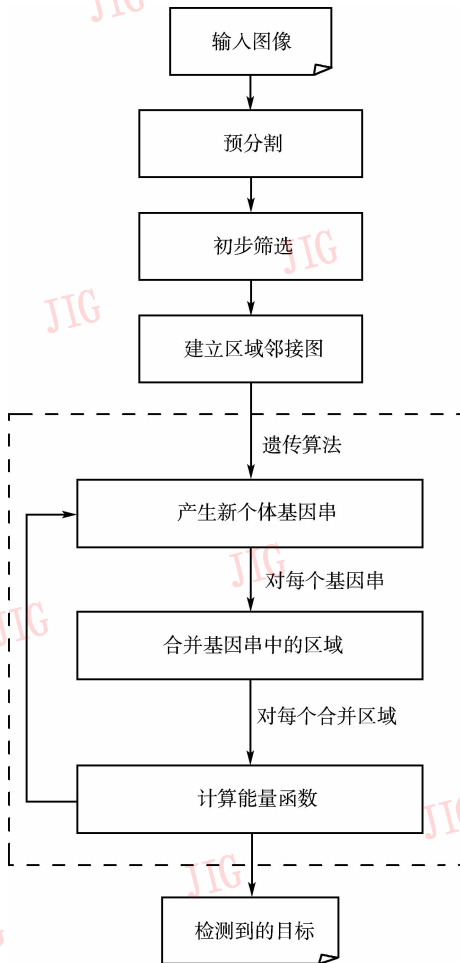


图 2 目标检测算法框图

Fig. 2 Flow chart of the object detection algorithm

#### 3.1 预分割

WT 是图像分割的强有力的形态工具。分割图像时,通常对待分割图像的形态梯度信号进行分割。然而,用 WT 对形态梯度信号进行分割时,梯度信号中每个独立的局部低谷都划归为不同区域,最终导致“过分割”;而且目标本身灰度并不一定均匀,因此有意义的目标通常是其中若干个积

水盆地的组合。我们的任务就是要找到符合目标特征的组合。

在选择具体的分水岭变换算法时,若算法得到的区域过多将导致优化时的计算量过大,但过小又可能将目标与背景合为一个区域,导致检测错误。因此,在应该保证适度的“过分割”。经过实验验证,文献[8]中给出的快速算法可以较好地满足本算法的要求。它是一个迭代标注过程,得到的图像是经标注的积水盆地图像。若输入图像被分割成  $N$  个盆地,则在输出图像中,相对于每一个盆地  $R_i (1, 2, \dots, N)$  的像素,被标注为一特定值  $I(R_i) = i$ 。

#### 3.2 初步筛选并建立区域邻接图

为了减少后续的计算量,提高目标的捕获效率,对于上面得到的所有盆地作初步筛选,滤除不可能是目标的盆地区域,并选取满足一定条件的盆地作为种子区。

灰度和面积是两个直观又易于计算的特征,以此作为初选的判决特征。具体算法如下:计算目标模板  $S$  的归一化灰度直方图  $H(x), x \in [0, 255]$  和面积上限  $T_{sup}$ 。由于目标至少包含一个盆地,所以如果盆地的面积大于  $T_{sup}$  时,该区域肯定不是目标,应予滤除。当盆地  $R$  的平均灰度值  $Grey(R)$  是模板的主流色时(定义为在模板的归一化灰度直方图中取值较大),则该盆地属于目标的置信度较高,应被选作种子区。以上过程可以用下面的伪代码描述。

##### 算法 1 盆地标记图的初步筛选

设  $Area(R)$  表示区域  $R$  的面积,  $\delta$  为预先选定的阈值 ( $0.5 \leq \delta \leq 1$ )。

```
for  $i = 1$  to  $N$ 
begin
```

```
if  $Area(R_i) > T_{sup}$ , then  $I(R_i) = -1$  (删除  $R_i$ );
else if  $H(Grey(R_i)) > \delta$ , then  $i$  加入种子集合  $S_i$ 
中( $R_i$  被选为种子区);
```

```
end
```

筛选后剩下的盆地用区域连接图(RAG)<sup>[11]</sup>来表示。若剩下的盆地个数为  $n$ ,图像的 RAG 为一无向图  $G = (V, E)$ ,节点  $V_i$  对应积水盆地  $R_i (i = 1, \dots, n)$ ,边  $E \in V \times V$  表示节点之间的连接关系,用邻接矩阵来表示。

图 3 给出了一个 RAG 的例子。

对应图 3(a)的区域邻接图 RAG 如图 3(b)所示。其邻接矩阵为

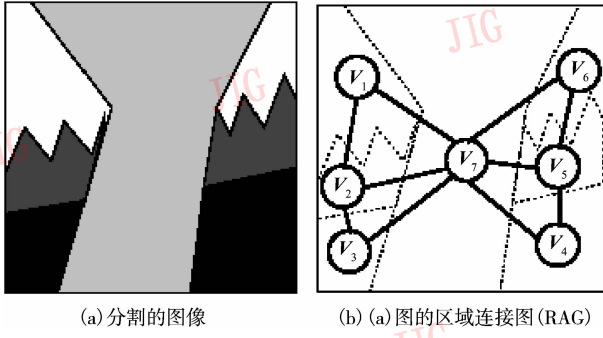


图 3 RAG 示例

Fig. 3 An example of RAG

$$E = \begin{bmatrix} 0 & 1 & 0 & 0 & 0 & 0 & 1 \\ 1 & 0 & 1 & 0 & 0 & 0 & 1 \\ 0 & 1 & 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 1 & 0 & 1 \\ 0 & 0 & 0 & 1 & 0 & 1 & 1 \\ 0 & 0 & 0 & 0 & 1 & 0 & 1 \\ 1 & 1 & 1 & 1 & 1 & 1 & 0 \end{bmatrix}$$

### 3.3 基于启发式遗传算法的能量函数最优化

遗传算法(GA)<sup>[9]</sup>是一种借鉴生物界自然选择和群体遗传机理的高度并行、随机、自适应全局搜索算法。GA 将问题中每个可能解看作是群体中的个体,并将每个个体编码成字符串的形式,根据预定的目标函数对每个个体进行评价,给出一个适应度,模拟自然选择和自然遗传中发生的繁殖、交配和突变现象,实现优胜劣汰,逐步逼近问题的解。由于图像中包含的目标对象可能有多个,因此我们寻求的不是最优解,而是一组优化结果。

#### 3.3.1 编码方法

对遗传算法的个体(染色体) $Ch$ 采用如下的编码方案:每个个体表示从某种子向邻接盆地泄洪所覆盖的流域。流域由很多小的盆地组成,且盆地的个数是不定的。因此个体 $Ch$ 由一个任意长度的基因串表示,每个基因表示组成流域的一个盆地,用其在 RAG 中相应的节点编号表示。第 1 个基因段 $Ch(1)$ 为种子的节点编号,第 $i$ 个基因段 $Ch(i)$ 为第 $i$ 步泄洪对象的节点编号。停止泄洪时的 $i=l$ 为个体长度,即有 $l$ 段基因( $1 \leq l \leq N$ )。图 4 给出了个体数据结构的示意图。为便于表达,基因段 $Ch(i)$ 对应的第 $i$ 个盆地也用 $Ch(i)$ 表示, $Ch$ 既表示染色体,又表示泄洪得到的流域,即一个可能的目标区域。




图 4 个体的数据结构

Fig. 4 The data structure of the chromosome

#### 3.3.2 适应度函数

适应度函数是遗传算法用来判断个体好坏的标准,结果越接近真值,它的值也应该越大。该算法中个体对应图像中的一个流域。前面已经分析了,流域的能量越小,表明是目标的置信度越大,因此该流域对应的个体越接近我们期望的结果,其适应度应该越高,即适应度与流域的能量成反比。由此可以设计适应度函数:设流域 $Ch_i$ 的能量函数为 $E(Ch_i)$ ,则相应个体 $Ch_i$ 的适应度函数取为 $f = 1/E(Ch_i)$ 。 $E$ 的计算如式(1)。

求个体 $Ch_i$ 的各基因段对应盆地的并,得到个体对应的流域 $Ch_i = \bigcup_{j=1}^{l_i} Ch_i(j)$ 。各盆地 $Ch_i(j)$ 的特征函数为 $g_i(j)$ ,则 $Ch_i$ 的平均特征值为

$$\bar{g}_i = \frac{\sum_{j=1}^{l_i} Area(Ch_i(j)) \cdot g_i(j)}{Area(Ch_i)}$$

特征值可以为灰度、颜色等,依据问题选取。由此定义 $E_{image}$ 如下:

$$E_{image}(Ch_i) = \frac{\sum_{j=1}^{l_i} [Area(Ch_i(j)) \cdot (g_i(j) - \bar{g}_i)^2]}{Area(Ch_i)} \quad (2)$$

设期望目标的模型是 $D$ ,它可以通过高层知识来指定,也可以从训练样本中提取。 $Ch_i$ 的属性是 $K_i$ ,于是定义 $E_{object}$ 为

$$E_{object}(Ch_i) = \frac{d_e(K_i, D)}{D} \quad (3)$$

式中, $d_e$ 是棋盘距离测度,定义为

$$\forall p \in \mathbf{R}^m, q \in \mathbf{R}^m$$

$$d_e(p, q) = \max_{k=1}^m \{ |p_k - q_k| \} \quad (4)$$

设目标模型的尺寸下限为 $T_{inf}$ ,上限为 $T_{sup}$ , $T(Ch_i)$ 为 $Ch_i$ 的尺寸函数,可以是区域面积、最小外接圆和最大内接圆的直径或面积等。于是硬约束 $E_{scale}$ 定义为

$$E_{\text{scale}}(\mathbf{Ch}_i) = \begin{cases} \ln T_{\text{inf}} - \ln[T(\mathbf{Ch}_i)] & T(\mathbf{Ch}_i) < T_{\text{inf}} \\ 0 & T_{\text{inf}} \leq T(\mathbf{Ch}_i) \leq T_{\text{sup}} \\ \exp[T(\mathbf{Ch}_i) - T_{\text{sup}}] - 1 & T(\mathbf{Ch}_i) > T_{\text{sup}} \end{cases} \quad (5)$$

### 3.3.3 初始群体的生成

个体的生成采用启发式搜索算法。其基本做法是:从种子集中随机选取一个值作为第1个基因段;接着建立该种子的邻接盆地集合(记录与当前个体中所有节点相邻的节点编号),从中随机地选择一个值作为第2个基因段,形成一个连通子图;然后更新邻接盆地集合,从中继续随机地选择一个值作为下一个基因段,形成新的子图。这样进行下去直至满足硬约束项等于0。得到的个体表示RAG中的一个连通子图,对应图像中的一个流域。

### 3.3.4 选择算子

遗传算法主要基于达尔文的自然选择过程,因此选择强度的大小起着关键作用。选择的步骤与3个因素有关:样本空间、样本机制和选择概率。样本空间由规模和元素(双亲或子孙)两个因素刻画。令 $npop$ 表示群体的大小, $noff$ 表示每一代所产生的子代的大小,在规则的样本空间中,其大小与 $npop$ 相等,包含子代中所有个体和一部分父代个体;在增大的样本空间中,其大小与 $npop + noff$ 相等,包含子代和父代中的所有个体。本文采用规则的样本空间。

从样本空间中选择个体,该算法采用赌轮选择方法。赌轮方法是目前遗传算法中最基本的选择方法,在该方法中,各个体的选择概率和其适应度值成比例。即对于适应度为 $f(\mathbf{Ch}_i)$ 的个体 $\mathbf{Ch}_i$ ,它的选择概率为 $p_i = f(\mathbf{Ch}_i) / \sum_{j=1}^{npop} f(\mathbf{Ch}_j)$ ,概率 $p_i$ 反映了个体 $\mathbf{Ch}_i$ 的适应度在整个群体的个体适应度总和中所占的比例。

此外,还采用了优化个体保留策略,其基本思想是对群体中适应度值超过预定门限的个体不进行交叉而直接复制到下一代中。采用这种方法的优点是,进化过程中某一代的优化解不被交叉和变异操作所破坏。

### 3.3.5 交叉与变异算子

交叉操作是指把两个父代个体的部分结构加以替换重组而生成新个体的操作,它使得遗传算法的搜索能力得以飞跃提高。算法通过轮盘赌随机选择

要进行交叉操作的一个父代个体 $\mathbf{Ch}_i$ ,然后在与其有共同基因段的个体中随机选择另一个父代个体 $\mathbf{Ch}_j$ ,以概率1进行交叉后产生新的个体为 $\mathbf{Ch}_k$ 。根据所求问题的特点,交叉操作采用了局部优化的思想:首先,两个父代共同具有的基因段(节点)被子代所继承,这样做是考虑到父代共有的基因段应该对优化解贡献较大,为此子代应继承。在子代继承这些基因段后,形成的可能是一个不连通的图。随机选择图中其他的节点将形成的不连通图重新相连成为连通图,由此得到新的个体。

变异操作的目的在于保持群体的多样性,避免求解过程陷入局部最优。变异方式如下:首先随机地选择要进行变异的个体,随机地删除某些节点,剩下的节点组成的图可能是不连通的。随机选择图中其他的节点加入其中,保证新得到的图是连通的,由此得到新的个体。

### 3.3.6 收敛条件

当满足下列条件之一时优化算法停止工作:

- (1)已经处理完 $M$ 代群体, $M$ 值为预先给定;
- (2)群体中个体的适应度值不再增加。

### 3.3.7 算法流程

综上所述,上述遗传算法可以用下面的伪代码描述。设 $g$ 表示进化代数, $npop$ 表示群体的规模。复制 $r$ 、交换 $c$ 及突变 $m$ 均为宏算子,将旧群体变换为新群体。

#### 算法2 遗传算法求优化子图

$g := 0$ ;

随机产生初始化群体

$\mathbf{P}^g := \{\mathbf{Ch}_1^g, \mathbf{Ch}_2^g, \dots, \mathbf{Ch}_{npop}^g\}$ ;

repeat

计算 $\mathbf{P}^g$ 的适应度:  $\{f(\mathbf{Ch}_1^g), f(\mathbf{Ch}_2^g), \dots, f(\mathbf{Ch}_{npop}^g)\}$ ;

选择:  $\mathbf{P}^g := r(\mathbf{P}^g)$ ;

交叉:  $\mathbf{P}^g := c(\mathbf{P}^g)$ ;

变异:  $\mathbf{P}^{g+1} := m(\mathbf{P}^g)$ ;

$g := g + 1$ ;

until 终止准则满足。

适应度大于预定门限值的个体作为优化解输出。

## 4 实验结果

为了验证上述算法的有效性,使用 Intel Celeron 466M(内存 256M)微机对不同类型的真实图像进行

各种实验,获得了较为满意的结果。下面以包含汽车的自然图像(含汽车 63 辆)和包含飞机的遥感图像(含飞机 127 架)各 40 幅为例加以说明,图像的平均尺寸为  $256 \times 256$ pixels。

实验图像均为在复杂背景中检测复杂目标,其代表图例分别如图 5、图 6 所示。对每幅输入图像进行“过分割”运算,计算得到的各个盆地的灰度均值。

若均值在待检测目标模板的归一化直方图中对应的纵坐标大于 0.7,则该盆地被选为种子。两类目标的尺度约束都取为面积和主轴长度的尺寸;目标模型采用旋转至与当前区域主轴重叠的目标模板(包括前视、后视或顶视)。优化时,初始群体规模设为 10,变异概率为 0.01。实验结果表明,算法收敛速度快,平均每幅图像在迭代 10 次以内就基本收敛了。

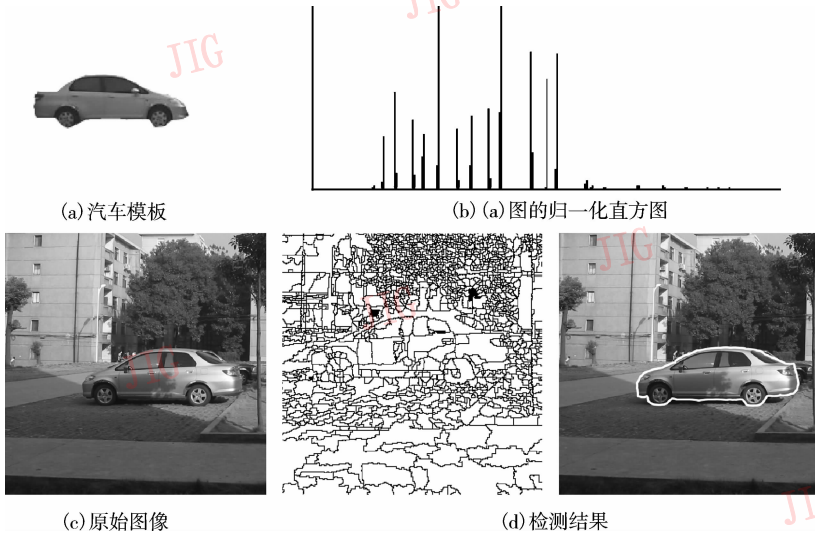


图 5 汽车图例

Fig. 5 The example of cars detections

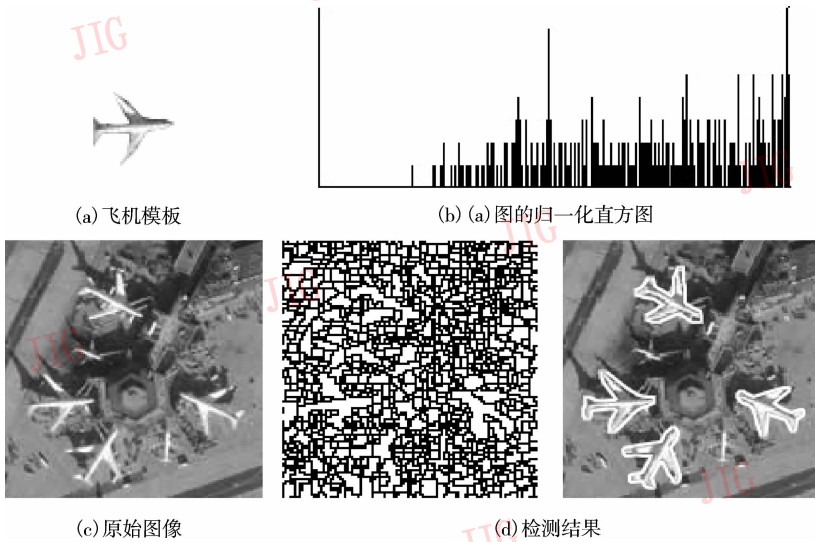


图 6 飞机图例

Fig. 6 The example of plane detections

将本文方法与文献[2]、[10]中的方法进行比较。Tu 等人在文献[2]中先分割图像,再对分割的区域分类,提取指定目标。由于存在多种噪声的扰动,要找到一个适用于自然场景的稳健而实用的低

层处理算法很困难。遥感图像的背景复杂、照明不均匀,使得这种困难显得尤为明显。当目标复杂,灰度不均一时(如飞机、汽车等),一般的分割算法很难提取完整的目标,从而导致检测失败。Zhang 等

人在文献[10]中提出的目标检测算法综合运用神经网络和遗传算法,但是识别是基于像素的,未利用高级特征。对比测试结果如表1所示。其中,检测率  $P_D$ 、虚警率  $P_F$  为

$$P_D = \frac{\text{正确检测到的目标数目}}{\text{目标的实际数目}} \quad (6)$$

$$P_F = \frac{\text{错误检测到的目标数目}}{\text{目标的实际数目}}$$

由表1的结果可见,本文方法的检测能力优于另两种方法,具有较好的平移、尺度和旋转不变性,对于噪声和照度不均也有一定的抵抗力。但是由于实验采用的特征有限,因此仍然存在漏检和虚检目标,这些在选用了更复杂的具有不变性的特征后会得到改善。

表1 目标检测算法的性能比较

Tab.1 Comparisons of three object detection algorithms

指标	Object class	Detection algorithms		
		文献[2]	文献[10]	本文
$P_D$ (%)	Car	52.4	82.5	92.1
	Plane	49.6	85.0	87.4
$P_F$ (%)	Car	1.6	4.8	3.2
	Plane	2.4	4.7	3.1
正确检测目标的个数	Car	33	52	58
	Plane	63	108	111
时间 (s/scene)	Car	9	18	13
	Plane	7	13	11

## 5 结 论

本文提出了一种在图像中自动检测目标的新算法。算法将目标检测问题转化为能量函数优化问题,并采用启发式遗传算法求解。检测结果不依赖于图像分割的优劣,也克服了固定窗口滑动匹配搜索的缺点。算法综合运用特征和模板作为目标的先验知识,适用于多种复杂背景下目标的

检测识别。今后还将在特征学习方面作进一步的研究。

## 参考文献 (References)

- 1 Wang Run-sheng. Image Understanding [M]. Changsha: The Publishing House of National University of Defense Technology, 1995. [王润生, 图像理解 [M]. 长沙: 国防科技大学出版社, 1995.]
- 2 Tu Z, Chen X, Yuille A, *et al.* Image parsing: segmentation, detection, and object recognition [A]. In: Proceedings of IEEE International Conference on Computer Vision 2003 [C], Nice, France, 2003: 18 ~ 25.
- 3 Bravo M J, Farid H. Object segmentation by top-down processes [J]. Visual Cognition, 2003, **10**(4): 471 ~ 491.
- 4 Chen J H, Chen C S, Chen Y S, Fast algorithm for robust template matching with M-estimators [J]. IEEE Transactions on Signal Processing, 2003, **51**(1): 230 ~ 243.
- 5 Lee K M, Street W N. Generalized Hough transforms with flexible templates [A]. In: Proceedings of the 2000 International Conference on Artificial Intelligence (IC-AI) [C], Las Vegas, Nevada, USA, 2000: 1133 ~ 1139.
- 6 Lai K F, Chin R T. Deformable contours: modeling and extraction [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1995, **17**(11): 1084 ~ 1090.
- 7 Roerdink JBTM, Meijster A. The watershed transform: definitions, algorithms and parallelization strategies [J]. Fundament Information, 2000, **41**(1): 187 ~ 223.
- 8 Vincent L, Soille P. Watersheds in digital spaces: an efficient algorithm based on immersion simulations [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1991, **13**(6): 583 ~ 598.
- 9 Koza J R. Survey of genetic algorithms and genetic programming [A]. In: Proceedings of the Wescon' 95 [C], San Francisco, California, USA, 1995, **61485**: 589 ~ 594.
- 10 Zhang M, Ciesielski V. Neural networks and genetic algorithms for domain independent multiclass object detection [J]. International Journal on Computational Intelligence and Applications, 2004, **4**(1): 77 ~ 108.
- 11 Llado J, Marti E, Jose J. Symbol recognition by subgraph matching between region adjacency graphs [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2001, **23**(10): 1137 ~ 1143.