

文章编号: 1672-8785(2016)11-0006-08

基于视觉注意机制和水平集方法的 红外海面目标检测与识别

李春荣¹ 王登位^{2*} 石文君³

(1. 93501 部队 17 分队, 北京 100061;
2. 电子科技大学航空航天学院, 四川成都 611731;
3. 空军第一航空学院航空弹药教研室, 河南信阳 464000)

摘要: 针对传统红外目标检测与识别方法所存在的问题, 即其处理过程总是盲目地对全图进行耗时搜索, 提出了一种基于视觉注意机制和水平集方法的红外海面目标检测与识别方法。首先, 搜索原始图像中的显著性区域, 并以获胜点的形式表示它们。接着, 基于所得到的显著性区域, 自动初始化水平集函数, 并使演化过程朝着期望的目标轮廓方向挺进, 直至演化过程到达最终的平衡状态。最后, 针对远距离(近距离)成像时的输入数据, 给出检测结果(基于不变矩和神经网络框架的识别结果)。对真实红外海面目标进行的实验证实了本文方法的有效性。

关键词: 视觉注意; 水平集方法; 红外成像; 海面目标; 检测; 识别

中图分类号: TP391.4 **文献标志码:** A **DOI:** 10.3969/j.issn.1672-8785.2016.11.002

Infrared Sea Surface Target Detection and Recognition Based on Visual Attention and Level Set Method

LI Chun-rong¹, WANG Deng-wei^{2*}, SHI Wen-jun³

(1. No. 93501 Unit, PLA, Beijing 100061, China; 2. School of Aeronautics and Astronautics, University of Electronic Science and Technology of China, Chengdu 611731, China; 3. Aeronautic Missile Department, the First Aeronautic Institute of Air Force, Xinyang 464000, China)

Abstract: To solve the problem that traditional infrared target detection and recognition methods always blindly carry out time-consuming searching for a whole image in their processing processes, an infrared sea surface target detection and recognition method based on visual attention mechanism and level set method is proposed. Firstly, the salient regions in an original image are searched and are denoted in terms of winner points. Then, on the basis of the salient regions captured, the level set function is initialized automatically and the evolution process is forced to go forward towards the expected target contour until its final equilibrium. Finally, for the input data obtained at a long distance (or at a short distance), the detection results are given (the recognition results based on moment invariants and neutral network framework). The validity of the proposed method is verified in the experiment made on the real infrared sea surface targets.

收稿日期: 2016-07-16

基金项目: 中央高校基本科研业务费(ZYGX2015KYQD032)

作者简介: 李春荣(1980-), 男, 山东莱州人, 工程师, 主要研究方向为雷达系统仿真和运用。

* 通讯作者: E-mail: wdengwei@126.com

Key words: visual attention; level set method; infrared imaging; sea surface target; detection; recognition

0 引言

由于可以处理多维信号并以被动方式工作, 基于红外图像的目标检测与识别技术已经在各个领域得到了广泛应用。

在众多的图像分析任务中, 识别并理解输入图像中的对象是计算机视觉的主要目标之一。在过去的二十年里, 人们提出了各种各样的用于执行目标识别任务的算法。这些方法大致可以分为基于矩的方法^[1-4]、基于知识的方法^[5-7]、基于模型的方法^[8-9]以及基于神经网络的方法^[10-11]等。

为了完成目标存在与否这一决策行为, 这些方法需要在整幅图像上执行校验操作。事实上, 期望的目标通常只是图像区域的一小部分。显然, 无论是在计算性能上, 还是在分析过程的复杂性上, 都存在着较为沉重的负担。

然而, 人类视觉系统却能很好地完成这一任务。当面临一个复杂场景时, 该系统总是选择较少的区域作为处理对象, 这一过程称为视觉注意, 被选中的区域称为注意焦点。视觉注意使人类视觉系统对场景中的每个区域赋以不同的级别和重要性。这里产生了一种选择性处理的效果。在这一机制下, 不必要的计算可以得到有效避免, 而且分析过程的难度也降低了。因此, 将这一机制引入到目标识别中是非常必要的。

基于人类视觉系统的有关机制, 本文提出了一种新的用于搜索图像中的显著性区域的方法。当搜索过程结束时, 我们得到了一组获胜点, 并以圆心位于这些点的圆来表示它们。在本文中, 这些圆是不必要的, 其含义也仅仅在示意层面上。

虽然我们得到了一组显著性区域及获胜点, 但它们的位置通常不是目标的真实位置, 因此后处理过程是必须进行的。

最近, 由 Osher S 等人^[12]设计的水平集方法引起了人们的极大关注。它是一种基于偏微

分方程的图像处理方法, 即先选择一条初始曲线(初始水平集函数对应的零水平集), 然后朝着使能量泛函取值降低的方向演化曲线, 直到演化过程停止在期望目标的轮廓之上。

考虑到应用特点, 我们将水平集方法引入到了信息处理过程的后处理环节之中。在本文中, 对于水平集方法的使用方式有别于传统的使用惯例, 即在初始化水平集函数时, 我们使用了视觉注意算法所提供的先验知识。因此, 对水平集函数的初始化被局限于显著性区域, 以至于传统方法中对初始水平集函数的任意定位问题可以得到有效避免。这样一来, 我们就可得到一种自动初始化水平集函数的方法。处理过程的时间消耗不是取决于图像尺寸, 而是取决于显著性区域的大小。因此, 时间消耗大大降低了。

1 背景技术

1.1 视觉注意机制

视觉注意是人类视觉系统的一种下意识行为。在注视一个场景时, 我们的注意焦点总是会定格在某些物体上。通常情况下, 这些物体要么相对于背景来说较为突出, 要么较为熟悉和易于识别。在图 1 所示的整个纹理背景中, 小模式就能首先引起我们的注意。在上述机制的指引下, 人类在与环境进行交互时就只需要花很短的时间来处理所有的信息。这样一来, 只有一小部分信息(最重要的一部分)得到处理, 而这部分信息又携带有较多的细节。人类视觉系统的这一表现令人惊讶。目前, 该系统所遵循的生理和心理机制还没有被人们完全理解。然而, 有很多众所周知的现象却可以引起我们的注意, 比如运动、形状、颜色以及相对于背景的对比度等^[13]。

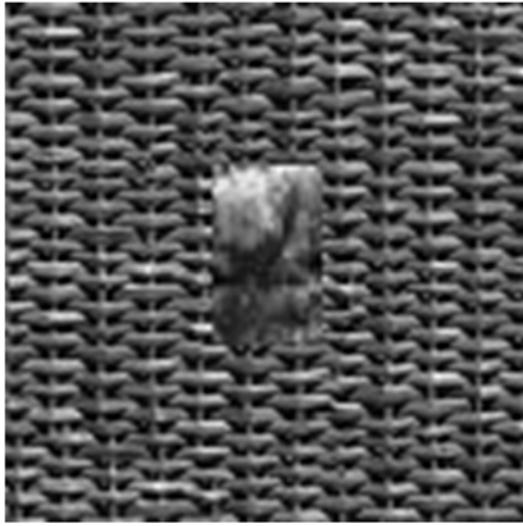


图 1 视觉注意实例

基于显著性的视觉注意的体系模型可以分为基于场景的模型和基于任务的模型两大类。

本文采用基于 Itti L 等人^[14]理论的注意系统, 其显著性模型如下: 输入图像被下采样到高斯金字塔中^[15], 金字塔的每一级都被分解成红(R)、绿(G)、蓝(B)、黄(Y)、强度(I)和局部方向(O_θ)等通道。我们用 r 、 g 和 b 来表示输入图像的红色、绿色和蓝色通道。对于灰度图像而言, $r = g = b$ 。采用图像强度 I 归一化之后, 我们得到 $R = r - (g + b)/2$, $G = g - (r + b)/2$, $B = b - (r + g)/2$ 和 $Y = r + g - 2(|r - g| + b)$ 。 O_θ 可以通过在强度金字塔中引入可操纵的滤波器来获取^[16-17]。

基于上述准备知识, 一组“特征图”可构建如下^[18]:

$$F_{\theta,c,s} = N(|O_\theta(c) - O_\theta(s)|) \quad (1)$$

$$F_{I,c,s} = N(|I(c)\Theta I(s)|) \quad (2)$$

$$F_{RG,c,s} = N(|(R(c) - G(c))\Theta(R(s) - G(s))|) \quad (3)$$

$$F_{BY,c,s} = N(|(B(c) - Y(c))\Theta(B(s) - Y(s))|) \quad (4)$$

式中, $N(\cdot)$ 为一个迭代、非线性的正则化算子; Θ 表示两个图在各自特征金字塔的中心 ($c : c \in \{2, 3, 4\}$) 与邻域级别 ($s : s = c + \delta, \delta \in \{2, 3, 4\}$) 之间的交叉尺度差。对于常规的特征如颜色和方位等, 其贡献被线性叠加并且归一化以生成“显著图”。

基于“赢家通吃”网络, 使显著性图中的位置之间相互竞争以获取最高的显著性值。

在显著性图中找到感兴趣的位置之后, 我们转而确定这些区域的尺寸。首先, 计算与特征图相对应的尺寸显著数组。具体的执行措施如下: 在每个已知位置上构建出不同尺寸的局部区域, 然后计算这些区域与其关联邻域之间在特征层面上的差异性, 并将这些差异性的度量值作为相应尺寸下的局部显著度。如此一来, 便可得到计算过程所需的显著数组。本文采用基于“感受野等级模型”的显著性推理过程。该模型由一组尺寸各异的感受野模板组成, 其中每个模板的组成要素皆为中心兴奋区和外围抑制区。对于指定位置上的某个特定尺寸的局部目标区, 选择一个在尺寸维度上与其相匹配的感受野模板, 使其中心兴奋区和外围抑制区分别对应于前述的局部目标区及其关联邻域。以模板响应输出的绝对值作为两者之间的特征差异。这一过程与视觉感知所能获取到的刺激强度相吻合, 同时亦符合自底向上型视觉显著性过程的形成机理。感受野模板可用 DOG 函数 $DOG(x, y, \sigma_c, \sigma_s)$ 近似表示。其中心兴奋区(正值)的大小由 σ_c 控制, 周边抑制区(负值)的大小由 σ_s 控制^[19]。对于特征图 F_{ij} 中的一组以 $(PosX^k, PosY^k)$ 为重心、以 $r(SizeR_{min} \leq r \leq SizeR_{max})$ 为半径的目标区域, 先由 r 确定 $DOG(x, y, \sigma_c, \sigma_s)$, 然后通过式(5)得到一个显著数组:

$$A_{ij}^k(r) = \left| \sum_{x=-m\sigma_c}^{m\sigma_c} \sum_{y=-m\sigma_s}^{m\sigma_s} DOG(x, y, \sigma_c, \sigma_s) \times F_{ij}(PosX^k + x, PosY^k + y) \right| \quad (5)$$

式中, m 用于控制 DOG 函数的空间范围; $[SizeR_{min}, SizeR_{max}]$ 为感兴趣的显著区域的尺寸范围。

然后依次计算各类特征所对应的尺寸显著数组。这里仍然采用正则化算子 $N(\cdot)$ 来完成这些工作:

$$A_i^k(r) = \frac{1}{FNum_i} \sum_{j=0}^{FNum_i-1} N(A_{ij}^k)(r) \quad (6)$$

$$A^k(r) = \frac{1}{CNum} \sum_{i=0}^{CNum-1} N(A_i^k)(r) \quad (7)$$

式中, A_{ij}^k 为 F_{ij} 所对应的显著数组; A_i^k 为第 i 类特征所对应的显著数组; $FNum_i$ 为第 i 类特征中的特征图数目, $FUum_0 = 1$, $FUum_1 = 4$, $FUum_2 = 3$; $CNum$ 为特征类别数, $CNum = 3$ 。

接着, 我们从尺寸显著数组 A^k 中选择显著值最大的单元所对应的尺寸作为显著区域的新尺寸: $SizeR^k = \arg \max_r A^k(r)$ 。

最后, 我们得到了感兴趣的显著性区域, 其中心位置为 $(PosX^k, PosY^k)$, 半径为 $SizeR^k$ 。

1.2 水平集方法

由 Kass 等人引入的活动轮廓技术采用动态曲线来分割图像中的目标。在过去的几年里, 这一思想已经在相当多的应用中变得非常流行。活动轮廓模型的基本思想是在一定的约束条件下演化一条曲线。在曲线演化问题中, 水平集方法已被人们广泛采用。这一方法首先被 Osher 和 Sethian 用来捕获运动对象的前端数据。为了实现传统的水平集方法, 使水平集函数在演化过程中保持为一个合适的符号距离函数是至关重要的, 尤其是在零水平集附近的邻域之中。为了得到稳定的曲线演化过程并且确保结果可用, 一种称为重新初始化的技术应运而生。该技术通过在演化过程中周期性地对当前水平集函数进行重新初始化, 使其保持为符号距离函数。

Li C M 等人^[20] 提出了一种新的可强迫水平集函数变成符号距离函数的变分方法。因此, 传统方法中所需的重新初始化操作就被完全去掉了。

下面介绍这种方法的基本原理。假设 $I(x)$ 表示输入图像, g 表示边缘指示函数:

$$g = \frac{1}{1 + |\nabla G_\sigma * I(x)|^2} \quad (8)$$

式中, G_σ 为标准方差为 σ 的高斯卷积核。

该模型的能量泛函 E 可表示为

$$E(\phi) = \mu \int_{\Omega} \frac{1}{2} (|\nabla \phi| - 1)^2 dx dy$$

$$+ \lambda \int_{\Omega} g \delta(\phi) |\nabla \phi| dx dy + \nu \int_{\Omega} g H(-\phi) dx dy \quad (9)$$

式中, $\mu > 0$ 、 $\lambda > 0$ 及 ν 均为常数; H 为 Heaviside 函数。 $E_m(\phi) = \lambda \int_{\Omega} g \delta(\phi) |\nabla \phi| dx dy + \nu \int_{\Omega} g H(-\phi) dx dy$ 表示某一能量泛函, 它可以驱使 ϕ 的零水平集向前移动。其中 $\delta(\phi)$ 通常采用以下的平滑形式:

$$\delta_\varepsilon(\phi) = \begin{cases} 0, & |\phi| > \varepsilon \\ \frac{1}{2\varepsilon} \left[1 + \cos \left(\frac{\pi\phi}{\varepsilon} \right) \right], & |\phi| \leq \varepsilon \end{cases} \quad (10)$$

式中, ε 为狄拉克函数支撑区间的半宽度。通过变分法的有关规则, 我们可以得到式 (9) 所示的能量泛函的加托微分:

$$\begin{aligned} \frac{\partial E}{\partial \phi} = & -\mu \left[\Delta \phi - \operatorname{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) \right] \\ & - \lambda \delta(\phi) \operatorname{div} \left(g \frac{\nabla \phi}{|\nabla \phi|} \right) - \nu g \delta(\phi) \end{aligned} \quad (11)$$

式中, Δ 为拉普拉斯算子; $\frac{\partial \phi}{\partial t} = -\frac{\partial E}{\partial \phi}$ 为最小化能量泛函 E 的梯度下降流。于是我们可以得到最小化能量泛函 ε 的最陡下降过程即以下梯度流方程:

$$\begin{aligned} \frac{\partial \phi}{\partial t} = & \mu \left[\Delta \phi - \operatorname{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) \right] \\ & + \lambda \delta(\phi) \operatorname{div} \left(g \frac{\nabla \phi}{|\nabla \phi|} \right) + \nu g \delta(\phi) \end{aligned} \quad (12)$$

在对式 (12) 所示的定义于连续空间中的表达式进行数值求解时, 我们采用 $\varepsilon = 5$ 的正则化形式的狄拉克函数。所有关于空间变量的偏导数 (如 $\frac{\partial \phi}{\partial x}$ 与 $\frac{\partial \phi}{\partial y}$) 均采用中心差分来近似, 所有关于时间变量的偏导数均采用前向差分来近似。因此, 式 (12) 可被离散化为以下的前向差分格式:

$$\frac{\phi_{i,j}^{k+1} - \phi_{i,j}^k}{\Delta t} = L(\phi_{i,j}^k) \quad (13)$$

式中, Δt 为迭代过程的时间步长; $L(\phi_{i,j}^k)$ 为式 (12) 右边所有项的数值近似。另外, $L(\phi_{i,j}^n)$ 中的

曲率项 $\kappa = \operatorname{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right)$ 采用以下二阶中心差分格式来实现离散化：

$$\kappa = \operatorname{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) = \frac{\phi_{xx}\phi_y^2 - 2\phi_{xy}\phi_x\phi_y + \phi_{yy}\phi_x^2}{(\phi_x^2 + \phi_y^2)^3/2} \quad (14)$$

$$\phi_x = \frac{1}{2h}(\phi_{i+1,j} - \phi_{i-1,j}) \quad (15)$$

$$\phi_y = \frac{1}{2h}(\phi_{i,j+1} - \phi_{i,j-1}) \quad (16)$$

$$\phi_{xx} = \frac{1}{2h}(\phi_{i+1,j} + \phi_{i-1,j} - 2\phi_{i,j}) \quad (17)$$

$$\phi_{yy} = \frac{1}{2h}(\phi_{i,j+1} + \phi_{i,j-1} - 2\phi_{i,j}) \quad (18)$$

$$\phi_{xy} = \frac{1}{2h}(\phi_{i+1,j+1} - \phi_{i-1,j+1} - \phi_{i+1,j-1} + \phi_{i-1,j-1}) \quad (19)$$

式中, h 为空间步长。

综上所述, 式(12)的离散化格式为

$$\begin{aligned} \frac{\phi_{i,j}^{k+1} - \phi_{i,j}^k}{\Delta t} &= \mu \cdot (\phi_{i+1,j}^k + \phi_{i-1,j}^k \\ &\quad + \phi_{i,j+1}^k + \phi_{i,j-1}^k - 4\phi_{i,j}^k) + \lambda \cdot \delta(\phi_{i,j}^k) \\ &\times \left\{ g_{i,j} \kappa + \left[g_x^k \frac{\phi_x^k}{\sqrt{(\phi_x^k)^2 + (\phi_y^k)^2}} + g_y^k \frac{\phi_y^k}{\sqrt{(\phi_x^k)^2 + (\phi_y^k)^2}} \right] \right\} \\ &\quad + \nu \cdot g_{i,j} \cdot \delta(\phi_{i,j}^k) \end{aligned} \quad (20)$$

基于式(20), 即可在计算机中通过编程来实现整个迭代过程。

2 算法

本文算法可以分为以下两个阶段：视觉注意模型搜索阶段和水平集方法演化阶段。在第一阶段, 该算法自动搜索具有最大局部强度对比度的区域, 然后搜索具有最大局部方向对比度的区域, 接着通过“赢家通吃”策略找到第一个最显著的获胜点及其对应的显著性区域, 最后按照显著性依次降低的顺序得到一组获胜点。对于接下来的第二阶段, 第一阶段的显著性区域扮演的是一个提供先验知识的角色。这是本文方法与传统的水平集方法之间最为显著的不同点, 因为前者具有对演化过程实施自动初始化的能力。与传统的任意初始化方式相比, 本文

方法可以极大地减少盲目性, 因为感兴趣的目标通常只是图像区域的一小部分。因此, 传统方法无论是在计算性能上, 还是在分析过程的复杂性上, 都存在较为沉重的负担。在第二阶段, 基于第一阶段所捕获到的获胜点, 我们构建出了一条初始的活动轮廓。它是初始水平集函数所对应的零水平集。然后根据式(12)演化曲线, 直至演化过程停止在期望目标的轮廓之上。有一点我们在此必须指出, 即本文算法的时间消耗不是取决于图像尺寸, 而是取决于显著性区域的大小, 因此所需的处理时间大大减少。与传统的水平集方法相比, 本文方法具有非常明显的优势。

本文方法的处理流程如下: (1) 使用视觉注意算法搜索显著性区域, 并以获胜点的形式对其进行定位; (2) 根据获胜点构建初始演化曲线; (3) 根据式(12)更新水平集函数, 直至收敛为止; (4) 当输入图像的成像距离较近时, 对步骤(3)所得的区域块进行基于不变矩和神经网络的识别操作, 否则仅给出检测结果(此时对应的成像距离较远)。

3 实验结果

为了评估本文方法在目标检测与识别方面的性能, 我们在大量的真实图像上对其进行了测试。本文使用一些在海边采集的中波红外图像, 采集当天的大气能见度为 10 km。为了获知目标的红外特性, 成像器在一天之中持续工作。我们发现, 目标的红外特性在一天中的各个时段是不同的。本文从这些图像中随机选取一部分来开展实验。我们采用相同的参数, 其取值如下: 时间步长 $\Delta t=5$, $\varepsilon=1.5$, $\sigma=1.5$, $\mu=0.04$, $\lambda=5$, $\nu=1.5$ 。

3.1 远距离情况下的小目标检测

当成像距离较远时, 典型舰船目标在红外成像面上呈斑状或小目标状。此类目标仅占整个图像或场景中的极小部分。此时, 目标的无形状特征或形状特征不明显。在这种情况下, 仅需考虑对舰船的检测任务。

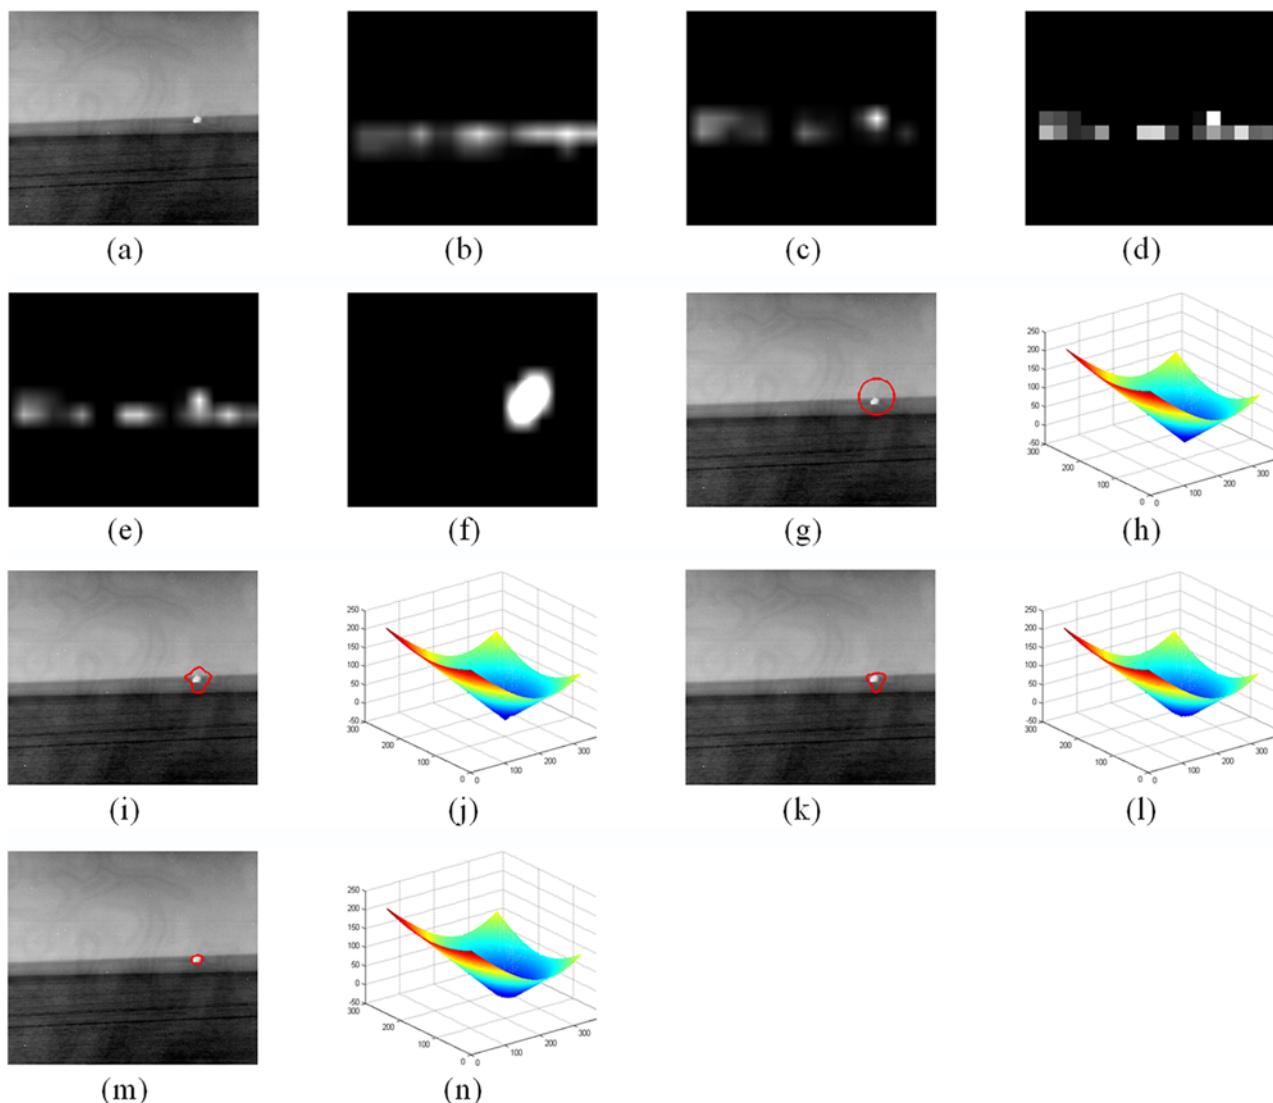


图 2 远距离情况下的目标检测实例: (a) 原始图像; (b) 强度显著性图; (c) 方向显著性图; (d) 显著性图; (e) “赢家通吃”后的结果; (f) 二进制形状图; (g) 显著性区域(初始轮廓); (h) 相应于(g)的水平集函数; (i) 第 50 次迭代结果; (j) 相应于(i)的水平集函数; (k) 第 190 次迭代结果; (l) 相应于(k)的水平集函数; (m) 最终结果(300 次迭代); (n) 相应于(m)的水平集函数

本文采用在秋季拍摄的由 1070 帧图像组成的图像序列, 其成像距离为 7 km。实验结果表明, 共有 1018 帧图像被正确检测, 检测概率为 95%。图 2 所示为本文方法对该序列中某一帧图像的完整检测流程。其中, 图 2(a) 为原始的输入图像, 图 2(b) ~ 图 2(e) 为根据本文前面介绍的方法所得到的强度显著性图、方向显著性图、显著性图以及“赢家通吃”后的结果。下面介绍图 2(f) 所示的二值形状图的获取途径。当我们得到显著性图后, 为了更好地对水平集的演化过

程进行初始化, 需要得到空间上相对集中的目标区域。为此我们作以下变换: 首先, 将显著性图分割成几个连通的区域, 然后从这些区域中选择一个显著性最强的区域(面积和亮度), 接着作一些形态学上的处理(膨胀等操作), 最后将得到的结果缩放至原始图像的大小, 此时即可得到二值形状图。这个二值形状图不仅不会改变显著性的本质效果, 而且还能更好地突出特性显著的目标。在本文以后的处理中, 我们以二值形状图作为初始化水平集的依据。图 2(g) ~

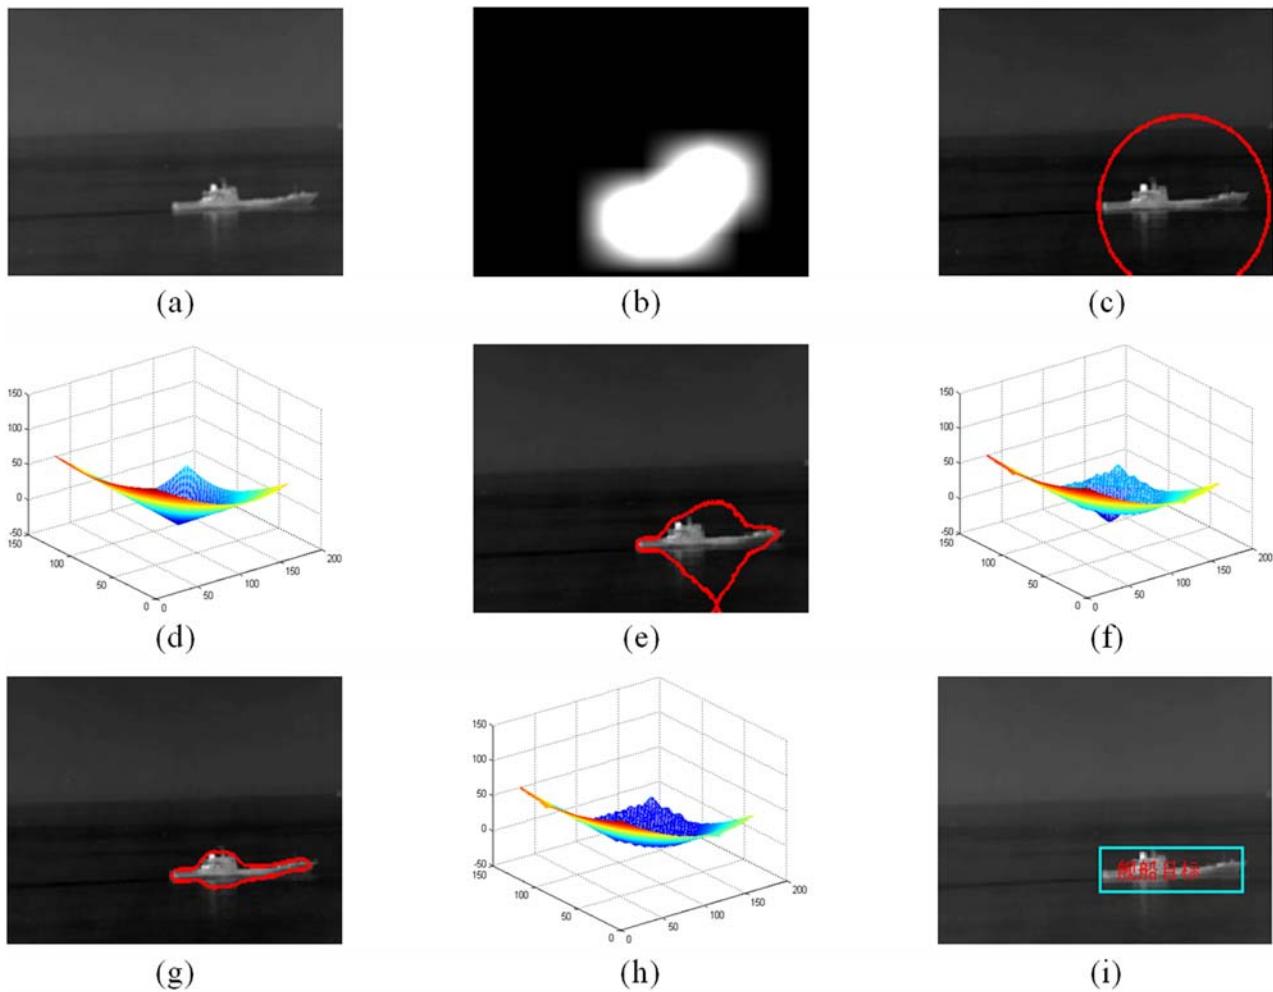


图 3 近距离情况下的单目标识别实例: (a) 原始图像; (b) 二进制形状图; (c) 显著性区域(初始轮廓); (d) 相应于(c) 的水平集函数; (e) 第 472 次迭代结果; (f) 相应于(e) 的水平集函数; (g) 水平集演化过程的最终结果(900 次迭代); (h) 相应于(g) 的水平集函数; (i) 神经网络识别结果

图 2(n) 所示为后续水平集演化过程的对应结果。

3.2 近距离情况下的面状目标准识别

当成像距离较近时, 舰船目标在成像面上将会呈现出较为完整的形态。这种情况下的图像解译任务可以拓展至识别这一级。为了有效地对水平集演化过程的输出(包含有效的和无效的区域块)结果执行识别任务, 我们采取以下策略: (1) 记录典型舰船目标在高斯扩展球面映射^[21]下的全空间形式的特性视图集; (2) 选择特性视图集中的典型样本, 计算其 22 维的矩不变量特征, 并将它作为特征向量来训练神经网络; (3) 利用训练好的神经网络来一一甄别图像中的区域块, 直至输出所有结果为止。

参与试验的第一个图像序列由 1000 帧图像组成, 其成像距离为 2.3 km, 拍摄时间为秋季。实验结果表明, 共有 990 帧图像被正确识别, 识别概率为 99%。图 3 所示为本文方法对该序列中某一帧图像的完整检测流程。其中, 图 3(a) 为原始的输入图像, 图 3(b) 为视觉注意搜索过程输出的二进制形状图(其定义方式与图 2(f) 相同), 图 3(c)~图 3(h) 所示为后续水平集演化过程的对应结果, 图 3(i) 所示为最终的识别结果。

4 结束语

本文提出了一种用于红外海面目标检测与识别的新颖算法。该算法有效地融合了视觉注意机制和水平集方法。首先, 搜索原始图像中

的显著性区域，并以获胜点的形式表示它们。其次，基于显著性区域，朝着期望的目标轮廓演化水平集函数，直至演化过程到达最终的平衡状态。最后，针对远距离(近距离)成像时的输入数据，给出检测结果(基于不变矩和神经网络框架的识别结果)。基于视觉注意的水平集方法的亮点是，其时间消耗不是取决于图像尺寸，而是取决于显著性区域的大小。该机制为水平集演化过程提供了一种自动初始化的方式。实验结果表明，本文方法非常有效。

参考文献

- [1] 马岱, 高尚兵, 张青. 基于不变矩的海面红外目标识别 [J]. *中国科技信息*, 2007, **18**(1): 336–337.
- [2] Li Y. Applications of Moment Invariants to Neurocomputing for Pattern Recognition [J]. *Electronics Letters*, 1991, **27**(7): 587–588.
- [3] Shen Y Z, Wang Q C, Yu S M. A Target Recognition of Wavelet Neural Network Based on Relative Moment Features [C]. Hangzhou: Fifth World Congress on Intelligent Control and Automation, 2004.
- [4] 张琦, 樊养余. 基于小波矩不变量的海上目标识别 [J]. *计算机工程与科学*, 2007, **29**(2): 59–61.
- [5] Zhu B, Li J Z, Cheng A J. Knowledge Based Recognition of Harbor Target [J]. *Journal of Systems Engineering and Electronics*, 2006, **17**(4): 755–759.
- [6] Shi G Z, Hu J C, Da L L, et al. Target Recognition Study Using SVM, ANNs and Expert Knowledge [C]. Qingdao: IEEE International Conference on Automation and Logistics, 2008.
- [7] Li W, Wu X Q. Recognition of Small Targets by Random Matching Algorithm Based on Prior Experience [J]. *Computer Engineering and Applications*, 2003, **12**(1): 110–113.
- [8] Bhanu B, Lin Y Q. Stochastic Models for Recognition of Occluded Targets [J]. *Pattern Recognition*, 2003, **36**(12): 2855–2873.
- [9] Andrew R W. Gamma Mixture Models for Target Recognition [J]. *Pattern Recognition*, 2000, **33**(12): 2045–2054.
- [10] Engin A, Ibrahim T, Mustafa P. Intelligent Target Recognition Based on Wavelet Packet Neural Network [J]. *Expert Systems with Applications*, 2005, **29**(2): 175–182.
- [11] Park S I, Mark J T S, Russell M M. Target Recognition Based on Directional Filter Banks and Higher-order Neural Networks [J]. *Digital Signal Processing*, 2000, **10**(3): 297–308.
- [12] Osher S, Sethian J A. Fronts Propagating with Curvature-dependent Speed: Algorithms Based on Hamilton-Jacobi Formulations [J]. *Journal of Computational Physics*, 1988, **79**(1): 12–49.
- [13] Stentiford F W M. An Evolutionary Programming Approach to the Simulation of Visual Attention [C]. Coex: 2001 Congress on Evolutionary Computation, 2001.
- [14] 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.
- [15] Burt P, Adelson E. The Laplacian Pyramid as a Compact Image Code [J]. *IEEE Transactions on Communications*, 1983, **31**(4): 532–540.
- [16] Simoncelli E, Freeman W. The Steerable Pyramid: A Flexible Architecture for Multi-scale Derivative Computation [C]. Washington: 2nd IEEE International Conference on Image Processing, 1995.
- [17] Manduchi R, Perona P D. Efficient Deformable Filter Banks [J]. *IEEE Transactions on Signal Process*, 1998, **46**(4): 1168–1173.
- [18] Dirk W, Ueli R, Christof K, et al. Selective Visual Attention Enables Learning and Recognition of Multiple Objects in Cluttered Scenes [J]. *Computer Vision and Image Understanding*, 2005, **100**(1): 41–63.
- [19] 张鹏, 王润生. 基于视点转移和视区追踪的图像显著区域检测 [J]. *软件学报*, 2004, **15**(6): 891–898.
- [20] Li C M, Xu C Y, Gui C F, et al. Level Set Evolution without Re-initialization: A New Variational Formulation [C]. San Diego: IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2005.
- [21] 张天序. *成像自动目标识别(第一版)* [M]. 武汉: 湖北科学技术出版社, 2005.