

基于相对形状上下文的低分辨率遥感影像阵群目标关联算法

刘平¹ 周滨² 赵键³

(南阳理工学院计算机与信息工程学院 南阳 473004)¹

(中国人民解放军驻一二二厂军事代表室 哈尔滨 150066)²

(国防科学技术大学电子科学与工程学院 长沙 410073)³

摘要 目标关联是遥感影像融合处理的重要步骤,本质上是目标配对问题。针对低分辨率遥感影像中阵群目标的特点,提出了一种基于点模式匹配的阵群目标关联算法。首先提出一种新的基于点集的不变特征——相对形状上下文特征,然后建立了以相对形状上下文特征的统计检验匹配测度为基础的阵群目标关联数学模型。为了求解该模型,在构造新的相容性度量函数来初始化关联概率矩阵后,利用松弛标记法通过迭代逐步更新关联概率矩阵,同时通过行列双向正则化最终得到满足一对一约束的最优关联匹配结果。通过仿真和实际数据实验验证了新算法的有效性和鲁棒性。

关键词 阵群目标关联,点模式匹配,相对形状上下文,松弛标记法

中图分类号 TP391 **文献标识码** A

Association Algorithm of Group Target in Low-resolution Remote Sensing Images Based on Relative Shape Context

LIU Ping¹ ZHOU Bin² ZHAO Jian³

(School of Computer and Information Engineering, Nanyang Institute of Technology, Nanyang 473004, China)¹

(Military Representative Office in 122 Factory of PLA, Harbin 150066, China)²

(School of Electronic Science and Engineering, National University of Defense Technology, Changsha 410073, China)³

Abstract One of the important pre-condition of identification fusion based on remote sensing images is target association, which is to determine if the information from two or more images are related to the same target. A novel and robust point pattern matching method was presented for group target association in low-resolution remote sensing images. A new point set based invariant feature, Relative Shape Context (RSC), was proposed. We used the test statistic of relative shape context descriptor's matching scores as the foundation of mathematics model of group target association. For resolving the model, we firstly constructed the new compatibility measurement and used it to initialize the association probability matrix. Then the association probability matrix can be updated by relaxation labeling. The one-to-one matching can be achieved by dual-normalization of rows and columns in the end. Experiments on both synthetic point-sets and on real world data show that the group association algorithm is effective and robust.

Keywords Group target association, Point pattern matching, Relative shape context, Relaxation labeling

1 引言

目标关联是面向目标识别的遥感图像融合处理中的重要步骤,是目标跟踪及融合识别等应用实现的前提。利用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,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^[1]。目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滤波的数据关联与跟踪方法^[2,3],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、联合概率数据关联、多假设滤波等。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基于图像特征的目标匹配和定位方法^[1,4]。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分辨率较高,目标的图像特征较多,且背景较为简单。

对于遥感影像数据,由于现实环境中无法连续获取同一区域内相近时刻的遥感影像,很难预测目标的状态参量,因此传统的基于滤波的关联方法显然不能解决这种问题。在低分辨率的遥感影像中,目标图像特征较少,基于图像特征的关联方法也不适用,因此必须寻求其他不以时间和单个目标图像特征为依赖的信息作为低分辨率遥感影像数据的关联量。通

到稿日期:2012-10-20 返修日期:2013-01-08

刘平(1980-),女,硕士,讲师,主要研究方向为图像处理、模式识别, E-mail: lpingsally@163.com;周滨(1978-),男,硕士,工程师,主要研究方向为图像处理、模式识别;赵键(1978-),男,博士,工程师,主要研究方向为计算机视觉与智能信息处理、模式识别。

常情况下,阵群目标(如舰船编队、车辆群等)常常以相对固定的编队出现。在较长的时间间隔下,阵群编队队形可以作为低分辨率遥感影像阵群目标关联的关联量。由于低分辨遥感影像的刈幅宽度较大,有可能观测到整个阵群目标,而且影像中阵群的各个目标的尺寸远远小于目标之间的距离,可以将阵群中个体目标抽象为点目标,因此基于编队队形的阵群目标关联的问题也就转化为两个点模式(或称点集)之间的匹配问题。

目前点模式匹配算法有两大类^[5],一是基于变换关系求解的算法,其通过估计点集之间的空间变换参数,利用该参数恢复或模拟点模式间的变换来求解点模式匹配问题,该算法也称为基于变换参数估计的算法。目前,这类算法主要有迭代最近点算法^[14]、基于图匹配的算法^[6]、基于薄板样条插值变换模型的算法^[7]等。二是基于匹配关系求解的算法,其通过提取点集中点的特征而后运用匹配识别方法获得点模式间的匹配关系,从而求解点模式匹配问题,该算法更形象地称为基于特征的匹配算法。目前,这类算法主要有基于谱图论的方法^[8]、基于形状上下文的方法^[9]、基于松弛标记法的方法^[10]等。

受复杂环境以及阵群目标机动性的影响,低分辨率遥感影像阵群目标的检测过程中会存在大量的虚警(或称出格点(Outliers)),以及存在阵群队形不会严格保持一致(存在队形变换和位置噪声)的情况。而现有的点模式匹配方法普遍对出格点、噪声比较敏感。本文从解决这些局限性出发,提出了一种对出格点和噪声等具有较强鲁棒性的点模式匹配算法来解决低分辨率遥感影像阵群目标关联的问题。本文第2节描述了低分辨率遥感影像阵群目标关联问题的数学模型;第3节提出了一种新的基于点集的不变特征——相对形状上下文特征,并将其与形状上下文特征^[9]进行了比较;第4节是新的基于点模式匹配的阵群目标关联算法的具体实现过程;第5节为本文算法与其它两种算法在仿真数据和真实图像数据下的性能比较实验;最后为结论和展望。

2 低分辨率遥感影像阵群目标关联问题的数学模型

本文所探讨的遥感影像阵群目标关联是指特定针对低分辨率遥感图像的基于阵群编队队形的目标关联。以分辨率为20米的Spot4影像中的海上舰船编队为例,假设其中某一艘大型舰船尺寸为200×80米,在理想情况下,其在影像中仅占10×4像素单位,而编队中个体目标之间的距离通常会在几千米甚至几十千米之上^[16]。在分辨率为8~9米的Radarsat-1遥感影像中的车辆个体目标的尺寸对于车辆阵群队形的影响也是可以忽略不计的。因此,本文将阵群个体目标抽象为点目标,并取图像中所检测到的目标质心位置作为对应的点目标的位置矢量,再将这些点目标的位置矢量组成点模式(或称点集)来代表阵群目标。

假设前一图像(或称模板图像)中有 n 个目标的位置矢量组成的点集 $P = \{p_i | i=1, 2, \dots, n\}$,其中 $p_i = (x_i, y_i)$ 。后一图像(或称目标图像)中有 m 个目标的位置矢量组成的点集 $Q = \{q_j | j=1, 2, \dots, m\}$,其中 $q_j = (x'_j, y'_j)$ 。 m 与 n 不一定相同(考虑检测中会存在虚警和漏警情况)。两幅图像中阵群目标的关联对应关系可用关联矩阵 $M = [M_{ij}]_{n \times m}$ 来描述,矩阵中的元素 M_{ij} 表示 $p_i \in P$ 与 $q_j \in Q$ 的关联对应关系, M_{ij} 可

以用离散值来表示,如 $M_{ij} \in \{0, 1\}$, M_{ij} 取值1时表示两点是关联的,取值0时则表示不关联。 M_{ij} 也可以用连续值来表示,如 $M_{ij} \in [0, 1]$,类似于概率取值,越接近于1表示两者存在关联的可能性越大,反之,关联可能性越小。本文将 M_{ij} 取离散值的关联矩阵称为关联关系矩阵, M_{ij} 取连续值的关联矩阵称为关联概率矩阵。

考虑到模板和目标点集中均会存在出格点和缺失点的情况,如果需要满足一对一的关联匹配约束,可以将关联矩阵 M 扩展为一个 $(n+1) \times (m+1)$ 的扩展关联矩阵。它分别将点集 P 的第 $n+1$ 点和 Q 的第 $m+1$ 点作为虚点(dummy)。当 P 的某一点不与 Q 中的任何一点对应时,该点就被指定与 Q 的虚点对应, Q 中出格点亦作同样处理。此时,在一对一的约束条件下,对任意的 $(n+1) \times (m+1)$ 扩展关联矩阵 M ,满足:

$$\begin{cases} \sum_{i=1}^{n+1} M_{ij} = 1, & j=1, 2, \dots, m \\ \sum_{j=1}^{m+1} M_{ij} = 1, & i=1, 2, \dots, n \end{cases} \quad (1)$$

给定任意点对 (p_i, q_j) 的某一相似性测度函数 C_{ij} ,设关联代价函数 $C(P, Q, M)$ 为:

$$C(P, Q, M) = \sum_{i=1}^n \sum_{j=1}^m M_{ij} C_{ij} \quad (2)$$


因此,一般情况下的阵群目标 P 与 Q 的关联问题就转化为在满足式(1)的一对一约束条件下的求解最优关联矩阵 \hat{M} 的优化问题:

$$\hat{M} = \arg \min_M C(P, Q, M)$$

3 相对形状上下文

点集中点的特征是描述点在点集中个体属性的信息,相应的特征提取是对该信息进行提取的过程,目的是实现点与点之间的匹配识别,它是基于特征的特征点模式匹配算法的重要前提步骤。目前点集中点的特征提取方法有:直接把点在欧氏空间中的坐标信息作为点的特征^[14];通过构造仿射变换下的Hu矩来获取点集中点的不变特征^[11];通过构造点集Voronoi图或Delaunay三角网的方法来提取点的特征^[12];通过对点集间邻近矩阵或Laplace矩阵进行特征值分解得到矩阵的谱和特征向量,从而获取点集中点的谱图特征^[13];通过形状上下文(Shape Context, SC)^[9]算子对点集整体形状进行描述,从而提取点的特征等。

得到广泛应用的形状上下文^[9]是一种用于刻画目标形状的描述子(算子),如图1所示。



(a) 形状上下文描述子的空间划分方法 (b) 点 p_i 的形状上下文特征,颜色越深表示落入该部分的点的数量越多

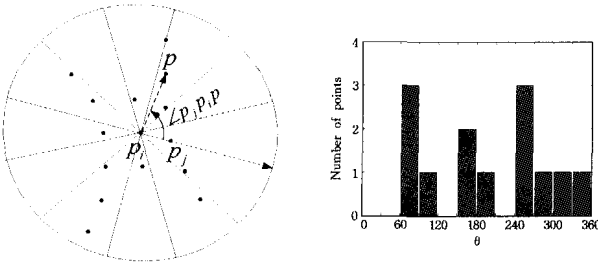
图1 形状上下文描述子

实质上点集中每个点的形状上下文就是点集中其它点相对于该点的角度以及对数距离的直方图分布。具体方法是对任意点 p_i 提取特征时,以其为原点把点集分布的空间按对数极坐标划分为 60 个部分,其中对数距离 $\log \rho$ 分为 5 部分,角度 θ 分为 12 部分。而后记录除 p_i 点外的 $n-1$ 个点在这 60 个部分的分布数目 $b_k (k=1,2,\dots,60)$,将该数目作为 p_i 的特征。

形状上下文描述子具有平移不变性;为达到旋转不变性,可以将每个点处的切线方向作为对数极坐标轴的正方向;为具备尺度不变性,可以先求点集中所有点对之间的平均距离,然后用该值来规则化所有的点对距离;形状上下文描述子由于在距离上的不均匀分组方式及其较为丰富的形状特征描述能力,而具有对局部区域形变的不变性。但是,当出格点较多和噪声较严重时,形状上下文描述子的上述不变性就会变得较差。为了解决这些局限性,本文提出了一种新的鲁棒性较强的形状特征描述子——相对形状上下文(Relative Shape Context, RSC)。

定义 1 如图 2 所示,在具有 n 个点的点集 P 中,任意点 p_i 相对于其他任意点 p_j 的相对形状上下文 $H_{p_{ij}}(s)$ 就是在以 p_i 为原点、矢量 $\overrightarrow{p_i p_j}$ 为正轴的极坐标系下,点集中其他的 $n-2$ 个点相对于该极坐标系正方向的极角所构成的直方图分布,即:

$$H_{p_{ij}}(s) = \# \{ p \neq p_i, p_j : p, p_i, p_j \in P, \theta(p - p_i, \overrightarrow{p_i p_j}) \in \text{bin}(s) \} \quad (4)$$



(a) 相对形状上下文描述子的空间划分方法 (b) 点 p_i 相对于点 p_j 的相对形状上下文直方图

图 2 相对形状上下文描述子

相对形状上下文描述子与形状上下文描述子的区别为:不需要特别选定每个点处的极坐标系正方向来达到完全的旋转不变性;不需要计算 $\log \rho$ 项,对所有的点只考虑其相对于极坐标系正方向的极角。与形状上下文相比较,本文所提出的相对形状上下文具有以下优点:具备平移和旋转不变性;不必计算各点对之间的对数距离,因此具有尺度不变性;由于不需要计算点集中所有点对之间的平均距离来实现距离项的规则化,因此相对形状上下文对出格点和噪声具有较强鲁棒性。

考虑到相对形状上下文描述子是基于直方图分布的特征,本文采用 χ^2 统计检验作为相对形状上下文的相似性匹配测度^[9]。在点集 P 中,设点 p_i 相对于点 p_k 的相对形状上下文为 $H_{p_{ik}}$ 。在点集 Q 中,设点 q_j 相对于点 q_l 的相对形状上下文为 $H_{q_{jl}}$,则两者的相似性匹配测度为:

$$C_{ik,jl} = \frac{1}{2} \sum_{s=1}^S \frac{[H_{p_{ik}}(s) - H_{q_{jl}}(s)]^2}{H_{p_{ik}}(s) + H_{q_{jl}}(s)} \quad (5)$$

式中, S 为相对极角直方图的总项数(本文中取 $S=12$)。若 $C_{ik,jl}$ 越小,则点 p_i 相对于点 p_k 的相对形状上下文特征与点

q_j 相对于 q_l 的相对形状上下文特征越相似。

4 阵群目标关联算法具体实现

本节的主要任务是首先建立阵群目标关联数学模型,其次以相对形状上下文的相似性匹配测度为基础初始化关联匹配概率矩阵,最后通过松弛迭代求解最优的关联匹配矩阵。

4.1 阵群目标关联数学模型

设 $C_{ik,jl}$ 是点集 P 中的点 p_i 相对于点 p_k 的相对形状上下文特征与点集 Q 中的点 q_j 相对于点 q_l 的相对形状上下文特征之间的相似性匹配测度。 $C_{ki,ij}$ 为 p_k 相对于 p_i 的相对形状上下文与 q_l 相对于 q_j 的相对形状上下文的相似性匹配测度。阵群目标的关联对应关系用扩展关联矩阵 $M = [M_{ij}]_{(n+1) \times (m+1)}$ 来描述,对于给定的 $C_{ik,jl}$ 和 $C_{ki,ij}$,可令关联代价函数为:

$$C(P, Q, M) = \sum_{i=1}^n \sum_{j=1}^m \sum_{k=1}^n \sum_{l=1}^m M_{ij} M_{kl} C_{ik,jl} C_{ki,ij} \quad (6)$$

当需要满足一对一关联约束时,阵群目标 P 与 Q 的关联问题就转化为在满足式(1)所示的一对一约束条件下求最优关联矩阵 M 的优化问题:

$$\hat{M} = \arg \min_M C(P, Q, M) \quad (7)$$

式中,当 M 为关联关系矩阵,即 $M_{ij} \in \{0, 1\}$ 时,式(7)的优化求解是一个 NP-hard 的离散组合寻优问题。本文利用松弛标记法^[15]来求最优解,此时离散的 M_{ij} 通过松弛可以连续化为 $M_{ij} \in [0, 1]$,式(7)就转化成求解有一对一关联约束条件的最优关联概率矩阵的最优化问题。

4.2 关联概率矩阵初始化

松弛标记法是局部寻优算法,初始关联概率矩阵的获取是关键前提。考虑到相对形状上下文特征的不变性和鲁棒性,本文利用相对形状上下文特征的相似性测度函数来构造相容性度量函数,并以此为基础来实现关联概率矩阵的初始化。

令模板点集为 P ,目标点集为 Q ,设 $p_i \leftrightarrow q_j$ 表示点 $p_i \in P$ 与点 $q_j \in Q$ 是匹配对应的。设点集间任意两对匹配点存在某种关系,这种关系表征这两对点匹配情况的共存程度,此共存程度称为相容性,通常用数值来描述。设 $p_i \leftrightarrow q_j$ 与 $p_k \leftrightarrow q_l$ 这两对匹配点同时存在情况下的相容性度量为 $C(i, j, k, l)$,在某一规定的值域中,相容性强则 $C(\cdot)$ 值较大,不相容则 $C(\cdot)$ 值较小。本文利用相对形状上下文特征的相似性匹配测度 $C_{ik,jl}$ 来构造相容性度量函数 $C(i, j, k, l)$,即:

$$C(i, j, k, l) = \frac{1}{1 + (C_{ik,jl} + C_{ki,ij})^2} \quad (8)$$

式中, $C_{ik,jl}$ 为 p_i 相对于 p_k 的相对形状上下文与 q_j 相对于 q_l 的相对形状上下文的匹配测度; $C_{ki,ij}$ 为 p_k 相对于 p_i 的相对形状上下文与 q_l 相对于 q_j 的相对形状上下文的匹配测度。式(8)中 $C(i, j, k, l)$ 的物理意义为:当 p_i 与 q_j 是正确匹配点对且 p_k 与 q_l 也是正确匹配点对时, $C_{ik,jl} = 0$ 且 $C_{ki,ij} = 0$,从而 $C(i, j, k, l) = 1$,此时表明 $p_i \leftrightarrow q_j$ 与 $p_k \leftrightarrow q_l$ 共存的相容性最大;若 $C(i, j, k, l) < 1$,则表示 $p_i \leftrightarrow q_j$ 与 $p_k \leftrightarrow q_l$ 共存的相容性减小。

设初始扩展关联概率矩阵为 $M^{(0)} = [M_{ij}^{(0)}]_{(n+1) \times (m+1)}$,其中 $M_{ij}^{(0)}$ 为 $p_i \leftrightarrow q_j$ 的初始概率。首先求当满足 $1 \leq i \leq n, 1 \leq j \leq m$ 的条件下的初始概率。当 $p_i \leftrightarrow q_j$ 时,对于任意一点 p_k ,

其中 $k \neq i$, 希望有且仅有唯一 q_l 与 p_k 是匹配对应的, 其中 $l \neq j$ 。因此, 对于任意点 p_k 可以取与 $p_i \leftrightarrow q_j$ 共存时相容性度量达到最大值的 q_l 点作为其可能的唯一匹配点, 此时 $p_k \leftrightarrow q_l$ 对 $p_i \leftrightarrow q_j$ 的支持函数可用 $\max_{l \neq j} [C(i, j; k, l)]$ 来表示。进而, 可以取点集 P 中除了点 p_i 外所有其他点 p_k 与其最可能的匹配点 q_l 对 $p_i \leftrightarrow q_j$ 的支持函数的均值作为 $p_i \leftrightarrow q_j$ 的初始关联概率 $M_{ij}^{(0)}$:

$$M_{ij}^{(0)} = \frac{1}{n-1} \sum_{k \neq i} \{ \max_{l \neq j} [C(i, j; k, l)] \} \quad (9)$$

式中, $1 \leq i \leq n, 1 \leq j \leq m$ 。当 $i = n+1$ 和 $j = m+1$ 时, 两个点集中各点与其虚点之间的初始关联概率 $M_{n,m+1}^{(0)} = M_{m+1,j}^{(0)} = 0.2$ 。

4.3 松弛迭代寻优

松弛标记法^[15]的基本原理就是利用模板和目标点集中邻点属性通过迭代逐步更新获取全局一致性结果。其中邻点属性可以用支持函数来表达, 设第 r 次迭代的关联概率矩阵为 $M^{(r)} = [M_{ij}^{(r)}]_{(n+1) \times (m+1)}$, 其中 $M_{ij}^{(r)}$ 为 $p_i \leftrightarrow q_j$ 的第 r 次迭代的概率, 与初始匹配概率定义不同的是, 在第 r 次迭代时任意点对 $p_k \leftrightarrow q_l$ 对 $p_i \leftrightarrow q_j$ 的支持函数用 $\max_{l \neq j} \{ \min [C(i, j; k, l), M_{kl}^{(r-1)}] \}$ 来表示 (其中 $M_{kl}^{(r-1)}$ 为第 $r-1$ 次迭代后 $p_k \leftrightarrow q_l$ 的概率), 即此时的支持函数是由相容性度量与第 $r-1$ 次迭代中所得到的关联概率共同组合而成的。由此可以得出 $M_{ij}^{(r)}$ 为:

$$M_{ij}^{(r)} = \frac{1}{n} \sum_{k \neq i} \{ \max_{l \neq j} \{ \min [C(i, j; k, l), M_{kl}^{(r-1)}] \} \} \quad (10)$$

为满足一对一的约束条件, 每次迭代后都对关联概率矩阵 $M^{(r)}$ 进行双向正则化操作^[6], 使得 $\forall i \in [1, 2, \dots, n], \sum_{j=1}^{m+1} M_{ij}^{(r)} = 1; \forall j \in [1, 2, \dots, m], \sum_{i=1}^{n+1} M_{ij}^{(r)} = 1$ 。至此, 可以得到满足一对一关联约束条件的最优关联关系矩阵 M 。

综上所述, 本文算法的具体步骤如下:

- 1) 计算相似性匹配测度 C_{k_i, j_l} 和 C_{k_i, l_j} , 并求相容性度量函数 $C(i, j; k, l)$;
- 2) 初始化关联概率矩阵 $M^{(0)}$;
- 3) 更新关联概率矩阵, 得到第 r 次迭代后的关联概率矩阵 $M^{(r)}$;
- 4) 对 $M^{(r)}$ 进行双向正则化操作;
- 5) 如果 $\delta(r) = \|M^{(r)} - M^{(r-1)}\| < \epsilon$, 则迭代停止 (本文取 $\epsilon = 0.001$); 否则继续第 3) 步。

5 实验结果与分析

本文首先利用模拟点集数据对本文算法与目前常用的两种算法进行了抗几何变换能力、抗噪声能力以及抗出格点能力的综合比较实验, 然后进行了真实遥感影像数据实验。

5.1 模拟仿真实验

为验证算法的抗几何变换能力、抗噪声能力以及抗出格点能力, 本文分别进行了 3 组针对性的模拟点集实验。每组均进行 100 次蒙特卡洛实验, 每次实验都将本文的基于相对形状上下文的算法 (RSC) 与基于薄板样条插值变换模型的算法 (TPS-RPM)^[7] 和基于形状上下文的算法 (SC)^[9] 进行比较。

第一组实验是用于验证算法的抗几何变换的能力。阵群目标关联基于阵群队形一致性原则, 一般情况下要求前后两幅图像中的阵群编队形状保持相似。本组实验中将模板点集

通过相似变换来得到对应的目标点集, 即:

$$\begin{pmatrix} x' \\ y' \end{pmatrix} = \begin{pmatrix} s \cos \theta & -s \sin \theta \\ s \sin \theta & s \cos \theta \end{pmatrix} \begin{pmatrix} x \\ y \end{pmatrix} + \begin{pmatrix} t_x \\ t_y \end{pmatrix} \quad (11)$$

式中, $(x, y)^T$ 为模板点集中点的坐标, $(x', y')^T$ 为对应的目标点集中点的坐标, s 为尺度因子, θ 为旋转角度, t_x 和 t_y 分别为 x 与 y 轴方向的位移。实验中所采用的变换参数是在满足 $0.5 \leq s \leq 4.5, 0^\circ \leq \theta \leq 360^\circ, 0 \leq t_x, t_y \leq 0.5$ 条件下, 服从均匀分布的随机变换参数。

第二组实验是用于验证算法的抗噪声能力。在遥感影像中, 目标检测过程中存在的随机扰动会造成目标位置噪声, 因此抗噪能力是很重要的性能指标。本组实验采用了高斯噪声, 首先将模板点集经过随机相似变换后 (随机变换参数的取值范围与第一组实验相同) 得到无噪声的目标点集, 然后将目标点集中各点的 x 和 y 坐标值加上均值为 0、标准差分别为 $l_{target} \cdot \delta_{noise}$ 和 $w_{target} \cdot \delta_{noise}$ 的高斯噪声, 其中 δ_{noise} 表示噪声强度, l_{target} 和 w_{target} 分别表示未加噪声时目标点集覆盖区域的长度和宽度。

第三组实验是为了验证算法的抗出格点能力。受遥感影像分辨率及复杂环境的影响, 阵群目标检测中不可避免地会产生大量虚警。因此, 抗出格点能力也是衡量关联算法的一项重要指标。本组实验中每次向经过随机相似变换后 (随机变换参数的取值范围与第一组实验相同) 的目标点集中增加 $n_{temple} \cdot r_{outliers}$ 个均匀分布的随机出格点, 其中 n_{temple} 为模板点集中点的数目, $r_{outliers}$ 为出格点比率。







图 3 某次模拟点集实验的匹配结果



(a) 不同变换参数下的匹配结果统计



(b) 不同程度噪声下的匹配结果统计



(c) 不同比率出格点的匹配结果统计

图 4 模拟点集匹配统计结果

在图 3 所示的某一次实验中, 模板点用 (\diamond) 表示, 目标点用 (\square) 表示, 出格点则用 ($*$) 表示, 而且模板与目标点集中的点目标均按对应关系一一编号。图 3 中模板点集的点数为 15 个, 目标点集是先将模板点集经过随机相似变换后, 再添加强度为 0.02 的高斯噪声以及 25 个服从均匀分布的随机出格点后得到的。在图 3 所示的实验中, TPS-RPM 算法的匹

配正确率仅为 6.67%, SC 算法则完全匹配错误, 而本文的 RSC 算法匹配正确率高达 93.33% (仅存在一对误匹配点)。统计结果图 4 显示: 在点集之间存在随机相似变换、高斯噪声以及出格点的情况下, 本文算法的匹配正确率均高于其他两种算法。

5.2 真实遥感图像实验

在真实的遥感图像实验中, 本文进行了低分辨率光学遥感影像舰队阵群目标关联实验。

图 5(a) 是 Landsat5 卫星遥感影像, 其分辨率为 30 米, 图中矩形框区域显示的是放大后的待关联舰船阵群目标图像切片。图 5(b) 是 Spot4 卫星遥感影像, 其分辨率为 20 米, 图中矩形框区域显示了放大后的目标舰船阵群目标图像切片。图 5(a) 与图 5(b) 的成像时间相隔约 30 分钟。




图 5 模板图像与目标图像

本文取模板与目标图像中经过了检测后的目标的质心坐标来构造模板与目标点集。然后, 利用本文算法与其他两种算法分别进行了阵群目标关联。本文算法关联结果如图 6 所示。其中模板点用 (□) 表示, 目标点用 (○) 表示, 出格点用 (*) 表示。从图 6 中可见, 在目标点集中的阵群目标队形发生较大变化, 而且在较多虚警点 (15 个) 的情况下, 本文算法关联正确率能达到 100%, 而 TPS-RPM 与 SC 算法的关联正确率则分别为 28.5% 和 14.3%。因此, 本文算法能更好地地实现复杂环境下低分辨率遥感影像阵群目标关联的任务。




图 6 本文算法关联结果示意图

结束语 本文提出了一种新的鲁棒的基于点模式匹配的阵群目标关联算法, 它能较好地解决复杂环境下低分辨率遥感影像阵群目标关联的问题。算法首先提出了一种新的基于点集的不变特征——相对形状上下文, 相比于已有的形状上下文特征, 相对形状上下文特征具有相似变换不变性、对噪声和出格点鲁棒性较强等优点。文中利用点集中点对之间的相对形状上下文的统计检验匹配测度来建立阵群目标关联问题的数学模型。为了求解该模型, 本文先构造新的相容性度量函数来完成关联概率矩阵的初始化, 再利用松弛标记法, 通过迭代更新模板与目标点集中各点对之间的关联概率, 同时经过双向正则化操作, 最后求解得到满足一对一约束的关联匹配结果。模拟仿真实验与真实遥感影像实验表明, 本文的 RSC 算法与 TPS-RPM 和 SC 算法相比, 具有较高的关联匹配正确率并对高斯噪声和出格点具有较强的鲁棒性, 能较好地完成

复杂环境下低分辨率遥感影像阵群目标关联的任务。由于算法使用了松弛迭代, 当点集中的点数较多时, 算法的时间复杂度较高; 当模板与目标点集中均存在出格点与缺失点的复杂情况时, 算法的鲁棒性有所下降, 因此, 今后在提升算法速度的同时需要进一步考虑增强在更复杂条件下算法的鲁棒性。

参考文献

- [1] 雷琳, 蔡红辛, 唐涛, 等. 基于 MSA 特征的遥感图像多目标关联算法[J]. 遥感学报, 2008, 12(4): 586-592
- [2] 潘泉, 叶西宁, 张洪才. 广义概率数据关联算法[J]. 电子学报, 2005, 33(3): 467-472
- [3] 康莉, 谢维信, 黄敬雄. 一种基于蚁群算法的多目标跟踪数据关联方法[J]. 电子学报, 2008, 36(3): 586-589
- [4] Zhou H Y, Yuan Y, Shi C M. Object tracking using SIFT features and mean shift[J]. Computer Vision and Image Understanding, 2009(113): 345-352
- [5] Caetano T S, Caelli T, Schuurmans D, et al. Graphical Models and Point Pattern Matching [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2006, 28(10): 1646-1663
- [6] Zheng Y F, Doermann D. Robust point matching for non-rigid shapes by preserving local neighborhood structures [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2006, 28(4): 643-649
- [7] Chui H, Rangarajan A. A new algorithm for non-rigid point matching [A]// Proceedings of IEEE Conference on Computer Vision and Pattern Recognition [C]. Hilton Head, SC, USA, 2000: 44-51
- [8] Caelli T, Kosinov S. An eigenspace projection clustering method for inexact graph matching [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2004, 26(4): 515-519
- [9] Belongie S, Malik J, Puzicha J. Shape matching and object recognition using shape contexts [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2002, 24(4): 509-522
- [10] Ranade S, Rosenfeld A. Point Pattern Matching by Relaxation [J]. Pattern Recognition, 1980, 12: 269-275
- [11] Voss K, Suesse H. Affine Point Pattern Matching [A]// Pattern Recognition; 23rd DAGM Symposium Proceedings [C]// Munich, Germany, 2001: 155-162
- [12] Luo B, Hancock E R. Structural graph matching using the EM algorithm and singular value decomposition [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2001, 23(10): 1120-1136
- [13] Shapiro L S, Brady J M. Feature-based correspondence: An eigenvector approach [J]. Image and Vision Computing, 1992, 10(5): 283-288
- [14] Besl P J, McKay N D. A Method for Registration of 3-D Shapes [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1992, 14(2): 239-256
- [15] Rosenfeld A, Hummel R A, Zucker S W. Scene Labeling by Relaxation Operations [J]. IEEE Trans. System, Man, and Cybernetics, 1976, 6(6): 420-433
- [16] 吴永杰. 海上舰艇编队系统[M]. 北京: 国防工业出版社, 1999: 13-34