

引用格式:黎航,邹卫军,沈运.基于fast-LOF与光流轨迹的弱小目标检测算法[J].电光与控制,2019,26(4):39-43. LI H, ZOU W J, SHEN Y. An algorithm for weak and small target detection based on fast-LOF and optical flow trajectory[J]. Electronics Optics & Control, 2019, 26(4):39-43.

基于 fast-LOF 与光流轨迹的弱小目标检测算法

黎航^a, 邹卫军^b, 沈运^a

(南京理工大学, a. 先进发射协同创新中心; b. 自动化学院, 南京 210094)

摘要: 研究动态背景中弱小运动目标检测问题,提出了一种基于 fast-LOF 的光流轨迹分类方法。针对弱小运动目标占据像素少、特征缺失等问题,引入光流轨迹思想,在高维空间检测异常光流轨迹实现动态背景中弱小运动目标检测;针对传统 LOF 算法复杂度过高问题,引入 fast-LOF 降低异常检测环节复杂度,保证系统良好的检测效率。以手持摄像机拍摄视频进行实验,实验结果表明,白光场景中算法可以实现复杂大视场中弱小运动目标快速检测,光流轨迹和 fast-LOF 的结合有效提高了算法性能和检测效率,在视觉检测系统中具有一定使用价值。

关键词: 弱小运动目标; 光流轨迹; 异常检测; fast-LOF

中图分类号: TP391.4 文献标志码: A doi:10.3969/j.issn.1671-637X.2019.04.008

An Algorithm for Weak and Small Target Detection Based on Fast-LOF and Optical Flow Trajectory

LI Hang^a, ZOU Wei-jun^b, SHEN Yun^a

(Nanjing University of Science and Technology, a. Advanced Launching Cooperative Innovation Center; b. School of Automation, Nanjing 210094, China)

Abstract: In order to address the issue of detection for weak and small moving targets in dynamic background, a classification method was proposed based on fast-LOF and optical flow trajectory. Weak and small moving objects only occupy a few pixels and are lack of features. To solve the problem, an idea of optical flow trajectory was introduced, and the abnormal optical flow trajectories were detected in high-dimensional space, so as to realize the detection of weak and small moving targets in dynamic background. To solve the problem of high complexity of the traditional LOF algorithm, fast-LOF was introduced to reduce the complexity of the anomaly detection link and ensure a good detection efficiency of the system. Experiments were carried out using videos captured by handheld cameras. The results showed that the algorithm can achieve rapid detection of weak and small moving targets with complex large field-of-view in white-light scenes. The combination of optical flow trajectory with fast-LOF effectively improved the performance and detection efficiency of the algorithm, which has certain value in visual detection systems.

Key words: weak and small moving target; optical flow trajectory; anomaly detection; fast-LOF

0 引言

目标检测广泛应用于军民领域。SPIE 将弱小目标定义为目标区域像素数占视场总像素数不足 0.15% 的一类目标^[1]。弱小目标能够传达的视觉信息有限,因此难以找到合适的特征描述表示这类目标,这使 YOLO^[2], RCNN^[3] 等结合深度学习和图像特征的物体检测算法难以施展。传统弱小目标检测算法大致可归纳

为 DBT (Detection Before Tracking) 和 TBD (Tracking Before Detection) 框架。DBT 框架在单帧图像中利用合理阈值分割疑似目标,利用后续多帧图像时间特性分析疑似目标运动轨迹并确认目标; TBD 框架则根据目标运动特性跟踪所有疑似运动目标,根据时间维度下的短时灰度变化、目标能量累积等特征求取各运动轨迹后验概率,设定合理阈值作为分类决策边界^[4]。REED 等提出了一种基于三维匹配滤波的 TBD 算法^[5],在噪声自协方差已知的先验下,该算法可以使红外图像 SNR 达到极大值,实现二维空间滤波和一维时间能量累积的综合;文献^[6]构造序列图像中所有可能航迹树图,并计

收稿日期:2018-04-24

修回日期:2018-12-11

作者简介:黎航(1994—),男,安徽安庆人,硕士生,研究方向为图像处理。

算每条航迹的序贯似然比,实现了基于多级假设检验的 TBD 算法。然而传统算法依赖于灰度阈值分割或时间能量累积,在复杂场景中难以通过灰度阈值分割方法获取疑似目标,背景运动也给经典的三维匹配滤波器在连续多帧积累目标能量带来困难。文献[7]使用 SIFT 特征进行帧间特征点匹配并以此补偿背景运动,能够检测动态背景中的运动目标但实时性较差。

1 相关工作

1.1 fast-LOF 算法

类似于聚类,异常检测同样可以用于视觉计算,用以寻找视频中具备独特运动模式的部分像素点,亦即运动模型有别于背景运动的目标像素集合,这成为本文研究的出发点。局部离群因子(Local Outliers Factor, LOF)算法是一种基于密度检测异常的无监督学习算法,LOF 为每一个样本点返回 Score 以量化其离群程度。LOF 算法步骤如下所述。

1) 使用欧氏距离作为距离度量,为每一个样本 p 计算其 $k_D(p)$ 并寻找其 $k_{NN}(p)$, $k_{NN}(p)$ 定义为包含距离样本点 p 最近的 k 个其余样本点的集合, $k_D(p)$ 定义如下。

对于正整数 k ,在样本空间中,存在对象 o ,它与对象 p 之间距离记为 $d(p, o)$ 。如果满足如下两个条件,则认为 $k_D(p) = d(p, o)$:

- ① 集合 C 中,至少有不包含 p 在内的 k 个点 $o' \in C \setminus \{x | x \neq p\}$, 满足 $d(p, o') \leq d(p, o)$;
- ② 集合 C 中,最多有不包含 p 在内的 $k-1$ 个点 $o' \in C \setminus \{x | x \neq p\}$, 满足 $d(p, o') < d(p, o)$ 。

2) 依据各样本点的 $k_{NN}(p)$, 样本点 p 的局部可达密度为

$$L_{LRD}(p) = \frac{1}{\frac{\sum_{o \in k_{NN}(p)} r_{\text{dist}}(p, o)}{|k_{NN}(p)|}} \quad (1)$$

式中, $r_{\text{dist}}(p, o) = \max\{k_D(o), \|p - o\|\}$ 。

3) 计算样本点 p 的局部离群因子为

$$L_{LOF}(p) = \frac{\sum_{o \in k_{NN}(p)} \frac{L_{LRD}(o)}{L_{LRD}(p)}}{|k_{NN}(p)|} \quad (2)$$

LOF 数值越大,表示该样本点离群程度越高。LOF 由于其 $O(n^2)$ 的复杂度难以应用于大规模数据集。

GOLDSTEIN 提出 fast-LOF^[8] 将算法复杂度降为 $O(n \log(n))$, 以小幅牺牲精度为代价大幅提高检测效率。算法步骤如下:

1) 将包含 N 个样本的原始样本集随机划分为 \sqrt{N} 个样本集合;

2) 对于每一个样本点只在单个样本集合中计算其 k_{NN} , 以此估计各样本的 LRD 和 LOF;

3) 保留 LOF 高于阈值 θ 的样本;

4) 循环执行 1) ~ 3) 直至对于每一个样本都无法再更新 k_{NN} 。

综上,如果能够选取合适的特征集合来描述视频中像素帧间运动模式,并将各像素点或像素集合的运动特征描述作为无监督学习的样本集返回给 fast-LOF, 算法便可以实现动态背景中弱小运动目标检测。

1.2 金字塔 Lucas-Kanade 稀疏光流

光流方程解算基于如下假设:1) 亮度恒定;2) 时间连续且像素运动缓慢;3) 空间一致;4) 局部空间像素运动一致性。由于假设 2) 对相机采样频率等性能要求较为苛刻,因此有学者引入图像金字塔理论降低光流方程解算对假设 2) 的依赖^[9]。于是对于一个框内的所有像素点, Lucas-Kanade 算法给出了获取光流场的一般方法

$$\begin{bmatrix} u \\ v \end{bmatrix} = (A^T A)^{-1} A^T b \quad (3)$$

式中:

$$A = \begin{bmatrix} I_x(p_1) & I_y(p_1) \\ \vdots & \vdots \\ I_x(p_n) & I_y(p_n) \end{bmatrix} \quad (4)$$

$$b = \begin{bmatrix} I_t(p_1) \\ \vdots \\ I_t(p_n) \end{bmatrix} \quad (5)$$

$I_x(p_n)$, $I_y(p_n)$, $I_t(p_n)$ 表示框内像素点 p_n 对 x 轴、 y 轴和时间轴的偏导数。当 $(A^T A)$ 满秩亦即 $(A^T A)$ 可逆时,该超定方程组有唯一最小二乘解,直观上这意味着该框内至少存在两个不同方向的纹理或边缘,此时,跟踪窗口中心处于图像角点或细节处。

2 基于稀疏光流和 fast-LOF 的弱小目标检测算法

2.1 弱小目标增强及疑似目标(跟踪点)获取

基于以上工作,本文提出基于稀疏光流和 fast-LOF 的弱小目标检测算法,该算法采用 DBT 框架。算法首先为后续环节提供疑似目标,后续环节依据目标光流轨迹的一致性和连续性筛选真实目标。由前文已知图像中角点和细节能够为 Lucas-Kanade 算法中超定方程组提供唯一最小二乘解,而图像中弱小目标的表现形式往往是点状细节,这一特性为本文算法的疑似目标检测环节提供了查全率保障。

Top-Hat 是形态学处理手段,灰度级图像 f 的 Top-

Hat 定义为 f 减去其开操作,即

$$T_{\text{hat}}(f) = f - (f \circ b) \tag{6}$$

式中, b 为自定义结构元。假定 1920×1080 视场中弱小目标占据像素不足 25 个,即不足总像素 0.0012%。使用 5×5 模板作为开操作结构元,这一结构元在开操作过程中不会拟合像素面积小于 5×5 的点状细节。因此 Top-Hat 将返回图中点状细节,算法将其作为部分疑似目标^[10]。

但 Top-Hat 无法提取图像中像素面积远大于结构元大小的弱小目标(例如占据视场总像素 0.15% 的目标)。由于这类目标已经具备少量边缘特征,因此算法使用 Harris 角点来表示,即疑似目标检测环节还会对原图像进行 Harris 角点检测,提取得分较高的 300 个 Harris 角点加入疑似目标集合。

为避免疑似目标被重复选取,算法计算每一个疑似目标 $x(i)$ 与其他疑似目标的距离,距离小于阈值的疑似目标将会被剔除,该环节的算法复杂度为 $O(n \log(n))$ 。

2.2 光流轨迹分类

获取疑似目标集后,算法在帧间计算各疑似目标光流数据。由于大量疑似目标分布在背景区域,且真实目标运动模式和背景运动模式存在显著差异,所以在单帧内获取的光流数据样本中,正样本(定义真实目标光流数据为正样本,背景光流数据为负样本)常常表现为数量稀少的异常点。

单帧光流数据的空间分布如图 1 所示,图中 U 与 V 分别表示数据点光流在水平和垂直方向的投影。

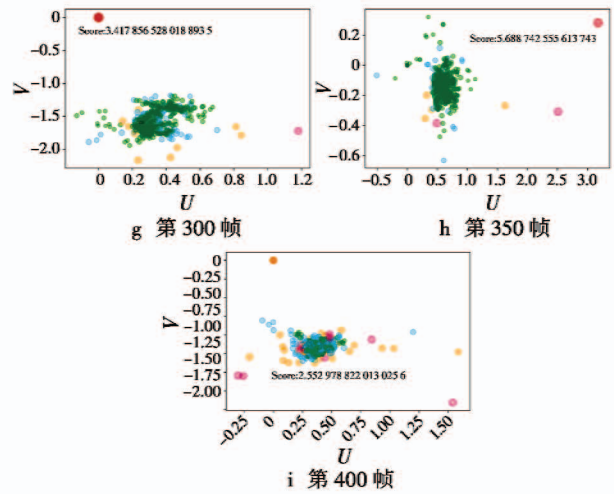
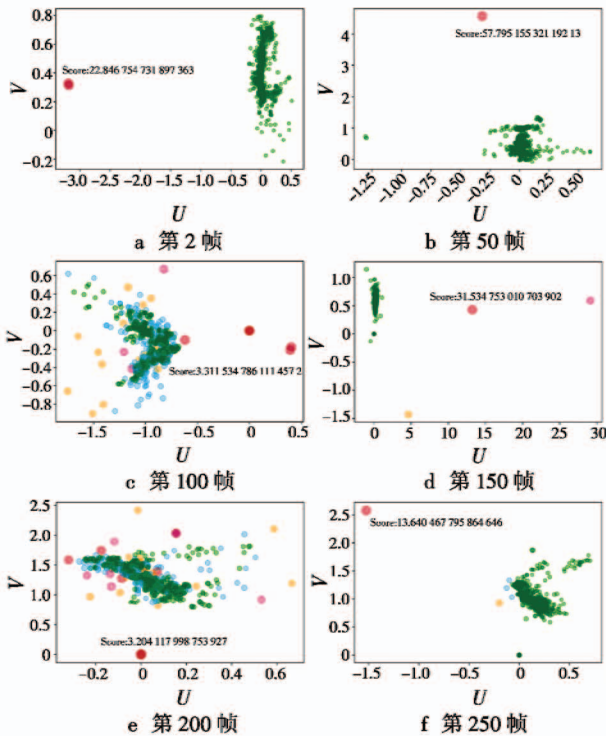


图 1 单帧光流数据分布可视化结果

Fig. 1 Visualized consequence of optical flow distribution in a single frame

图 1a ~ 图 1i 分别展示了测试样例第 2, 50, 100, 150, 200, 250, 300, 350, 400 帧中各疑似目标光流数据离群程度。使用 fast-LOF 度量各数据点离群程度并使用 Matplotlib 进行可视化,图中不同颜色表征数据点不同的离群程度。注意到,在少量视频帧中运动目标和动态背景可以近乎完美地被分割,例如在第 2 帧中。而在多数情况下针对运动目标的异常点检测会被数据噪声影响,这些噪声来源于视频中自然运动物体。该问题表现在测试视频样例中,如图 2 所示,真实运动目标位于天空区域,而检测器在左下角树叶处出现大量虚警。




图 2 基于单帧光流数据检测弱小运动目标的结果

Fig. 2 The results of detection for weak and small moving target based on single-frame optical flow data

依靠单帧光流数据检测目标没有充分利用视频的时间轴信息。因此本文提出光流轨迹分类以求减少甚至消除虚警,将光流轨迹定义为单个跟踪点在连续多帧内的光流数据点连接形成的轨迹,图 3 所示为一个 3 帧的光流轨迹,图中 U 与 V 分别表示单帧中数据点光流在水平和垂直方向投影。




图 3 光流轨迹

Fig. 3 Trajectory of optical flow

光流轨迹分类本质是通过增加时间维度特征来改善数据的可分性,对于当前帧无法消除的虚警,算法保留其当前帧光流数据,在下一帧光流数据到来时描述其轨迹特征,使用 fast-LOF 在更高维特征空间对轨迹分类,迭代此过程直至虚警数低于阈值。本文算法直接使用历史光流数据点坐标描述光流轨迹,为避免 fast-LOF 陷入维度灾难,在迭代超过 10 帧后算法将跳出循环直接输出检测结果。

2.3 算法流程

综上,本文算法流程如图 4 所示。

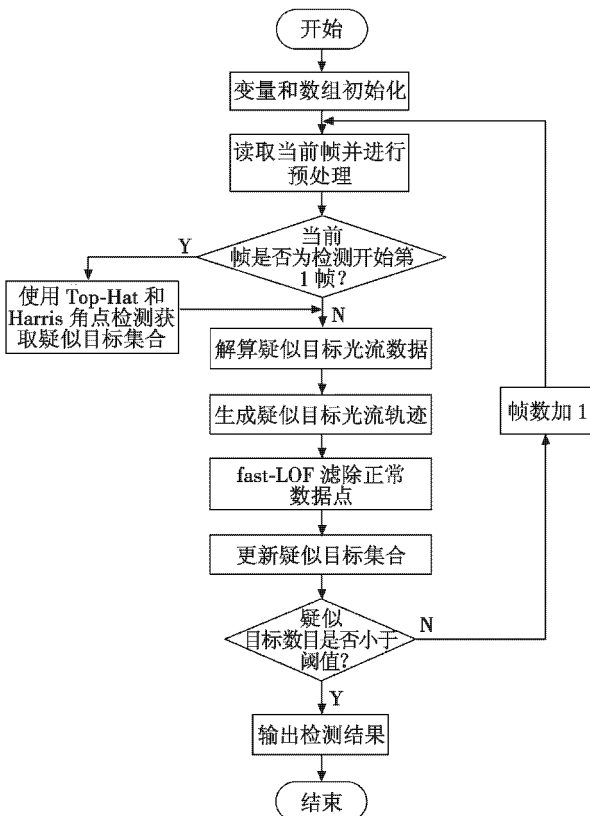


图 4 算法流程图

Fig. 4 Flow chart of the algorithm

3 实验结果分析

基于 Visual C++ 14 软件平台和 Core i7-7700k 硬

件平台对算法进行实验。实验所用测试样例来源于手持摄像机拍摄的像素大小为 1920 × 1080 视频,视频中弱小运动目标是在天空区域飞行的无人机,在复杂背景中肉眼难以快速发现。实验分多组进行,每组使用不同的测试样例,每一个测试样例视频时长 2 min 左右,对于每一个测试样例算法将在目标不同运动阶段进行多次检测。fast-LOF 中的 k 值设定为 5,疑似目标数量阈值设定为 5,异常检测决策阈值设定为 0.2。

图 5 展示算法在某一测试视频 310 帧处的迭代过程(橙色标记为疑似目标,红色标记为算法最终输出的真实目标),可见算法从开始检测后迭代 7 帧输出真实目标,亦即在光流轨迹的 14 维特征空间,弱小运动目标与运动背景已经具备良好的可分性。




图 5 算法迭代过程及检测结果

Fig. 5 The process of iteration and results of detection for the algorithm

单组实验中,在弱小目标不同的运动阶段进行多次实验,部分实验结果如图 6 所示(只展示算法最终输出结果而忽略算法迭代过程)。由图可知,在多数实验中算法可以正确检测天空中的无人机目标,少数情况下树叶和飞鸟会给检测器带来虚警。




图 6 实验结果

Fig. 6 Results of experiments

从各组实验中随机抽取了多组实验结果,统计检测器迭代帧数、起始帧疑似目标数及算法耗时,如表 1 所示。

表1 算法迭代次数及时间代价

Table 1 The number of iterations and the time cost for the algorithm

实验标号	迭代帧数	起始帧疑似目标个数	消耗时间/ms
1	1	395	113
2	1	411	133
3	2	409	181
4	2	752	279
5	5	403	298
6	4	530	307
7	3	734	326
8	3	674	328
9	7	509	385
10	2	1184	652

算法基本能够在 10 帧内检测出弱小运动目标,极少引发维度灾难。算法时间代价受迭代帧数和疑似目标数量影响,表 1 中第 9 次、第 10 次实验分别展示了在两种恶劣场景(较多迭代帧数和较多疑似目标)下算法的时间代价,可见在恶劣场景中算法仍然具有可观的检测速度,这证明 fast-LOF 的引入有效提高了本文算法的检测效率。

使用虚警率与漏警率度量检测精度,图 7 所示为异常检测的决策阈值对漏警率与虚警率的影响。




图7 检测精度曲线

Fig. 7 Curves of detection accuracy

从图 7 可以看出,随着决策阈值增大,漏警率逐渐增大而虚警率逐渐减小,二者呈负相关,这意味着必须根据实际应用场景对二者进行取舍。定义代价函数为

$$C_{\text{cost}} = C_{\text{MA}} P_{\text{MA}} + C_{\text{FA}} P_{\text{FA}} \quad (7)$$

式中: P_{MA} , P_{FA} 分别表示漏警率和虚警率; C_{MA} , C_{FA} 分别表示漏警惩罚因子和虚警惩罚因子,惩罚因子的取值取决于实际应用场景更注重减小漏警率还是虚警率。在本文应用场景中,选取漏警惩罚因子为 0.7,虚警惩罚因子为 0.3。最小化代价表明选取决策阈值为 0.2 进行迭代时,可以获得最佳检测精度,此时漏警率为 0.131,虚警率为 0.224。

4 结论

本文通过大量实验数据,可视化分析了将 fast-LOF 应用于动态背景中弱小运动目标检测这一思路的可行性。实验结果证明,在合理先验条件下,本文算法能够在较复杂运动背景中通过搜索异常光流轨迹成功检测出弱小运动目标,并且具备良好的检测效率。由于检测过程中避免了特征模板匹配,算法并不过多依赖目标或背景的视觉特征描述,因此对于光照等敏感条件具备较好的鲁棒性。

参考文献

- [1] 汪大宝. 复杂背景下的红外弱小目标检测与跟踪技术研究[D]. 西安:西安电子科技大学,2010.
- [2] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[C]//IEEE Conference on Computer Vision and Pattern Recognition, 2015:779-788.
- [3] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]//IEEE Conference on Computer Vision and Pattern Recognition, 2014:1-21.
- [4] 董华安,王建国,陆军,等. 基于匹配滤波器设计的粒子滤波检测前跟踪算法研究[J]. 电光与控制,2016, 23(9):44-48.
- [5] 张慧莉. 基于时空域滤波的红外小目标检测[D]. 哈尔滨:哈尔滨工业大学,2014.
- [6] BLOSTEIN S D, HUANG T S. Detecting small, moving objects in image sequences using sequential hypothesis testing[J]. IEEE Transactions on Signal Processing, 1991, 39(7):1611-1629.
- [7] 王亮芬. 基于 SIFT 特征匹配和动态更新背景模型的运动目标检测算法[J]. 计算机应用与软件,2010, 27(2):267-270.
- [8] GOLDSTEIN M. FastLOF: an expectation-maximization based local outlier detection algorithm[C]//The 21st International Conference on Pattern Recognition, 2012:2282-2285.
- [9] 张聪炫,陈震,黎明. 金字塔光流三维运动估计与深度重建直接方法[J]. 仪器仪表学报,2015, 36(5):1093-1105.
- [10] 吴健,陆书文,芮大庆,等. 基于背景抑制的改进 Top-Hat 红外小目标检测方法[J]. 电光与控制,2018, 25(9):42-44.