

基于 Vague 集的特征不确定性建模及 相似度求解

高 峰, 赵竹新, 文贡坚, 卢焕章

(国防科技大学电子科学与工程学院 ATR 重点实验室, 湖南长沙 410073)

摘 要: 受图像噪声和特征提取方法不稳定性等的影响, 特征提取结果存在不确定性, 它降低了同名特征之间的相似程度, 增大了匹配模糊性. 如果忽略这种不确定性, 可能会造成匹配精度的降低, 甚至导致匹配的失败. 为此, 本文对图像配准中常用特征的属性参数不确定性进行了分析和建模, 并提出了一种基于 Vague 集的不确定性特征相似求解方法. 本文的理论成果可以应用于图像配准和目标识别等领域中牵涉到的特征匹配问题中.

关键词: 特征匹配; 不确定性; 建模; 相似度; Vague 集

中图分类号: TP391 **文献标识码:** A **文章编号:** 0372-2112 (2011) 11-2622-05

Modeling of the Uncertainty of Image Features and Their Similarity Computing Based on Vague Sets

GAO Feng, ZHAO Zhu-xin, WEN Gong-jian, LU Huan-zhang

(ATR Key Laboratory, School of Electronic Science and Engineering, National University of Defense Technology, Changsha, Hunan 410073, China)

Abstract: For the influences of noises and feature extraction method, uncertainties are existing in the extracted features, which decrease the degree of similarity between corresponding features, and enlarge the matching illegibility. If the uncertainties are not analyzed, they may decrease the accuracy of matching and even lead to a failure. Hence, the paper analyses and models the uncertainties of the features, and then proposes a method which bases on Vague sets to compute the similarity between features with uncertainties. The study result can be used in the fields of image registration and target recognition which relate to feature matching.

Key words: feature matching; uncertainty; modeling; similarity; vague sets

1 引言

在特征匹配问题中, 造成同名特征属性出现差异的原因主要有两个: 一是由于图像获取条件的不同或图像受干扰的差异; 二是特征属性自身的不稳定性以及特征提取算法的影响. 现有基于特征的图像配准算法^[1~3]绝大多数没有考虑这种特征提取结果的不确定性因素. 另外, 在特征匹配阶段, 现有算法一般都是同等地看待图像中提取的每一个待匹配特征, 而忽略它们之间的显著性差异. 上述两种情况会影响匹配的精度, 甚至会导致匹配的失败. 目前处理特征不确定性的方法主要有三种: 一是利用统计思想平滑特征不确定性的影响^[4]; 二是设置误差门限的方法, 将特征的不确定性视为误差, 给定这种不确定性的变化范围作为误差门限^[5]; 三是对特征不确定性进行描述并将其用于衡量特征间的匹配性^[6,7]. 这些文献都没有对特征提取的不确定性进行建

模分析. 文献[8]只对线段特征端点不确定性进行了分析, 而没有考虑其它因素的影响.

根据上述分析, 本文首先从理论上深入分析了造成不确定的主要因素, 并对特征的不确定性进行了建模. 然后根据特征的不确定性模型, 提出了一种基于 Vague 集的特征相似度计算方法.

2 特征不确定性建模

设 $I(x, y)$ 表示一幅图像, (x, y) 表示图像的像素点坐标, 从图像中提取 N_1 个某种类型的特征, 记为 $F = \{f_1, f_2, \dots, f_{N_1}\}$, 对于每一个特征 f_i , 其属性参数表示为 $E_i = \{c_i, l_i\}$, 其中 c_i, l_i 分别表示位置参数和长度参数. 下面我们将对不同类型的特征属性参数不确定性进行分析和建模.

2.1 位置或者方向参数的不确定分析与建模

我们把提取特征的位置参数统一记为 $C = \{c_1, c_2,$

$\dots, c_{N_1}\}$. 其中 $c_i = (x_i, y_i)$, $(i = 1, \dots, N_1)$ 表示第 i 个特征的位置坐标. 分析可知, 图像特征一般分布在图像的主要结构中, 以它为中心的局部区域内应包含较大的信息量; 而对于因图像噪声等原因产生的虚假特征, 则可能随机分布在图像的任意位置, 以它为中心的局部区域内包含的信息量较小. 因此, 可以利用信息量的大小来判断特征位置参数提取结果的可靠性. 我们采用以特征位置为中心的局部区域的熵的大小来衡量角点提取结果的不确定性, 熵越大, 局部区域的信息量越丰富, 特征位置提取结果越可靠, 偏差越小. 反之, 特征位置提取结果越不可靠, 位置偏差越大.

取以 c_i 为中心大小为 $N \times N$ 的子窗口图像 w , 记 w 的熵为 $H_i(w)$, 则

$$H_i(w) = - \sum_{m=0}^{255} p_m \log(p_m) \quad (1)$$

其中 p_m 表示 w 中图像灰度值为 m 的像素个数占整个子窗口图像中像素个数总数的比例, 即

$$p_m = \frac{B}{N^2} \quad (2)$$

B 是子窗口图像 w 中灰度值为 m 的像素个数.

为了将所有 c_i 所在的子窗口图像的熵归一化, 使它们落在 $0-1$ 之间, 我们对公式做如下变换

$$H_i(w) = \frac{H_i(w)}{H^{\text{Max}}} \quad (3)$$

其中 H^{Max} 表示图像中以 c_i 为中心的所有子窗口图像根据式(1)计算得到的最大熵. 按式(3)计算的熵值越大, 特征提取结果越稳健, 可靠性越好. 因此可以认为位置参数偏差的大小主要和以特征为中心的窗口图像的熵值有关, c_i 的位置最大偏差 $(\Delta x_i, \Delta y_i)$ 可以利用下面的公式定义:

$$\begin{cases} \Delta x_i = f_{c1}(H_i(w)) \\ \Delta y_i = f_{c2}(H_i(w)) \end{cases} \quad (4)$$

其中, f_{c1}, f_{c2} 为一维递减函数, 算法中我们取:

$$f_{c1}(x) = f_{c2}(x) = a_1 - x \quad (5)$$

其中 a_1 表示位置的平均偏移量, 与特征提取算法本身的精度有关, 一般取 $a_1 = 2 \sim 5$.

这样, 特征的位置参数不再用一个固定的坐标值表示, 而是纵横坐标可能分布在区间 $[x_i - \Delta x_i, x_i + \Delta x_i]$, $[y_i - \Delta y_i, y_i + \Delta y_i]$ 中的任何位置, 那么位置参数可以表示成 $\{[x_i - \Delta x_i, x_i + \Delta x_i], [y_i - \Delta y_i, y_i + \Delta y_i]\}$ 的形式, 为简单记, 表示为 $\{X_i, Y_i\}$.

2.2 长度参数的不确定性分析与建模

我们把提取特征的长度参数统一记为 $L = \{l_1, l_2, \dots, l_{N_2}\}$. 下面以线特征为例, 来分析长度参数的不确定性建模. 一般特征的长度参数不确定性主要和两方面

的因素有关: (1) 以线特征为中心的窗口内像素包含的信息量; (2) 线上像素的平均梯度值与整个窗口内像素的平均梯度值的大小关系. 为了定量计算线特征不确定性, 划分出以该线特征为中心的, 长和宽分别为 l_i 和 b 的区域 w , 我们称其为线特征的支撑区域, 窗口内的像素包含的信息量按照式(1)和式(3)计算.

下面我们分析如何计算线特征像素上的梯度值与窗口内其它像素的梯度值的大小关系. 对于一个像素点 (x_m, y_m) , 灰度值为 $I(x_m, y_m)$, x, y 方向的梯度可以分别用下面的公式计算:

$$\begin{cases} \nabla_x(x_i, y_i) = I(x_m, y_m) - I(x_{m-1}, y_m) \\ \nabla_y(x_i, y_i) = I(x_m, y_m) - I(x_m, y_{m-1}) \end{cases} \quad (6)$$

那么线特征上所有点的平均梯度值 Tgl_i 为:

$$Tgl_i = \frac{\sum_{(x_j, y_j) \in l_i} \sqrt{\nabla_x^2(x_j, y_j) + \nabla_y^2(x_j, y_j)}}{len_i} \quad (7)$$

线支撑区域的平均梯度值 Tgw_i 为

$$Tgw_i = \frac{\sum_{(x_j, y_j) \in w} \sqrt{\nabla_x^2(x_j, y_j) + \nabla_y^2(x_j, y_j)}}{len_i * b} \quad (8)$$

那么线特征上像素的平均梯度值与整个窗口内像素的平均梯度值的比例关系 dg_i 可以用下面的公式计算:

$$dg_i = \frac{Tgl_i}{Tgw_i} \quad (9)$$

dg_i 值越大, 说明线特征越明显, 显著性越大, 特征越稳健. 一旦直线特征被提取出来以后, 除出现断裂外, 长度的不确定性受噪声等影响不大, 并且直线越长, 长度的不确定性对结果的影响越小, 因此我们可以通过下式来衡量直线长度的不确定性:

$$\Delta l_i = \alpha_2 \exp\left\{-\frac{len_i}{\sigma_2^2}\right\} + \alpha_3 \exp\left\{-\frac{Tgw_i + dg_i}{\sigma_3^2}\right\} \quad (10)$$

其中 α_2 和 σ_2^2 是控制长度与最大长度偏差关系的量, 一般直线的长度偏差在 5 个像素以内, 根据经验, 一般可取 $\alpha_2 = 1 \sim 3$, $\sigma_2^2 = 10 \sim 15$; α_3 和 σ_3^2 表示最大长度偏差与信息量大小和梯度比值关系的量, 同样, 一般可取 $\alpha_3 = 1 \sim 3$, $\sigma_3^2 = 2 \sim 4$. 考虑特征提取不确定性的长度参数 l_i 不再用固定的值表示, 而是用一个取值区间 $[l_i - \Delta l_i, l_i + \Delta l_i]$ 表示. 需要说明的是, 上述参数值虽然是根据经验给出的, 对于大多图像而言, 取上述值都可以得到比较理想的结果.

3 考虑不确定性的特征相似度求解

假设 $F^1 = \{f_1^1, f_2^1, \dots, f_{N_1}^1\}$ 为从基准图像中提取出的某种特征, $F^2 = \{f_1^2, f_2^2, \dots, f_{N_1}^2\}$ 为从待配准图像中提取出来的同种类型的特征, 其中 $f_j^i = \{c_j^i, l_j^i\}$, $i = 1, j =$

$1, \dots, N_1$ 或 $i=2, j=1, \dots, N_2, c_j^i, l_j^i$ 分别表示特征的位置参数和长度参数. 假设两幅图像已经经过了初始的配准, 那么若两个特征 f_j^1, f_k^2 是同名特征, 则它们应该具有相同长度参数, 即 $c_j^1 = c_k^2, l_j^1 = l_k^2$. 然而由于图像质量、特征提取方法本身的稳健性等因素, 它们并不完全相同, 为了衡量它们之间的近似程度, 本文在对特征的不确定性进行建模的基础上, 提出了基于 Vague 集的相似度求解方法.

3.1 Vague 集的基本理论

设 U 是一个论域 $U = \{u_1, u_2, \dots, u_n\}$, 论域中的一个 Vague 集 A 可以用一个真隶属函数 $t_A(x)$ 和一个假隶属函数 $f_A(x)$ 表示, $t_A(u_i)$ 是支持 u_i 隶属度的下界, $f_A(u_i)$ 是反对 u_i 隶属度的下界, $t_A(u_i) + f_A(u_i) \leq 1$, 这两个下界构成了 $[0, 1]$ 上的一个子区间 $[t_A(u_i), 1 - f_A(u_i)]$, 称为一个 Vague 值. 它表示对象 u_i 属于 Vague 集 A 的程度为 $t_A(u_i)$, 又称 A 中元素 u_i 的赞成度; 不属于 A 的程度为 $f_A(u_i)$, 又称 A 中元素 u_i 的反对度.

文中我们采用李凡^[9]等提出的 Vague 值贴进度计算公式. 设两个 Vague 值为 $[t_x, 1 - f_x]$ 和 $[t_y, 1 - f_y]$, 则它们之间的贴进度计算如下:

$$\sigma(x, y) = 1 - \frac{|S(x) - S(y)|}{4} - \frac{|t_x - t_y| + |f_x - f_y|}{4} \quad (11)$$

其中 $S(x) = t_x - f_x$ ——称为 A 中元素 x 的核, 它表征为现有证据对元素 x 的支持和反对两种趋势的力量对比. 两个 Vague 集 A 和 B 的贴进度计算公式为:

$$\sigma(A, B) = \frac{1}{n} \sum_{i=1}^n \left(1 - \frac{|S(V_A(u_i)) - S(V_B(u_i))|}{4} \right) - \frac{1}{n} \sum_{i=1}^n \frac{|t_A(u_i) - t_B(u_i)| + |f_A(u_i) - f_B(u_i)|}{4} \quad (12)$$

3.2 特征之间相似度的计算

我们把基准图像中的特征作为模板, 由于图像质量和特征提取算法等的影响, 模板的测量值和真实值之间可能存在一些误差, 通过模板真实值与测量值计算得到标准 Vague 集; 而待配准图像中的特征与模板的测量值进行运算得到的 Vague 集称为观测 Vague 集, 然后通过计算标准 Vague 集和观测 Vague 集的相似度来反映两个特征之间的相似度.

(1) 当属性参数为长度参数时

基准图像中特征的长度参数为 $[l^1 - \Delta l^1, l^1 + \Delta l^1]$, 当长度可能的偏差 Δl^1 固定时, 长度越长, 则长度的测量值相对误差越小, 反之越大. 所以求标准 Vague 集时赞成度进行如下的定义:

$$t_l^1 = \exp \left\{ - \frac{2 * \Delta l^1 + l^1}{l^1} \right\} \quad (13)$$

反对度为

$$f_l^1 = \frac{0.5}{4\Delta l^1 + 1} \quad (14)$$

那么标准 Vague 集(只包含一个值)就是 $\{[t_l^1, 1 - f_l^1]\}$.

对于观测 Vague 集, 两个特征之间的相似度不仅与长度参数的绝对差异有关, 还和它们的不确定性大小有关. 长度参数越接近, 则赞成度应该越大, 反之越小. 当长度参数差异固定时, 不确定性越大, 则反对度越小, 反之越大. 因此, 观测 Vague 集的赞成度和反对度可以用如下的公式进行计算.

赞成度定义为:

$$t_l^2 = \exp \left(- \frac{2|l^1 - l^2| + \Delta l^2 + \Delta l^1 + l^1}{l^1} \right) \quad (15)$$

反对度定义为:

$$f_l^2 = \frac{|l^1 - l^2| + 0.5}{|l^1 - l^2| + 2 * (\Delta l^1 + \Delta l^2) + 1} \quad (16)$$

(2) 当属性参数代表坐标或者方向信息时

当属性参数 $[x^1 - \Delta x^1, x^1 + \Delta x^1]$ 表示坐标或者方向等信息时, 因为偏差 Δx^1 和坐标 x^1 本身没有必然的关系, 所以与第一种情况不同, 比较它们的大小没有意义. 因此求解 Vague 集的方法和上面的方法是不同的, 下面我们分别给出标准 Vague 集和观测 Vague 集的赞成度和反对度的定义.

标准 Vague 集赞成度的定义:

$$t_x^1 = \exp \left(- \frac{\Delta x^1 + 0.5}{\Delta x^1 + 1} \right) \quad (17)$$

反对度的定义:

$$f_x^1 = \frac{0.5}{4 * \Delta x^1 + 1} \quad (18)$$

分析可知, 观测 Vague 集的赞成度和反对度也主要受属性参数之间的差异和偏差影响, 与上一种情况类似, 我们对观测集的赞成度进行如下定义:

$$t_x^2 = \exp \left(- \frac{2|x^1 - x^2| + 0.5 + \Delta x^2}{\Delta x^1 + 1} \right) \quad (19)$$

反对度的定义与式(16)相同.

根据不确定性的定义和取值范围, 不难证明赞成度 t_x 和反对度 f_x 的定义满足 $0 < t_x < 1, 0 < f_x < 1, t_x + f_x < 1$, 所以上述定义都是合理的.

对标准 Vague 集和观测 Vague 集的赞成度和反对度进行定义后, 可以按照式(12)求两个 Vague 集之间的相似度, 即两个特征之间的相似度.

3.3 分析仿真

本节我们主要给出赞成度和反对度与相关参数的关系曲线, 进而验证定义的正确性. 篇幅所限, 本文只给出属性参数为长度参数时的仿真结果, 其它情况仿真结果可以按照类似的方法得到.

(1)标准 Vague 集的赞成度和反对度

由式(13)可知,标准 Vague 集的赞成度主要和不确定性长度偏差与提取的长度值比值有关,由于位置偏差 Δx^1 小于长度值 x^1 ,所以 $0 < \frac{\Delta x^1}{x^1} < 1$,因此赞成度随比值的变化的关系如图 1 所示.可以看出,赞成度随着比值的增大而减小,即随着不确定性的增大而减小,显然这是合理的.由式(14)可知,标准 Vague 集的反对度主要和偏差 Δx^1 有关,图 2 为反对度与偏差的关系.分析可知,图中的变化关系是合理的.

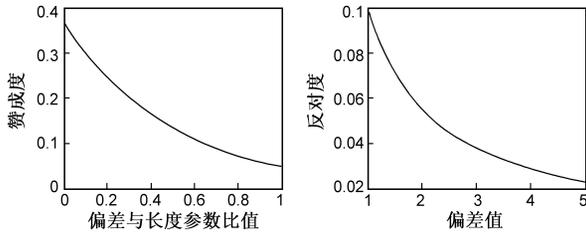


图1 标准Vague集的赞成度 t_x 与 $\Delta x^1/x^1$ 的关系曲线 图2 标准Vague集反对度与长度偏差的关系曲线

(2)观测 Vague 集的赞成度和反对度

由式(15)可知,赞成度主要与基准图像中特征的长度、待配准图像中特征的长度、以及对应的偏差有关,下面我们假设基准图像中特征的长度和偏差都是固定的(假设为 $x^1 = 20$ 和 $\Delta x^1 = 2$),赞成度与待配准图像中长度和偏差的关系如图 3 所示.其中图 3(a)中假设固定偏差 $\Delta x^2 = 2$,可以看出当 $x^2 = x^1$ 时,相似度达到最大;图 3(b)中分别取 $x^2 = 18, 19, 20, 21, 22$ 时,位置偏差与赞成度的关系,并用不同的颜色表示出来,由赞成度的定义可知, $x^2 = 18$ 与 $x^2 = 22, x^2 = 19$ 与 $x^2 = 21$ 对应的曲线是相互重合的,分析可知,这是合理的.

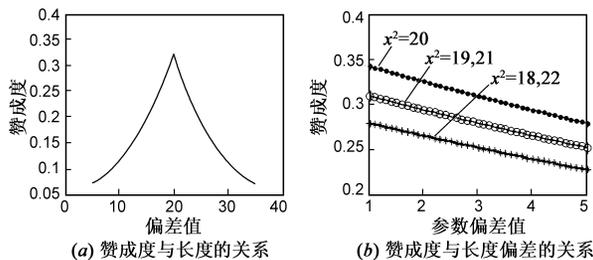


图3 观测Vague集的赞成度与 x^1 和 Δx^1 的关系曲线

由式(16)可知,反对度也主要与基准图像中特征的长度、待配准图像中特征的长度、以及对应的偏差有关.同样,假设基准图像中特征的长度和偏差是固定的($x^1 = 20$ 和 $\Delta x^1 = 2$),反对度与待配准图像中特征的长度和偏差的关系如图 4 所示.在求反对度与长度关系时,我们固定偏差 $\Delta x^2 = 2$,可以看出,当两特征的长度值相同时,反对度最小.在求反对度与偏差的关系时,分别固定长度为 $x^2 = 18, 19, 20, 21, 22$.从图可以看出,

$x^2 = 18$ 与 $x^2 = 22, x^2 = 19$ 与 $x^2 = 21$ 对应的反对度曲线是也是相互重合的,显然这也是合理的.

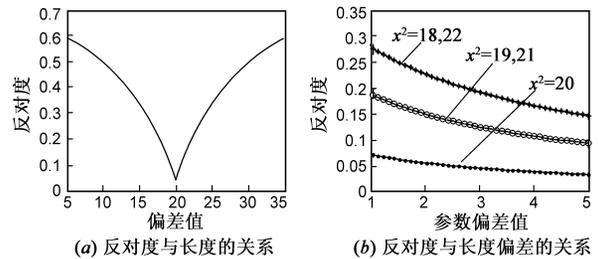


图4 观测Vague集反对度与 x^1 和 Δx^1 的关系曲线

4 结论

本文的主要贡献有两个方面:第一,对特征的不确定性进行了建模,克服了原有算法中直接利用固定属性信息进行对应性求解造成的匹配误差大、难以寻找最优对应关系等问题;第二,利用模糊 Vague 集理论对包含不确定性的图像特征之间进行了相似度的定义,为特征对应性求解提供理论基础.

参考文献

- [1] 王安娜,张新华,谷召伟.基于改进 Hausdorff 测度的医学图像配准算法[J].电子学报,2008 36(11):2247-2250. WANG An-nan, ZHANG Xin-hua, GU Zhao-wei. A medical image registration algorithm based on revised Hausdorff distance[J]. Acta Electronica Sinica, 2008 36(11): 2247-2250. (in Chinese)
- [2] Gong-Jian Wen, Jin-jian Lv, Wen-xian Yu. A high-performance feature-matching method for image registration by combining spatial and similarity information[J]. IEEE Transactions on GRS, 2008, 46(4): 1266-1277.
- [3] 韦燕风,赵忠明,闫冬梅.基于特征的遥感图像自动配准算法[J].电子学报,2005,33(1):161-165. WEI Yan-feng, ZHAO Zhong-ming, YAN Dong-mei. Remote sensing image automatic registration based on feature[J]. Acta Electronica Sinica, 2005, 33(1): 161-165. (in Chinese)
- [4] Clark f Olson. A general method for geometric feature matching and model extraction[J]. International Journal of Computer Vision, 2001, 45(1): 39-54.
- [5] Xilin Yi, Octavia I Camps. Line-based recognition using a multidimensional Hausdorff distance[J]. IEEE Transactions on PAMI, 1999, 21(9): 1168-1180.
- [6] Gonzalo Pajares, Jesús M de la Cruz. Fuzzy cognitive maps for stereovision matching[J]. Pattern Recognition, 2006, 39(11): 2101-2114.
- [7] Ying Shan, Zhengyou Zhang. New measurements and corner-guidance for curve matching with probabilistic relaxation[J]. International Journal of Computer Vision, 2002, 46(2): 157-171.

- [8] Xinquan Shen, Phil Palmer. Uncertainty propagation and the matching of junctions as feature groupings[J]. IEEE Transactions on PAMI, 2000, 22(12): 1381 – 1395.
- [9] 李凡, 徐章艳. Vague 集之间的相似度量[J]. 软件学报,

2001, 12(6): 922 – 926.

LI Fan, XU Zhang-yan. Measures of similarity between vague sets[J]. Journal of Software, 2001, 12(6): 922 – 926. (in Chinese)

作者简介



高 峰 男, 1982 年 4 月出生, 河南民权人. 2004 年、2006 年、2011 年分别获得国防科技大学工学学士、工学硕士和工学博士学位. 现为国防科技大学电子科学与工程学院讲师, 从事图像配准、目标识别等方面的有关研究.

E-mail: gaofeng_nudt@yahoo.com.cn



赵竹新 男, 1984 年 6 月出生, 山东烟台人. 2007 年本科毕业于国防科技大学电子科学与工程学院, 现为硕博连读生, 从事摄影测量与遥感、运动检测等方面的研究.