

文章编号: 1007-4619(2008)04-0586-07

基于 MSA 特征的遥感图像多目标关联算法

雷 琳, 蔡红苹, 唐 涛, 粟 毅

(国防科学技术大学 电子科学与工程学院, 湖南 长沙 410073)

摘 要: 遥感图像中多目标关联存在以下两个问题: 一是低时间分辨率观测使得目标状态信息无法准确估计, 基于 Kalman 滤波的多目标关联算法不再适用; 二是基于图像特征的目标关联算法又无法处理大场景观测中多个目标关联引起的模糊性。针对上述问题, 提出一种基于多尺度自卷积特征匹配和关联代价矩阵最优化的多目标关联算法。实验表明该算法对遥感图像中多目标关联问题具有一定的适用性。

关键词: 遥感图像; 目标关联; 多尺度自卷积; 关联代价矩阵

中图分类号: TP75 **文献标识码:** A

1 引 言

目标关联是面向目标识别的遥感图像融合系统中的重要步骤, 是目标变化检测、跟踪及融合识别等应用实现的前提。利用多源遥感图像进行目标关联, 就是将两幅 (或多幅) 图像中同一目标的信息对应起来, 即判断一幅图像中的某一目标信息究竟来源于另一幅图像中的哪一个目标, 这实际上是一个目标配对问题。由于不同成像传感器在性能上的差异 (如时间不同步、分辨率和定位精度不同) 和目标分布情况等因素的影响, 使得目标信息提取具有不确定性, 导致多目标关联关系模糊, 系统很难判断两幅待融合图像中的目标信息是否源于同一个目标。因此, 如何利用遥感图像信息进行目标关联, 成为面向目标识别的多源遥感图像融合系统中一个亟待解决的关键问题。

当前利用图像数据进行目标关联的方法大致分为两种。一是借鉴传统的基于 Kalman 滤波的数据关联与跟踪方法^[1,2], 即利用多帧图像累积的目标状态信息进行关联和跟踪。典型的有最近邻关联 (NN)、联合概率数据关联 (JPDA)、多假设滤波 (MHT) 等。这类方法的前提是需要时间采集较密

的观测数据, 且目标运动模型简单而易于估计。二是借鉴计算机视觉中的单目标匹配和定位方法^[3]。典型的有互相关模板匹配、不变特征匹配等。此类方法的前提是图像中跟踪的目标单一, 且背景较为简单。

对于遥感图像数据, 由于现实环境中无法获取同一区域连续多个时刻的遥感图像, 所以很难预测目标的状态参量, 传统的关联与跟踪方法显然不能解决这种问题。必须寻求其他不以时间为依赖的信息作为关联量, 即基于目标图像特征的匹配和定位。但是这类方法面对多目标关联问题时缺乏合理的关联准则, 无法处理特征对应关系的模糊性。本文从解决这些局限性出发, 提出一种基于目标多尺度自卷积特征匹配和关联代价矩阵最优化的算法来解决遥感图像中多目标关联问题。首先根据仿射不变特征提取方法, 构造目标的多尺度自卷积 (Multi-scale Autoconvolution, MSA) 特征, 克服遥感成像中视点变化或目标姿态变化等因素对图像不变特征提取的影响, 以此作为目标关联的关联量。然后利用特征匹配相似度构造多目标关联代价矩阵 (Association Cost Matrix, ACM), 以此描述多目标对应关系的模糊性。最后基于模拟退火算法求解最优 ACM, 得到最终多目标关联结果。

收稿日期: 2007-03-07; 修订日期: 2007-05-18

基金项目: “十五”国防预研资助项目 (编号: 513220206)

作者简介: 雷 琳 (1980—), 女。分别于 2002 年和 2003 年在国防科技大学电子科学与工程学院获信息与通信工程专业学士和硕士学位, 现为该校电子科学与工程学院在读博士。研究方向为遥感图像处理与分析、图像融合与目标识别。E-mail: alaleilin@163.com。

2 遥感图像多目标关联问题的描述

传统的数据关联与跟踪 (泛指各种 Kalman 滤波)是不可分离的,因为它们依赖于跟时间有关的目标状态信息为关联量。统一的数学描述一般是基于状态空间方法,建立离散时间的目标运动模型。以最典型的联合概率数据关联算法为例,当在含有多个目标的复杂环境下进行跟踪时,在 $k-1$ 时刻目标状态信息定义成如下序列: $\{x^i(k-1|k-1)\}_{i=1,\dots,n(k-1)}$, $n(k-1)$ 表示 $k-1$ 时刻的目标数。 k 时刻获取的测量为 $\{z^j(k)\}_{j=1,\dots,m(k)}$, $m(k)$ 表示 k 时刻确认的量测个数。首先利用动态方程 $x_k^i = f_k(x_{k-1}^i, v_k^i)$ 预测出当前的状态信息 $\{x^i(k|k-1)\}$, 然后利用量测方程 $z_k^j = h_k(x_k^i, n_k^i)$ 推导出 k 时刻量测 j 对目标 i 进行 Kalman 滤波所得的状态估计 $\{x_j^i(k|k)\}$ 。联合概率数据关联算法就是要求得 k 时刻量测 j 与目标 i 关联的后验概率 $\beta_{ij}(k)$, 以此来更新目标 i 的状态信息 $x^i(k|k) = \sum_{j=0}^{m(k)} \beta_{ij} x_j^i(k|k)$ 。

本文所探讨基于图像特征的遥感图像多目标关联是指特定针对遥感图像的不依赖于时间的目标描述与关联。但可以将多目标数据关联中联合后验概率估计的思想引入到基于图像特征的目标关联中来;将前一图像中目标 i 的特征 f_{i1} , $i=1,\dots,n$ 与后一图像中目标 j 的特征 f_{j2} , $j=1,\dots,m$ 相比较,得到相似性测度 β_{ij} 。只是不用概率密度估计来衡量两者关联的概率,而是利用图像特征匹配结果作为两者之间的相似测度。这样要考虑的不是状态信息随时间变化的不确定性,而是目标图像特征提取的不确定性引起的关联模糊。

因此,图像目标关联就要寻求使多目标关联模糊性最小的关联结果,即一幅图像中的某一目标在另一图像中都有一个匹配序列,多目标关联最终是要以稳健的关联策略和方法来搜索到一个全局最优关联结果。假设两个目标群的目标数量一样,那么对应关系很自然地可用一个可行的关联矩阵 $S = [s_{ij}]_{n \times n}$ 来描述, $s_{ij}=1$ 表示图像 1 中目标 i 与图像 2 中目标 j 相关联。给定 d_{ij} , $i=1, 2, \dots, n$, $j=1, 2, \dots, n$ 为两目标的关联代价 ($d_{ij} \propto 1/\beta_{ij}$), 那么关联代价矩阵就表示为: $C = [d_{ij} \times s_{ij}]_{n \times n}$ 。关联的最终目的,就是根据“ S 中每一行 (每一列) 只有一个值为 1”这样一个约束条件,寻求一个使关联结果最优的 ACM (能量最小)。至此,多目标关联问题就成为一个组

合优化问题。

3 多尺度自卷积不变矩特征

遥感图像中目标不变特征提取的难点在于: (1) 不同传感器成像特性不同,如分辨率、感光度等; (2) 成像时间和环境不同,造成照度、目标姿态的改变。目前研究较热的图像仿射不变特征对于遥感图像目标识别具有重要的意义,体现了目标在几何仿射变换下所具有的不变性,克服了视点变化或目标姿态变化对特征量的干扰。

常用的图像仿射不变特征是不变矩特征,主要反映了图像灰度统计方面的特性,最具代表性的就是 Hu 矩特征^[4]。在 Hu 矩的基础上,又发展出许多新的不变矩构造方法。但是大部分不变矩特征在某些数据上的交叉和不理想的期望值使得其在目标发生变化时使用范围有限。所以研究可分性好、抗噪性能强的仿射不变特征一直是研究者的追求。2005 年 Esa Rahtu 提出了多尺度自卷积方法^[5],实践证明是目前最稳健的不变矩特征之一,本文正是基于目标的 MSA 特征构造多目标关联代价矩阵。

3.1 数学定义

MSA 方法的基本原理是:图像中的任意 (随机) 不共线三点的坐标可以线性表示出图像中任意其他一点的坐标。当图像发生仿射变换时,这 4 个点的线性表示形式不变,即线性表示时的系数不变, Rahtu 正是利用这种系数不变的性质构造仿射不变量。MSA 变换中将不共线 3 个随机点坐标的概率用这些点对应的归一化灰度值来表示,这种表示形式虽然在物理意义上不具有可解释性,但并不影响其数学上的推导。

设 $f: R^2 \rightarrow R$ 且 $f \geq 0$ 是定义在 $L^1(R^2) \cap L^2(R^2)$ 上的图像灰度函数,令归一化灰度函数为图像上该点的概率密度函数:

$$p(x,y) = \frac{f(x,y)}{\iint_{R^2} f(x,y) dx dy} \tag{1}$$

式中, R^2 是图像灰度函数的定义域。设 R^2 上 3 个点 x_0, x_1, x_2 是服从独立的同分布随机变量。对于任意 $\alpha, \beta \in R$ 以这 3 个点来定义新的随机变量:

$$u_{\alpha, \beta} = \alpha(x_1 - x_0) + \beta(x_2 - x_0) + x_0 \tag{2}$$

式中, (α, β) 是 $u_{\alpha, \beta}$ 在以 x_0 为原点、 $x_1 - x_0$ 和 $x_2 - x_0$ 为单位向量仿射空间 A^2 的坐标。令 $r=1-\alpha-\beta$

β , 那么 $u_{\alpha, \beta} = \alpha x_1 + \beta x_2 + \gamma x_0$ 。定义仿射变换后的图像为 $f'(x') = f(Tx + t)$, 由 (1) 式的定义, p' 也就是图像 f' 的概率密度函数。那么原来图像上的坐标点 $u_{\alpha, \beta}$ 经过仿射变换得到:

$$Tu_{\alpha, \beta} = \alpha(Tx_1 - Tx_0) + \beta(Tx_2 + Tx_0) + Tx_0 \quad (3)$$

令 $u'_{\alpha, \beta} = Tu_{\alpha, \beta} + t$ 可见, 经过坐标系仿射变换后随机变量 $u'_{\alpha, \beta}$ 的坐标仍然是 (α, β) 。因为仿射变换前后 $f(u_{\alpha, \beta})$ 与 $f'(u'_{\alpha, \beta})$ 具有同样的坐标 (α, β) , 所以该点在两幅图像上的概率密度函数是同一个确值。于是由点 $u_{\alpha, \beta}, u'_{\alpha, \beta}$ 在平面上的任意性, 定义特征为 $u_{\alpha, \beta}, u'_{\alpha, \beta}$ 的概率密度函数的数学期望:

$$\begin{aligned} F(\alpha, \beta) &= E[f(u_{\alpha, \beta})], \\ F'(\alpha, \beta) &= E[f'(u'_{\alpha, \beta})] \end{aligned} \quad (4)$$

单纯从数学上考虑积分元素在积分域内的任意性, 可知 $F(\alpha, \beta) = F'(\alpha, \beta)$, $F(\alpha, \beta)$ 就是仿射变换的不变特征。

3.2 基本性质及实现

由概率论知识可知, 如果 X, Y 是平面 R^2 中的相互独立的变量且各自的概率密度函数为 p_X, p_Y , 那么新的变量 $Z = aX + bY$ 的概率密度函数为: $p_Z = \frac{1}{a^2 b^2} \left[p_X \left(\frac{X}{a} \right) \times p_Y \left(\frac{Y}{b} \right) \right]$ 。所以点 $u_{\alpha, \beta}$ 的概率密度也可以由 x_0, x_1, x_2 的概率密度表示, 即:

$$q(u | \alpha, \beta) = \frac{1}{(\alpha\beta\gamma)^2} \iint_{R^2} p \left(\frac{u - x_2 - x_1}{\alpha} \right) \times p \left(\frac{x_2}{\beta} \right) p \left(\frac{x_1}{\gamma} \right) dx_2 dx_1 \quad (5)$$

求数学期望得:

$$\begin{aligned} F(\alpha, \beta) &= E[f(u_{\alpha, \beta})] = \int_{R^2} f(u) q(u | \alpha, \beta) du \\ &= \frac{1}{(\alpha\beta\gamma)^2} \frac{1}{\|f\|^3} \iiint_{L_1 R^2 \times R^2} f(u) \left(\frac{u - x}{\alpha} \right) \times F \left(\frac{y}{\beta} \right) \left(\frac{u - x - y}{\gamma} \right) dx dy du \end{aligned} \quad (6)$$

对于大小为 $N_1 \times N_2$ 的图像, 用傅里叶变换将时域卷积变为频域相乘, (6) 式简化计算得:

$$\begin{aligned} F(\alpha, \beta) &= \frac{1}{N_1 N_2} \frac{1}{\hat{f}(0)^3} \sum_{R^2} \hat{f}(-\xi) \hat{f}(\alpha\xi) \times \hat{f}(\beta\xi) \hat{f}(\gamma\xi) \end{aligned} \quad (7)$$

数学推理和实验都证明, $F(\alpha, \beta)$ 在仿射变换图像中具有仿射不变性、对称性、凸性等性质。其中最重要的一点就是对称性, 根据对称关系可以找到 (α, β) 平面上一个固定小区域, 就可取到所有的

变换值。这样的区域有多种取法, 文献 [5] 在实现过程中通过在集合 $\{-1, -0.75, -0.5, -0.25, 0, 0.25, 0.5, 0.75, 1\}$ 中取任意两元素的组合构成 29 对 (α, β) 值, 计算 MSA 特征的 29 个分量。

4 基于 ACM 最优化的多目标关联算法

4.1 ACM 构造

提取出各目标的 MSA 特征后, 通过 $d_{ij} = \|f_{i1} - f_{j2}\|$, $i=1, 2, \dots, n$; $j=1, 2, \dots, m$ 可获得任意两目标的 MSA 特征匹配代价, 其中 f_{i1} 为前一幅图像中目标 i 的 k 维 MSA 特征, f_{j2} 为后一幅图像中目标 j 的 k 维 MSA 特征。对于任何一个可行的关联矩阵 S 就可构成一个 ACM: $C = [d_{ij} \times s_{ij}]_{n \times n}$ 。为保证 C 为一方阵, 必须将匹配代价的定义扩展至目标群中目标数量不一致的情况。假设 $n > m$, 在含 m 个目标的图像 2 中增加 $n-m$ 个虚假目标。那么它们的匹配代价可定义为: $d_{ij} = D_d$ ($i=1, 2, \dots, n$; $j=m+1, \dots, n$), 且 $D_d > \max\{d_{ij}\}$, ($i=1, 2, \dots, n$; $j=1, 2, \dots, m$)。至此, 关联的目的就是对于所有可行的关联矩阵 S 寻求其相应 ACM 能量最小的状态。

4.2 ACM 最优化描述

上述的关联代价矩阵最优化问题是具有 NP 复杂度的组合优化问题。设 $C = \{C_1, C_2, \dots, C_k\}$ 为所有可能的 ACM 的集合, $E(C_i)$ 为 C_i 下的目标函数。ACM 优化问题的数学描述为: $E(C^*) = \min E(C_i)$, $C^* \in C$, $\forall C_i \in C$ 。可见, 目标函数是对 ACM 的量化描述, 是可能的 ACM 状态组合到某个数集的一个映射。此外, 为了将关联矩阵 S 限制于“每一行 (每一列) 只有一个值为 1”范围之内, 需将此约束条件作为惩罚项加入目标函数, 形成一个求解新目标函数最小的无约束问题。

本文的 ACM 有 n^2 个元素, 这样一个网络的最低能量状态 (网络最稳定的状态) 对应了最优关联结果。根据前述约束条件, 第一, 目标函数的全局最小值对应求解结果。第二, 目标函数应该包含惩罚项。因此, E 可以定义成如下形式 [6]:

$$\begin{aligned} E &= \frac{A}{2} \sum_i \left| \sum_j s_{ij} - 1 \right| + \frac{B}{2} \sum_j \left| \sum_i s_{ij} - 1 \right| + \\ &\quad \frac{C}{2} \left| n - \sum_k \sum_i s_{ik} \right| + D \sum_i \sum_j d_{ij} s_{ij} \end{aligned} \quad (8)$$

其中,当且仅当关联矩阵 S 每一行(每一列)最多只有一个元素为 1,其余元素为 0 时,第一项(第二项)的和为 0。当且仅当 S 中只有 n 个值为 1 的元素时,第三项为 0。对于一个有效的求解结果,前三项惩罚项应当为 0,任何偏离都会迅速增大 E 的值。因此,令 A, B, C 为大的正常量。当前三项都为 0 时,第四项为关联的实际代价。

4.3 模拟退火寻优

设图像中的目标数为 n ,则要从 $n!$ 个可能解中找出最优 ACM。当目标数较大时,如此求精确解是不可行的。为了快速搜索最优关联结果,须采用近似算法。其中模拟退火算法可取任意初始值,且最终收敛到全局最优,对上述一类组合优化问题具有很好的普适性。这里采用模拟退火来加速求解最优 ACM。

模拟退火算法源于对融化晶体退火过程的模拟,是工程中常用的一种加工方法。对融化晶体骤然降温,融化晶体一般会被结晶成不规则晶体。而如果是逐渐降温,在一个温度下保持一段时间,然后再降低到另一个接近的温度保持一段时间,则融化晶体会结晶成规则的晶体(能量最小)。因为降温是逐渐的,在每个温度下晶体内所有原子的能量趋于均衡后再接受下一个降温过程,所以晶体最终达到了能量最小状态。

这种在一个恒定温度下达到热平衡的过程可用 Monte Carlo 方法进行模拟,但该方法必须大量采样才能得到比较精确的结果,计算量很大。1953 年, Metropolis 等提出了重要性采样法,采样时着重选取有重要贡献的状态,则可以较快达到较好结果。Metropolis 算法接受新状态的准则为:给定原子初始状态 i 作为晶体的当前状态,该状态的能量是 E_i 。然后随机选取某个原子并随机地产生一微小变化,得到一个新状态 j ;新状态的能量为 E_j 。如果 $E_j < E_i$,则选取新状态 j 作为重要状态;如果 $E_j > E_i$,则依据晶体处于该状态的概率 χ 来判断该状态是否为重要状态。

$$\chi = \exp\left\{\frac{E_i - E_j}{kT}\right\} \tag{9}$$

式中, k 为 Boltzmann 常数, T 为晶体温度。每次产生一个 $[0, 1]$ 区间的随机数 ξ ,若 $\chi > \xi$ 则将新状态 j 作为重要状态,否则舍去。若新状态 j 是重要状态,就以 j 取代 i 成为当前状态,否则仍以 i 为当前状态。再重复若干以上新状态产生过程,系统在此温

度下趋于能量较低的平衡状态。
本文设关联代价矩阵 C_i 及其目标函数 $E(C_i)$ 分别与晶体的一个微观状态 i 及其能量 E_i 等价,则对于 T 的每一取值,模拟退火算法持续进行“产生新解—判断—接受/舍弃”的迭代过程,也就是执行一次 Metropolis 算法,求得给定 T 值时 ACM 的相对最优解。随后逐渐减小控制参数 T 的值,重复执行 Metropolis 算法,就可以在控制参数 T 趋于零时,最终求得 ACM 的整体最优解。实验中设初始温度 $T_0 = 5000$,控制参数 $T_i = \Delta T \times T_{i-1} = 0.95T_{i-1}$,最终温度 $\delta = 0.1$, Metropolis 算法的长度 $N_M \leq 50$ (接受和拒绝次数之和),关联矩阵元素个数为 n^2 ,则模拟退火算法的计算复杂度为:

$$C_{SA} = N_M \times \log_{\Delta T} \left(\frac{\delta}{T} \right) \times O(n^2)$$

式中, $O(n^2)$ 为计算一次目标函数值的复杂度。当目标数越大时,则利用模拟退火算法寻优更具有时间优势。

5 仿真及性能分析

实验首先提取出某光学图像场景中 12 个不同种类的舰船切片,然后对各个切片进行随机仿射变换或加上一定等级的高斯噪声。这样就构成了多组 12 个待关联的目标切片,原始目标切片和其中 4 组仿真图如图 1。

以图 1(a)中的目标群和其仿真的待关联目标群图 1(b)进行特征提取和关联为例:首先计算各目标的 29 维 MSA 特征,得到两两匹配代价;然后随机初始化关联矩阵 $[s_{ij}]$,并得到其相应的关联代价矩阵 C 如下:

$$[s_{ij}] = \begin{pmatrix} 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \end{pmatrix}$$

C=

18	3355	1632	895	1837	6610	687	1291	915	1371	5778	14671
5677	182	1044	1761	938	137	9225	1287	1730	1219	57	2516
2852	138	86	399	78	1091	5387	277	384	262	801	5343
1338	674	73	9	128	2407	3250	66	11	84	1934	7946
3218	116	171	540	104	874	5852	384	522	367	631	4911
9420	1255	2864	4033	2615	140	13791	3308	3981	3199	307	854
243	5769	3292	2244	3554	9782	47	2963	2281	3093	8811	19372
2983	71	212	489	174	974	5734	215	467	187	662	4985
1424	605	55	20	108	2285	3396	47	16	60	1820	7717
2159	267	121	227	126	1564	4595	44	209	29	1155	6218
7604	651	1947	2902	1758	22	11648	2251	2854	2153	54	1462
20313	6498	9860	11921	9446	3349	26552	10548	11836	10336	3998	311

最后,利用基于模拟退火的 ACM最优化算法,得到 ACM 能量最小时对应的关联矩阵 $[s_{ij}]_{SAE_{min}}$ 。同时实验给出了利用最近邻关联算法得到的最终关联矩阵 $[s_{ij}]_{NN}$ 以作比较。结果表明,通过全局寻优获取的关联矩阵,能克服图像特征匹配引起的关联模糊性,获得更稳健的多目标关联结果。

$[s_{ij}]_{SAE_{min}} = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix}$

$[s_{ij}]_{NN} = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix}$




图 1 目标切片图
(a)原图; (b)原图 +17%高斯噪声;
(c)原图 +30%高斯噪声; (d)随机仿射变换 1;
(e)随机仿射变换 2

Fig. 1 Target chips
(a) original images (b) original+17% Gaussian noises
(c) original+30% Gaussian noises (d) random affine transformation1; (e) random affine transformation2

并利用最近邻 (NN)算法进行关联。关联正确率随仿射变换而变化的统计结果如图 2 关联正确率随噪声大小的变化如图 3。可以看出,由于 MSA 特征的稳定性和抗噪性都优于 Hu矩特征,所以在相同的实验环境中,基于 MSA特征的目标关联结果都优于基于 Hu矩特征的关联结果。

从图 3中还可看出,MSA +NN方法在噪声等级增加加大时,关联正确率同样会急速下降。这是因为当噪声等级偏高时,MSA 特征稳定性降低,很难区分外形相似的目标,且最近邻关联算法又无法解决这种关联模糊性。而本文基于 ACM最优化的方法考虑了整体关联代价,具有一定的抗模糊性。图 3中同样显示了基于模拟退火的 ACM最优化算

法 ($MSA + SAE_{min}$) 的关联正确率, 明显可看出其解决多目标关联问题的高效性, 得到了更为稳定的关联结果。




图 2 随机仿射变换下关联正确率的统计结果
Fig.2 Association accurate ratio vs. random affine transformation




图 3 关联正确率随噪声等级变化的统计结果
Fig.3 Association accurate ratio vs. noise level

6 结 论

在遥感图像中实现多目标关联, 有别于基于状

态信息的数据关联, 目前鲜有可供参考的研究思路和方法。本文将图像中多目标关联问题, 分解为目标特征匹配和多维组合优化两个问题, 提出基于目标 MSA 特征和关联代价矩阵最优化的多目标关联方法。通过仿真实验得到以下结论: (1) 本文通过提取 MSA 这一图像特征作为目标的关联量是有效的, 避免了遥感图像无法获取与时间相关的状态特征这一瓶颈; (2) 与 NN 局部最优算法比较, 本文通过最优化 ACM 解决了多目标间的关联模糊性, 是一种全局最优算法, 在高密度目标环境下也有很好的关联性能; (3) 模拟退火等近似算法能够大大加快多目标最优化关联搜索, 使复杂关联算法具有实际操作性。今后, 基于图像特征的多目标关联方法需结合实际的应用背景, 在目标联合关联概率建模这一方面进一步深入研究。

参考文献 (References)

[1] Kang Y H. Data Fusion: Theory and Application[M]. Xidian University Press. 1997. [康耀红. 数据融合理论与应用[M]. 西安电子科技大学出版社, 1997.]
[2] Dorin Comaniciu, Peter Meer. Kernel-Based Object Tracking [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence. 2003, 25(5): 564—577.
[3] Wu Q X. A Correlation-Relaxation-Labeling Framework for Computing Optical Flow-Template Matching from a New Perspective [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence. 1995, 17(8): 843—853.
[4] Hu M K. Pattern Recognition by Moment invariant[A]. Proc IEEE[C]. 1961.
[5] Esa Rahtu, Mikko Salo, Janne Heikkilä. Affine Invariant Pattern Recognition Using Multiscale Autoconvolution[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence. 2005, 27(6): 908—917.
[6] Achintya K Mandal, Srinanta Pal et al. Novel Approach to Identify Good Tracer Clouds From a Sequence of Satellite Images [J]. IEEE Transactions on Geoscience and Remote Sensing. 2005, 43(4): 813—818.

A MSA Feature-based Multiple Targets Association Algorithm in Remote Sensing Images

LEI Lin CAI Hong-ping TANG Tao SU Yi

(School of Electronic Science and Engineering, National Univ. of Defense Technology, Hunan, Changsha 410073, China)

Abstract Target identification fusion based on multi-source remote sensing images can make full use of the redundancy and complementary information from all sensors, acquiring more accurate result of target recognition. One of the pre-condition of identification fusion is target association, which is to determine if the information from two or more images are related to the same target and should be fused together. Due to different performance of sensor and diverse target distribution, the extracted information of targets generally has some uncertainty, which results in the difficulty in judging whether the information from two images is originated from the same target. Therefore, how to utilize the information of remote sensing images to distinguish multi-target association has become an urgent problem.

There are two kinds of methods concerning target association when using image data: one is Kalman filtering based data association and tracking, which utilizes accumulated kinematic information of multi-frame images to estimate and track. Typical methods are Nearest Neighbor (NN), Joint Probabilistic Data Association (JPDA), Multiple Hypothesis Tracking (MHT) and so on. These methods need dense sampling of observed data, and the target motion model should be simple. The other one uses image match in computer vision for reference. Typical methods are cross correlation matching, feature matching and so on. These methods usually work on condition that only single target is concerned.

For remote sensing images, there are two problems when associating multiple targets in them. Firstly, it is incapable to acquire a series of multi-temporal remote sensing images on the same region at present, so the kinematic state of a target cannot be estimated accurately with low temporal resolution data and the classical Kalman filtering association algorithms are no more applicable. We must seek for other time-independent information as the associating measurement, which can be image invariant feature. Secondly, there are two uncertainties lying in image feature extraction of a target. One uncertainty lies in determining invariant features due to various image distortions such as rotation, scaling and so on. The other lies in establishing feature correspondences between any two consecutive images. So, it is difficult to discriminate the ambiguity of multiple targets' correspondences when using image matching-based association method.

In order to solve above problems, a novel multiple targets association method based on image invariant feature matching and Association Cost Matrix (ACM) global optimization is proposed. At first, the Multi-scale Autoconvolution (MSA) transform of a target is computed based on affine invariant theory and is used as association measurement, which can overcome the negative influence of changes in target's pose, imaging viewpoint and so on. Secondly, the association cost matrix is constructed based on the dissimilarities of MSA feature matching of any two target pairs from two images respectively, representing the correspondence illegibility of two targets. Finally, the minimal energy of ACM is found using simulated annealing (SA) algorithm, and the global optimal association result is achieved.

From the simulation experiments, some conclusions can be drawn as follows: (1) Using image invariant features to perform target association is a valid way, overcoming the bottleneck that the time-dependent kinematic feature cannot be estimated from sparse remote sensing image series. (2) Compared with the NN local algorithm, the optimization of association cost matrix is a global optimal algorithm and has excellent performance in dense targets circumstance. (3) The approximate algorithms such as SA can greatly improve the search of optimal association cost matrix, and then make complex association method practicable.

Key words remote sensing images; target association; multi-scale autoconvolution; association cost matrix