

改进形状上下文的湍流杂波形状目标匹配识别

徐兴贵^{1,2,3*}, 冉兵^{1,3}, 杨平^{1**}, 鲜浩¹, 刘永²

¹中国科学院光电技术研究所, 四川 成都 610209;

²电子科技大学光电科学与工程学院, 四川 成都 610054;

³中国科学院大学, 北京 100049

摘要 针对近地面远距离成像场景下轮廓目标受湍流杂波影响而使匹配误差较大的问题, 提出一种基于方向形状上下文和边连续性约束的形状点集匹配识别方法。首先将方向特征嵌入传统的形状上下文来构造一个具有尺度和旋转不变性的特征算子。然后, 受模板和目标形状之间的边连续性先验启发, 在目标匹配能量代价函数中加入轮廓形状边连续性约束条件以提高形状匹配精度。合成湍流杂波场景和真实远距离成像场景中的形状匹配实验结果表明, 和传统方法相比, 所提方法能够将杂波场景下的目标匹配误差平均降低约 6%, 同时还降低了计算复杂度。

关键词 大气光学; 目标识别; 湍流杂波; 形状上下文; 点集匹配

中图分类号 TP391

文献标志码 A

doi: 10.3788/LOP57.210101

Shape Object Matching Recognition of Turbulence Clutter Based on Improved Shape Context

Xu Xinggui^{1,2,3*}, Ran Bing^{1,3}, Yang Ping^{1**}, Xian Hao¹, Liu Yong²

¹Institute of Optics and Electronics, Chinese Academy of Sciences, Chengdu, Sichuan 610209, China;

²School of Optoelectronic Science and Engineering, University of Electronic Science and Technology of China, Chengdu, Sichuan 610054, China;

³University of Chinese Academy of Sciences, Beijing 100049, China

Abstract Contour targets are affected by turbulence clutters in near-ground remote imaging scenes, leading to large matching errors. To address this problem, we propose a shape point set matching recognition method based on an oriented shape context and an edge continuity constraint. In the proposed method, directional features are embedded into a traditional shape context to construct a feature operator with a scale and rotation invariance. Further, inspired by the priori of edge continuity between the template and target shapes, we add the edge continuity constraint condition of the contour shape into the target matching energy cost function to improve the accuracy of shape matching. The experimental results of shape matching in a synthetic turbulence clutter scene and a real remote imaging scene show that compared with the traditional method, the proposed method can reduce the target matching error by about 6% in clutter scenes and reduce computational complexity.

Key words atmospheric optics; object recognition; turbulent clutter; shape context; point set matching

OCIS codes 010.7060; 150.0150; 010.1330; 100.3008

1 引言

目标图像的颜色、纹理、轮廓等特征都是识别目标的重要视觉线索。然而, 近地面远距离光电成像系统^[1]获取的图像往往仅含有目标轮廓信息, 且受

大气湍流的影响, 获取的形状目标轮廓伴有几何畸变、位置漂移及离群值等湍流杂波噪声。可见, 远距离湍流杂波场景下的目标形状点集匹配识别具有较大的挑战性。如文献[2-5]所述, 有效去除目标图像噪声和提高基于形状特征的匹配识别能力成为形状

收稿日期: 2019-12-23; 修回日期: 2020-02-10; 录用日期: 2020-03-09

基金项目: 国家自然科学基金(61805251, 61875203)

* E-mail: xu_xinggui@126.com; ** E-mail: pingyang2516@163.com

目标点集匹配的根本任务。为有效提高湍流杂波场景下的目标匹配识别精度和效率,本文主要基于形状特征的匹配问题进行展开,下面将详细讨论相关特征描述和匹配处理的典型方法。

经典的特征提取方法主要有尺度不变特征转移(SIFT)算子^[6]、形状上下文(SC)算子^[7]、内点距离上下文(IDSC)^[8]等。这些方法不同程度地实现了对形状信息的局部或全局表示,但也存在对形状目标发生形变和旋转等时较为敏感的问题。例如,SIFT描述子利用多尺度金字塔局部梯度信息实现尺度不变性,但该算子没有提取方向信息而不具有旋转不变性,且其弱梯度特征易受噪声的影响。而SC算子则利用形状空间像素点位置关系表征轮廓特征,该方法将轮廓取样点在所划分扇形区域内的空间长度和方向作为特征表示,可见,该方法容易受离群点的干扰,且计算成本较高。最近,Lian等^[4-5]提出了尺度不变特征描述算子,并利用全局优化方法实现形状点集匹配,该方法将原匹配问题转换为凹二次分配问题,并采用分枝定界算法实现全局最优解。另外,基于深度学习的方法^[9-10]在特征提取和目标识别中也取得较好的识别效果,如Li等^[10]通过改进骨架关节结构和提取多层卷积网络特征来对目标进行识别。然而,由于杂波场景下的轮廓形状目标本身缺乏颜色和纹理特性,此类深度学习算法难以获取湍流杂波下轮廓形状目标与噪声间的特征差异,进而使得深度网络难以提取特征,且此类方法的大数据样本需求和硬件成本均较高。综上所述,将基于深度学习的目标识别方法直接用于杂波背景下的轮廓形状目标识别变得不可行。近来,Ling等^[8]将SC方法中的欧几里得距离替换为最短内点距离,有效地提高了目标轮廓形状的局部和全局结构描述能力。在上述特征表示基础上,在最后的形状点集匹配阶段,把特征数据抽象为一个闭环字符串、图或树结构进行优化匹配。典型的匹配识别方法有谱匹配(SP)法^[11]、图匹配(GP)法^[12]、线性规划(LP)法^[13-14]及动态规划(DP)法^[8,15]等。

为了克服上述方法在特征描述鲁棒性、抗噪能力及计算复杂度方面的局限性,本文提出了一种基于方向形状上下文(OSC)和图形边连续性约束的形状点集匹配模型。首先构建OSC描述算子,然后建立满足边连续性约束条件的匹配目标函数,最后基于DP方法实现形状点集匹配。与大多数基于SC算子的匹配方法^[7-8,16]不同,所提基于OSC算子的方法对形状旋转和变形具有鲁棒性,此外,

匹配目标代价函数中增加等距图形连续性约束条件则提高了抗噪能力,并且OSC算子保留的形状点集序列使基于DP的匹配过程的计算复杂度大大降低,即由传统的 $O(n^4)$ 降低至 $O(nm^2)$,其中 n 和 m 分别表示目标轮廓图像数量和模板形状点集数量,满足不等式 $m < n$ 。

2 方向形状上下文

传统的SC描述子^[7]的核心思想:选取目标形状轮廓中一定数量的点,通过计算该点到其周围点的角度和距离来构建在空域关系上的上下文特征矩阵;然后根据不同形状目标之间的矩阵匹配度来判断两幅图像是否属于一类或者相互匹配。给定 m 个点在空间位置上构成的形状点集 $\{x_1, x_2, \dots, x_m\}$,形状点 x_i 处的SC特征表示为该点与其余 $(m-1)$ 点的相对空间长度和方向的直方图 h_i ,该直方可表示为

$$h_i(k) = \# \{x_j : j \neq i, x_j - x_i \in \text{bin}(k)\}, \quad (1)$$

式中:二进制bin表示对数极坐标空间中的SC特征直方图; $\#\{\cdot\}$ 表示坐标空间统计; k 表示坐标空间范围。可见,SC特征算子的主要优点是能充分利用上下文信息,在典型的形状目标匹配中有很好的效果。但SC算子仍然存在两个主要缺点:一是SC算子不携带形状方向信息,因而其不具有旋转不变性;二是在含有大量背景噪声或者轮廓目标点集形状畸变较大的情况时,目标形状点集空间关系受各类噪声的干扰而使匹配效果不好。为改进SC的旋转不变性,方法^[8]则通过旋转坐标系找到形状正 x 轴,使其与切线向量对齐来提高旋转不变性,但该方法容易受杂波噪声的干扰。方法^[3]则通过选定参考点,利用参考点与其他数据点的SC特征将形状点集的方向特征信息刻画成形状目标点集间的空间特性,进而实现方向旋转不变性。该方法的另一好处是同时获得形状点集的空间顺序,从而使基于DP的优化方法能够在低计算复杂度情况下完成目标优化匹配。为改进SC算子的旋转不变性,在目标形状空间中加入方向特征来实现。假定二维模板形状点集的空间坐标为 $S = \{(x_i, y_i), 0 \leq i \leq n\}$,参考点 (x_0, y_0) 的选定策略为该点到其余所有点最大欧氏距离对应的点。与方法^[3]相似,选定 x 轴的正方向为形状点集指向参考点 r_0 的方向,OSC的特征提取示意图如图1所示。

图1中方向虚线段表示形状帧边长度特征。通常,特征提取算子的表示能力越强,后续基于特征的




图1 OSC描述算子构建示意图

Fig. 1 Schematic of OSC description operator construction
 匹配识别精度越高。如图1特征描述算子所示,所提方法具有很强的局部结构特征描述能力。为直观显示OSC算子的特征表示,选取距离数 $n_d = 5$,




图2 OSC描述子提取的特征直方图。(a)标记点1;(b)标记点2;(c)标记点3

Fig. 2 Feature histogram extracted by OSC descriptor. (a) Marking point 1; (b) marking point 2; (c) marking point 3

式中: $h_{A,i}$ 和 $h_{B,j}$ 分别表示两个形状点集 A 和 B 所对应的第 i 和 j 的特征点直方图; M 表示所提取的特征向量维度。形状距离值 $d(S_A, S_B)$ 越小,两个形状越相似。

3 轮廓边连续性约束的匹配能量代价函数

在OSC描述算子基础上,根据目标形状点集匹配过程前后相邻边的位置关系不变这一观察先验知识,提出了基于轮廓边连续性约束的匹配能量代价函数,并利用DP算法实现了全局优化。

3.1 目标函数构建

匹配识别任务中,给定由 S_A 表示的二维模板轮廓形状点集和由 S_B 表示的图像轮廓数据点。匹配识别的目标是找到形状 S_A 中第 i 个点相对应到形状 S_B 的第 j 点的映射 $\phi: S_A \rightarrow S_B$,寻优的过程即是最小化匹配目标能量函数的过程。然而,湍流杂波场景中的离群点和噪声的空间随机分散特性会干扰到正常形状点集匹配精度。为此,提出一个具有图形边连续性约束的匹配能量代价模型。形状边连续性约束的示意图如图3所示。

图3中,假设形状模型 U 上的相邻两点为 u_i 和 u_{i-1} , ϕ 为形状匹配变换,则经过匹配变换后所对应

方向数 $n_\theta = 12$,图1中小圆圈标注点对应所提取的特征直方图如图2所示。

图2中,特征直方图的横坐标和纵坐标分布表示方向特征和空间长度特征,该特征描述算子的直方图维数为60。可以看出,轮廓形状上不同位置所获得的方向特征直方图不同,OSC算子具有较强的形状描述能力。在上述特征表示下,目标匹配识别任务则可通过利用目标特征点计算匹配代价函数(形状距离相似性度)来实现。方法[8,17]证明形状点集之间的距离相似性可用卡方统计分布特性表示,形状距离 $d(S_A, S_B)$ 可表达为

$$d(S_A, S_B) = \frac{1}{2} \sum_{k=1}^M \frac{[h_{A,i}(k) - h_{B,j}(k)]^2}{h_{A,i}(k) + h_{B,j}(k)}, \quad (2)$$




图3 加入的边连续性约束示意图

Fig. 3 Schematic of imposing edge continuity constraint
 的目标形状 V 上的相邻点 $v_{\phi(i)}$ 和 $v_{\phi(i-1)}$ 也满足边连续性约束条件,换一句话说,模型形状点集上的相邻点应映射到目标形状上彼此靠近的点。受此启发,将边连续性先验约束代入形状匹配目标函数中。假设模板形状用 S_A 表示,目标形状点集用 S_B 表达,则所提匹配能量代价函数可表示为

$$C_\phi(S_A, S_B) = C_{\text{OSC}}(S_A, S_B) + \lambda C_{\text{frame}}(S_A, S_B) + \beta C_{\text{cont}}(S_A, S_B), \quad (3)$$

式中: C_{OSC} 表示OSC的特征相似性代价函数; C_{frame} 表示轮廓形状帧的边代价; C_{cont} 表示边连续性代价约束项; λ, β 均为正则化参数。假定模板形状 S_A 上的点 u_i 映射到目标形状点集 S_B 上的相邻点 $v_{\phi(i)}$,则基于OSC的匹配代价相似性可表示为所有待匹配点的能量匹配代价总和,即

$$C_{\text{OSC}}(S_A, S_B) = \sum_{i=1}^n C_{\text{OSC}}(u_i, v_{\phi(i)}). \quad (4)$$

类似 OSC 特征点的相似性表达,轮廓形状边的能量匹配可表示为除参考点外所有帧边对应点的能量匹配代价总和,表示为

$$C_{\text{frame}}(S_A, S_B) = \sum_{i=2}^n C_{\text{frame}}(u_i, \nu_{\phi(i)}). \quad (5)$$

边连续性与轮廓形状点上的曲率相关,采用方法[5,18]的策略,即利用轮廓形状点集上的曲率值来刻画图形帧边的连续性,将(3)式中的边连续性代价约束项转换为曲率的能量代价约束:

$$C_{\text{cont}}(S_A, S_B) = \sum_{i=2}^{n-1} |\kappa(u_i) - \kappa(\nu_{\phi(i)})|. \quad (6)$$

其中,

$$\kappa(u_i) = |u_{i-1} - 2u_i + u_{i+1}|, \quad (7)$$

式中: κ 表示对应轮廓形状点集上的曲率能量。U-chord 曲率法^[18]被用来提取轮廓形状曲率值。U-chord 曲率法的曲率由形状点集上的两点支撑,两点与参考点之间的距离为给定弦长,在相邻区域内估算出当前点的 U 弦曲率。

所构建的基于轮廓边连续性约束的匹配能量代价函数有三方面优点:一是 OSC 特征算子具有旋转不变性;二是目标形状点集空间的边连续约束关系能够抵抗各类杂波噪声的干扰;三是与传统的无序点集 SC^[7]的匹配优化计算复杂度 $O(n^4)$ 相比,在给定形状点的顺序情况下,如 IDSC 方法,计算复杂度仅为 $O(nm^2)$ 。

3.2 基于 DP 的点集匹配

DP 算法能够有效解决有序数据类型结构的优化

问题。定义 n 个表单 $V[i, 0], i=1, 2, \dots, n$, 每一表单内含 $m \times m$ 点。在参考点 ν_0 表示下,匹配点 $V[i, 0](l_i, l_0)$ 表示形状端点 ν_i 对应的最佳匹配点。降序排列 ν_i , 则端点位置 $\{\nu_0, \nu_i\}$ 与帧边点集 $\{l_0, l_i\}$ 一一对应。据此,所要查询的匹配点满足回归方程:

$$V[i, 0](l_i, l_0) = \sum_i \min_{l_i} C_{\text{osc}}[i, 0](l_i, l_0) + \lambda C_{\text{frame}}[i, 0](l_i, l_0) + \beta C_{\text{cont}}[i, 0](l_i, l_0). \quad (8)$$

根据(8)式中的匹配点能量代价值,可以进一步计算出当前全局最优的匹配点:

$$(\hat{l}_r, \hat{l}_0) = \underset{(l_r, l_0)}{\operatorname{argmin}} V[i, 0](l_i, l_0). \quad (9)$$

然后根据(8)、(9)式,可以通过追踪得到最终对应匹配点的位置,具体表达式为

$$\hat{l}_i = \underset{l_i}{\operatorname{argmin}} C_{\text{osc}}[i, 0](\hat{l}_i, \hat{l}_0) + \lambda C_{\text{frame}}[i, 0](\hat{l}_i, l_0) + \beta C_{\text{cont}}[i, 0](\hat{l}_i, l_0). \quad (10)$$

目标形状点集表示的数据结构采用方法[3]类似的 $n-1$ 边二叉树结构,因此,该匹配算法具有时间复杂度 $O(nm^2)$ 和空间复杂度 $O(nm)$ 。

3.3 算法实现

根据目标能量函数的模型建立和公式推导过程,基于 OSC 和边约束的目标能量匹配算法逻辑框如图 4 所示。

在算法实现过程中,首先提取图像形状轮廓的 OSC 特征并计算出代价矩阵;然后将目标形状点集

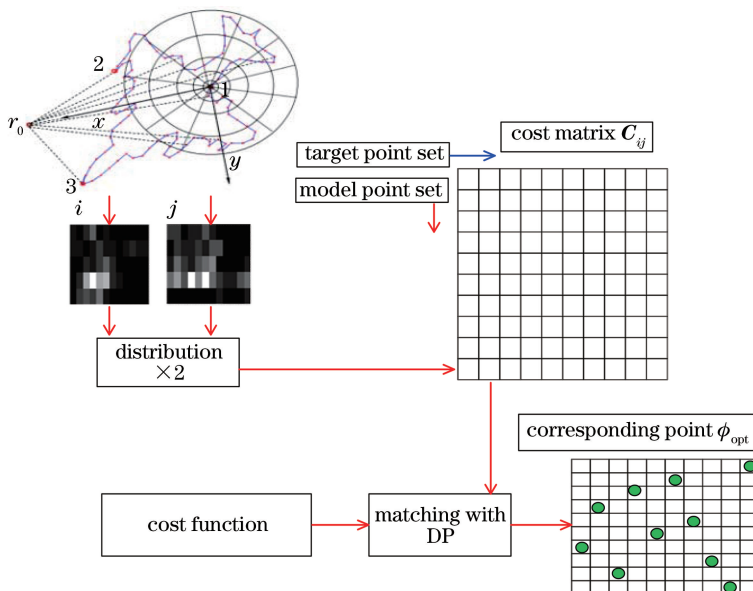


图 4 算法实现流程

Fig. 4 Flow chart of algorithm implementation

映射成具有二叉树的图结构,找出内部顶点 ν_0 并将其作为点集的根节点(参考点);最后基于DP优化算法对所提目标函数进行优化求解,选择能量代价最小的点作为匹配点,从而得到最终的对应匹配变换。算法步骤:1)用二叉树将数据点集映射成图表示结构;2)按照方法[3]找到形状点集内部根节点(参考点) ν_0 ,然后将每个模型点的OSC特征输入到目标代价函数(3)式中,计算模型点到数据点的匹配代价能量;3)根据(9)、(10)式,选择具有最小能量代价值的点作为对应匹配点;4)对最佳匹配点进行跟踪,得到最终的对应索引,以完成形状点集的定位、匹配识别等任务。

4 实验结果与分析

对比分析所提方法在合成和真实的湍流杂波场景中的匹配识别性能,所有实验均在PC i5 CPU和

8G RAM进行,运算软件为Matlab2012b。

4.1 实验数据

合成数据:原始形状数据源于完整而公开的Kimia数据集^[19-20]。其中,Kimia数据库^[19]包含6个类别共25个图像,数据库^[20]包含9个类别共99个图像。仿真合成的杂波形状由以上数据集一对一仿真构成,湍流几何畸变仿真使用方法^[2],离群点杂波噪声使用方法^[3]在 $[0.1\pi, 0.2\pi, \dots, 2\pi]$ 空间上的形状混合随机离群点模拟。湍流退化合成数据典型帧如图5所示。

实际外场中的远程成像数据:真实的远距离成像系统的可见光和红外图像序列由公共数据集^[21]获得,图中的目标点集形状数据是通过方法^[22]所获得的。如图6所示,真实目标物体的轮廓形状显示出强烈的杂波和严重的湍流变形,模板形状则采用人工制作的地面真值模型。

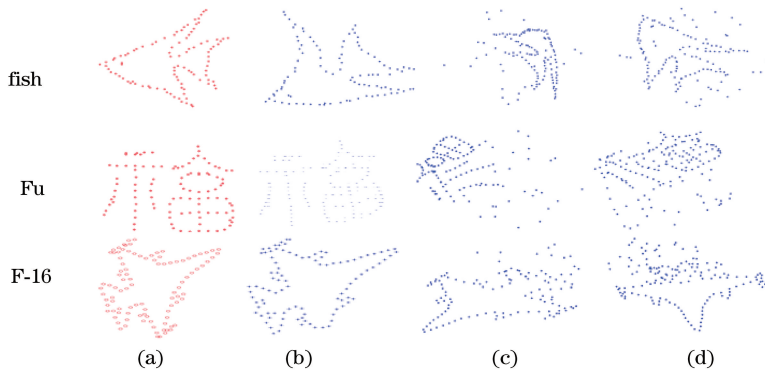


图5 湍流杂波场景下的仿真形状点集。(a)原图;(b)旋转和形变退化形状;(c)含旋转、形变、离群点的湍流杂波退化形状;(d)同时含旋转、形变、离群点噪声的强湍流杂波退化形状

Fig. 5 Simulation shape point sets under turbulence clutter scene. (a) Original image; (b) shape simultaneously degraded by rotation and deformation; (c) turbulence clutter degraded by deformation, outliers, and rotation; (d) strong turbulence clutter shapes degraded by deformation, outliers, and rotation




图6 远距离成像数据。(a)(b)外场湍流杂波场景下的图像数据;(c)(d)手动制作的私家车和卡车模板形状点集
Fig. 6 Long distance imaging data. (a)(b) Image data in turbulent clutter scene; (c)(d) manual model shape point set of personal car and truck

4.2 参数设置

在所提算法中,OSC特征算子设置的距离数 $n_d=5$,方向数 $n_\theta=12$,特征直方图维数为60。正则化参数由合成数据集得出,如图7所示,当 $(\lambda, \beta) = (1, 3)$ 时,Kimia数据集上仿真湍流退化的匹配误差

最小。因此在本实验中,将目标能量代价函数中的参数值设置为 $\lambda=1$ 和 $\beta=3$ 。

4.3 仿真杂波场景的实验结果

使用类似方法^[5]的平均匹配误差作为匹配识别的评估指标。平均匹配误差定义为模型形状点集




图 7 实验参数与平均匹配误差

Fig. 7 Average matching error and the experimental parameters

(地面真实目标形状)与所匹配的湍流杂波目标形状点集之间的欧氏距离。选取目前较为经典有效的点集匹配方法 (APM 方法^[5] 和 IDSC 方法^[8]) 进行比较。

首先证明边连续性的重要性。图 8 为合成湍流杂波场景下形变目标(‘鱼’)无边约束和有边连续性约束的匹配结果。可以看出,无边约束下匹配误差比有约束的误差大,同时旋转场景下的高精度匹配结果也表明 OSC 描述算子具有旋转不变性。

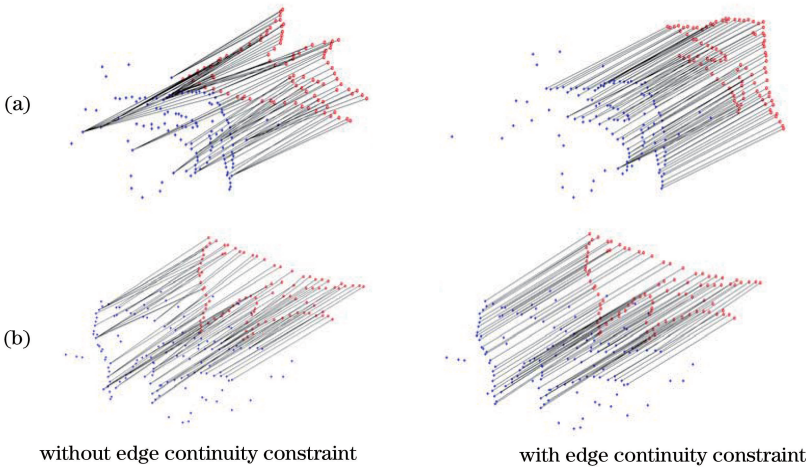


图 8 湍流杂波场景下所提方法对形变目标‘鱼’的匹配结果。(a)湍流噪声和旋转变换场景下的目标匹配结果;(b)湍流噪声场景下的目标匹配结果

Fig. 8 Matching results of proposed method for deformable target ‘Fish’ in turbulent clutter scene. (a) Target matching results in both turbulent noise and rotating scene; (b) target matching results in turbulent noise scene

实验还验证了所提方法的可靠性和有效性。图 9 有两种湍流退化杂波场景,图 9 第 1 行采用 20 个

杂波噪点和 $[0, 1\pi, 0, 2\pi]$ 空间上的形变模拟中等强度的湍流杂波场景,而图9第2行采用30个杂波噪




图 9 湍流杂波场景下不同方法对非刚体形变目标‘福’的匹配结果。(a)APM 方法^[5];(b)IDSC 方法^[8];(c)所提方法

Fig. 9 Matching results of different methods for non-grid deformable target ‘Fu’ in turbulent clutter scene.

(a) APM method^[5]; (b) IDSC method^[8]; (c) proposed method

点和 $[0.2\pi, 0.3\pi]$ 空间上的形变模拟高强度的湍流杂波场景。在仿真的湍流杂波场景下,所提方法获得了更高的匹配精度,相比其他方法更具鲁棒性。各种方法的匹配识别量化评价指标如表 1 所示,可

以看出,APM 方法^[5]的性能略优于 IDSC 方法^[8],而所提方法的匹配误差最小,能够将形状目标匹配误差平均降低约 6%,时间复杂度最低,总体表现最好。

表 1 不同方法在三类目标上的平均匹配误差和处理时间

Table 1 Average matching errors and processing time of different methods operating on three-type targets

Method	Average matching error			Processing time /s
	Fish	Fu	F-16	
APM method ^[5]	0.09	0.15	0.52	5.41
IDSC method ^[8]	0.11	0.17	0.64	1.39
Proposed method	0.03	0.12	0.14	0.87

4.4 现实湍流杂波场景下的实验结果

所提方法在仿真杂波退化序列实验中取得较好结果后,将在外场湍流杂波场景中进行实验。真实场景序列的目标形状往往与模板对象有较大区别,

目标形状会存在几何畸变、旋转、尺度变换及离群点等中的一种或多种退化现象。采用手动制作的模型(图 6)进行匹配实验,各种方法的匹配结果如图 10、11 和表 2 所示。

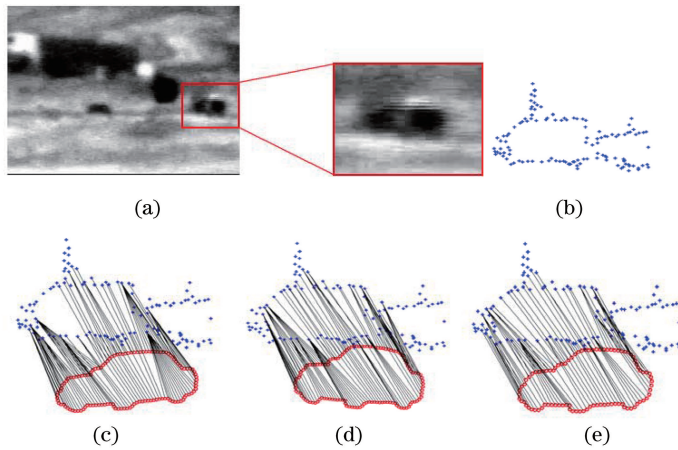


图 10 实际外场湍流杂波场景下不同方法对刚体形变目标‘私家车’的匹配结果。(a)获取的图像和放大的目标;(b)采用方法[19]获取的轮廓形状点集目标;(c) APM 方法^[5];(d) IDSC 方法^[8];(e)所提方法

Fig. 10 Matching results of different methods for grid deformable target ‘personal car’ in actual outfield turbulence clutter scene. (a) Acquired image and enlarged target; (b) contour shape point set target obtained by method in Ref. [19]; (c) APM method^[5]; (d) IDSC method^[8]; (e) proposed method

表 2 不同方法在两类外场湍流退化目标形状上的平均匹配误差和处理时间

Table 2 Average matching errors and processing time of different methods operating on the two-type outfield turbulence-cluttered sequences

Method	Average matching error		Processing time /s
	Personal car	Truck	
APM method ^[5]	0.10	0.35	7.62
IDSC method ^[8]	0.07	0.39	2.15
Proposed method	0.05	0.31	1.08

图 10 和图 11 湍流杂波形状目标匹配实验结果表明:所提方法在强杂波场景中得到了最好的匹配效果;但当目标形状轮廓边的噪声较大时(如图 11),所有方法的平均匹配误差都增大。值得注意的是,在图 11 匹配关系中,卡车大小发生变化,这是因为相应方

法中的匹配关系,模板发生缩小或者放大,但这并不影响方法之间的公平比较。另一方面,从表 2 可以看出,所提方法比 APM 方法^[5]的性能要好,而 APM 方法^[5]在一定程度上优于 IDSC 方法^[8]。所提方法的计算复杂度最低,单帧处理时间为 1.08 s。

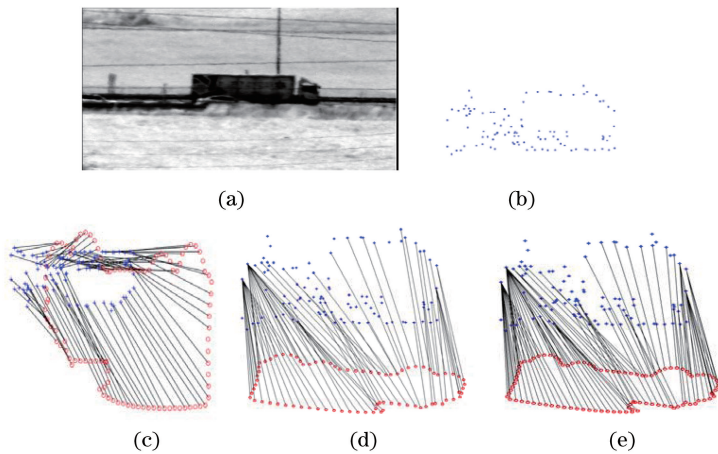


图 11 实际外场湍流杂波场景下不同方法对刚体目标‘卡车’的匹配结果。(a)获取的图像；(b)采用方法[19]获取的轮廓形状点集目标；(c) APM方法^[5]；(d) IDSC方法^[8]；(e)所提方法

Fig. 11 Matching results of different methods for grid deformable target ‘truck’ in actual outfield turbulence clutter scene.

(a) Acquired image; (b) contour shape point set target obtained by method in Ref. [19]; (c) APM method^[5]; (d) IDSC method^[8]; (e) proposed method

5 结 论

为了提高近地面远距离成像场景中形状点集匹配识别的鲁棒性和有效性,提出了一种基于方向形状上下文和形状边连续性约束的匹配能量代价函数模型。改进的方向形状上下文特征描述子能够保留形状点集的空间顺序,且具有旋转、缩放和变形不变性。同时,构建的匹配能量代价函数模型充分利用了形状边缘连续性先验,提高了匹配识别精度。在合成的和真实场景的湍流杂波形状数据上的实验结果表明,所提方法在复杂的远距离湍流杂波场景中具有最好的目标形状匹配识别精度,能够平均降低形状目标匹配误差约 6%。

参 考 文 献

- [1] Yang Z J, Vorontsov M A. Impact of atmospheric turbulence and refractivity on the modulation transfer function of incoherent imaging system[J]. Journal of Optics, 2017, 19(12): 125601.
- [2] Xu X G, Yang P, Liu Y, et al. Geometric distortion correction of long-range imaging containing moving objects[J]. Journal of Optics, 2019, 21(1): 015702.
- [3] Lowe D G. Distinctive image features from scale-invariant keypoints [J]. International Journal of Computer Vision, 2004, 60(2): 91-110.
- [4] Lian W, Zhang L, Zhang D. Rotation-invariant nonrigid point set matching in cluttered scenes [J]. IEEE Transactions on Image Processing: a Publication of the IEEE Signal Processing Society, 2012, 21(5): 2786-2797.
- [5] Lian W, Zhang L, Yang M H. An efficient globally optimal algorithm for asymmetric point matching[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(7): 1281-1293.
- [6] Shen W, Jiang Y, Gao W J, et al. Shape recognition by bag of skeleton-associated contour parts [J]. Pattern Recognition Letters, 2016, 83: 321-329.
- [7] 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.
- [8] Ling H B, Jacobs D W. Shape classification using the inner-distance [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2007, 29(2): 286-299.
- [9] Xu Z X, Yang P, Hu K, et al. Deep learning control model for adaptive optics systems [J]. Applied Optics, 2019, 58(8): 1998-2009.
- [10] Li M S, Chen S H, Chen X, et al. Actional-structural graph convolutional networks for skeleton-based action recognition [EB/OL]. (2019-04-26) [2019-12-22]. <https://arxiv.org/abs/1904.12659>.
- [11] Egozi A, Keller Y, Guterman H. Improving shape retrieval by spectral matching and meta similarity[J]. IEEE Transactions on Image Processing, 2010, 19(5): 1319-1327.
- [12] Torresani L, Kolmogorov V, Rother C. Feature correspondence via graph matching: models and global optimization [M] // Forsyth D, Torr P,

- Zisserman A. Computer vision-ECCV 2008. Lecture notes in computer science. Heidelberg: Springer, 2008, 5303: 596-609.
- [13] Yu L L, Xia X M, Zhou K, et al. Affine invariant fusion feature extraction based on geometry descriptor and BIT for object recognition [J]. IET Image Processing, 2019, 13(1): 57-72.
- [14] Zhao Y P, Xiao X Y, Xu W. Accelerating the optimal shape design of linear machines by transient simulation using mesh deformation and mesh connection techniques [J]. IEEE Transactions on Industrial Electronics, 2018, 65(12): 9825-9833.
- [15] García-Ordás M T, Alegre-Gutiérrez E, González-Castro V, et al. Combining shape and contour features to improve tool wear monitoring in milling processes [J]. International Journal of Production Research, 2018, 56(11): 3901-3913.
- [16] Pepperberg I M. Tool use in Goffin's cockatoos: shape/framematching [J]. Learning & Behavior, 2019, 47(1): 1-2.
- [17] Nie Y W, Cao X, Li P, et al. Interactive contour extraction via sketch-alike dense-validation optimization [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2020, 30(4): 903-916.
- [18] Guo J J, Zhong B J. U-chord curvature: a computational method of discrete curvature [J]. Moshi Shibie Yu Rengong Zhineng/Pattern Recognition and Artificial Intelligence, 2014, 27(8): 683-691.
- [19] Sharvit D, Chan J, Tek H, et al. Symmetry-based indexing of image databases [J]. Journal of Visual Communication and Image Representation, 1998, 9(4): 366-380.
- [20] Sebastian T B, Klein P N, Kimia B B. Recognition of shapes by editing their shock graphs [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2004, 26(5): 550-571.
- [21] Goyette N, Jodoin P M, Porikli F, et al. Changedetection. net: a new change detection benchmark dataset [C]//2012 IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops, June 16-21, 2012, Providence, RI, USA. New York: IEEE, 2012.
- [22] Xu X G, Yang P, Xian H, et al. Robust moving objects detection in long-distance imaging through turbulent medium [J]. Infrared Physics & Technology, 2019, 100: 87-98.