

文章编号 1004-924X(2012)02-0439-08

遮挡环境下采用在线 Boosting 的目标跟踪

颜 佳*, 吴敏渊

(武汉大学 电子信息学院, 湖北 武汉 430079)

摘要:针对被跟踪目标在发生严重遮挡时采用基于自学习方法的在线 Boosting 算法易导致错误累积而产生“漂移”甚至目标丢失的问题,提出了一种基于子区域分类器的在线 Boosting 算法。首先,将特征池划分为多个子区域分类器对应的子区域特征池;然后,在跟踪过程中自适应地选取子区域分类器来组成强分类器以剔除被遮挡子区域对目标定位的影响;最后,采用对子区域特征池进行部分更新的方法有效解决了特征在线更新时的错误累积问题。对不同视频序列测试的结果表明,当目标大面积被遮挡时本算法能准确定位目标,目标大小为 36 pixel \times 40 pixel 时的处理帧率为 15 frame/s。与传统在线 Boosting 算法相比,本算法对发生严重遮挡的目标仍能进行准确跟踪。

关键词:在线 Boosting; 目标跟踪; 子区域分类器; 抗遮挡

中图分类号: TP391 **文献标识码:** A **doi:** 10.3788/OPE.20122002.0439

On-line boosting based target tracking under occlusion

YAN Jia*, WU Min-yuan

(School of Electronic Information, Wuhan University, Wuhan 430079, China)

* Corresponding author, E-mail: yanjiaapple@tom.com

Abstract: A new on-line boosting algorithm based on sub-regional classifiers was presented to solve the problem that traditional on-line boosting based tracking algorithm often leads to drifting or failure due to the accumulated error during on-line updating under serious occlusions. Firstly, the feature pool was divided into a number of sub-regional feature pools to correspond to their sub-regional classifiers. Then, the sub-regional classifiers were selected adaptively into a strong classifier to eliminate the influence of occluded sub-regions on the target location when occlusions took place. Finally, the sub-regional feature pools were updated partly to solve the problem of accumulated error during on-line learning. The proposed algorithm was tested with variant video sequences and results show that proposed algorithm achieves exact tracking for the object occluded, and the average computing frame rate is 15 frame/s when the object scale is 36 pixel \times 40 pixel. In conclusion, the algorithm can satisfy the requirements of stability under occlusion as compared with the original on-line boosting algorithm.

Key words: on-line boosting; target tracking; sub-regional classifier; anti-occlusion

收稿日期: 2011-09-19; 修订日期: 2011-11-10.

基金项目: 国家自然科学基金面上项目 (No. 61072135)

1 引言

视频序列中的目标跟踪在计算机视觉领域有非常重要的地位和应用^[1-2]。近年来,目标跟踪领域的一个研究热点是将跟踪问题看作是在线分类问题^[3-5],目标跟踪的任务就是将视频序列每一帧中的目标和背景区分开来,一类属于目标,另外一类属于背景。这样做的好处是在跟踪过程中能针对目标形态的改变和背景的变化动态地调整目标背景区分所需分类器的组成。

文献[5]中提出了一种用于目标跟踪的在线 Boosting 算法,并引起了众多研究者的关注。该算法主要包括强分类器的生成和目标定位两个部分,其中用于分类的强分类器由多个特征选择器组成,然后在跟踪过程中利用被跟踪目标的位置获得训练需要的正负样本进行特征选择器的生成,每次生成中均挑选特征池里具有最小训练错误率的特征作为特征选择器。该方法能够很好地解决自适应目标及背景的变化问题,其缺陷是由于该方法是一种自学习的过程,将上一帧的跟踪窗口当作新的正样本,所以当目标发生遮挡时,被遮挡的正样本易导致特征池中的误差累积而产生“漂移”^[6-8]。

为了解决这一问题,文献[6-7]中将离线训练得到的先验知识融入在线 Boosting 中,并且提出强分类器由离线训练得到的强分类器和在线训练得到的强分类器按照一定的权重组合而成。该方法的问题是如何选择离线强分类器的权重来解决自适应与“漂移”之间的矛盾。文献[8-9]中采用了一种半监督的在线 Boosting 跟踪算法,利用第一帧得到的样本来训练跟踪过程中得到的新样本。但这种训练方法在目标形态持续变化的情况下限制了分类器的在线更新。文献[10]中提出了一种基于 Co-tracking 的目标跟踪算法,采用两种独立的特征来描述目标,并且采用协同训练的方法将两种特征中难于分类的样本交换进行训练,降低累积误差,但当目标发生遮挡时正负样本的标记错误会导致该方法的失效。文献[11]中提出了一种基于多实例学习的目标跟踪算法,该方法的思想是即使跟踪过程中目标定位出现偏差,但

联合附近多个样本进行学习总能得到一个用于在线更新的正样本。但在目标发生严重遮挡时,正样本中被“污染”的区域在弱分类器更新过程中仍将导致分类误差的累积。

上述方法均是在目标定位已经出现偏差的情况下考虑的一系列补救措施,而本文在分析了在线 Boosting 算法的缺陷后,提出了一种基于子区域特征选择器的在线 Boosting 算法来解决遮挡发生对目标定位的影响,并且考虑了遮挡过程中特征的在线更新问题。实验表明,本文提出的跟踪算法在目标大面积被遮挡时仍能很好地定位跟踪目标。

2 在线 Boosting 算法的缺陷

本节首先分析文献[5]中的在线 Boosting 跟踪算法的基本流程,然后指出该算法在目标被遮挡时出现跟踪“漂移”及目标丢失的原因。

在线 Boosting 算法中的强分类器由 N 个特征选择器 h_n^{sel} ($n=1, \dots, N$) 组成,这些特征选择器共用一个代表弱分类器(用 h_m ($m=1, \dots, M$) 表示)的特征池,并且一直维持和更新各个特征的累积分类正确样本权值 λ_m^{corr} 和分类错误样本权值 λ_m^{wrong} 。文献[5]中采用的特征主要是 Haar 特征,在目标整体区域内生成,并利用积分直方图^[12]的方法有效减少了特征计算时间。

在目标定位后,将跟踪窗口内的目标区域作为正样本,将跟踪窗口外和目标等大小的若干背景区域作为负样本。当新样本 (x, y) , $y \in \{0, 1\}$ 到达时, N 个特征选择器依次生成,每次生成均对 M 个特征进行更新:

当 $h_m(x) = y$ 时,

$$\lambda_m^{\text{corr}} += \lambda_{n-1}^x, \quad (1)$$

当 $h_m(x) \neq y$ 时,

$$\lambda_m^{\text{wrong}} += \lambda_{n-1}^x, \quad (2)$$

其中的 λ_{n-1}^x 为样本当前的权值,初始值为 1。更新完毕后,每个特征选择器将挑选当前最小累积错误率的特征作为其对应的弱分类器: $h_n^{\text{sel}} = h_m^+$, $m^+ = \arg \min_m (\epsilon_m)$, 其中 ϵ_m 为每个特征的累积错误率: $\epsilon_m = \frac{\lambda_m^{\text{wrong}}}{\lambda_m^{\text{wrong}} + \lambda_m^{\text{corr}}}$ 。 h_n^{sel} 的权重为 $\alpha_n = \frac{1}{2} \ln$

$$\left(\frac{1-\epsilon_n}{\epsilon_n}\right), \epsilon_n = \epsilon_m^+.$$

第 n 个特征选择器 h_n^{sel} 生成后,样本 (x, y) 的权值 λ_{n+1}^x 也根据是否被 h_n^{sel} 错分来进行增加或减少。经过 N 次挑选后,强分类器由这 N 个挑选出来的特征按照各自的权重组合而成:

$$H(x) = \text{sign}\left(\sum_{n=1}^N \alpha_n h_n^{\text{sel}}(x)\right). \quad (3)$$

目标新位置通过在上一帧时目标位置附近范围内用强分类器评价决定。设搜索范围为 S , S 内的目标候选位置为 $p_w (w=1, \dots, W)$, 目标新位置为 x_{new} 。则 $x_{\text{new}} = p_w$, 其中 w^+ 为:

$$w^+ = \arg \max_w \left(\sum_{n=1}^N \alpha_n h_n^{\text{sel}}(p_w)\right). \quad (4)$$

从式(4)可以看出,目标定位时需要 N 个特征选择器在 W 个候选位置上进行评价。传统的在线 Boosting 算法中未提供解决目标大面积遮挡时如何精确定位问题的处理机制,当目标发生大面积遮挡时,无法判断哪些 h_n^{sel} 此时是可靠的,而哪些 h_n^{sel} 会位于被遮挡区域之中而不再可靠,从而导致真正的目标处并不满足式(4),造成目标定位的偏差。从式(1)、(2)可以看出,对特征池中特征的更新过程属于自学习的过程,正负样本的标记完全依赖于上一帧中目标的定位结果。而上述的目标定位偏差将会导致正样本的错误标记,

而这个正样本在对特征池中的所有特征进行更新的过程中会造成累积错误,跟踪出现漂移。

图 1 给出了传统在线 Boosting 算法 (OLB tracker) 对一段视频序列 Face^[13] 进行跟踪的两组实验结果(初始跟踪窗口均为手工选定,其大小为 $78 \text{ pixel} \times 112 \text{ pixel}$; 目标描述特征均为 Harr 特征;每次用于训练的正样本 1 个,负样本 4 个;搜索范围 S 为目标大小的 1.5 倍)。其中,白色矩形框是 $N=30, M=150$ 时的跟踪结果;黑色矩形框是 $N=120, M=600$ 时的跟踪结果。可以看出,当目标左脸部轻微遮挡时(第 292 帧),OLB tracker 依然能很好地定位目标,但当大面积遮挡发生(第 375 帧)时定位出现偏差,正样本标记错误,而随后的持续遮挡过程(第 375 帧至第 442 帧)造成的特征池的累积错误导致该次遮挡结束后(第 442 帧至第 536 帧),仍然无法定位到真正的目标。值得注意的是第 536 帧中,当时由于用于区分目标和背景的特征过少导致跟踪窗口完全“漂移”。本文提出的在线 Boosting 算法中采用了子区域分类器来构成强分类器,能很好地降低大面积遮挡对目标定位的影响;并能自适应地对特征池进行更新,既能避免滞后更新,又能避免被遮挡样本在弱分类器更新过程中造成的累积误差。

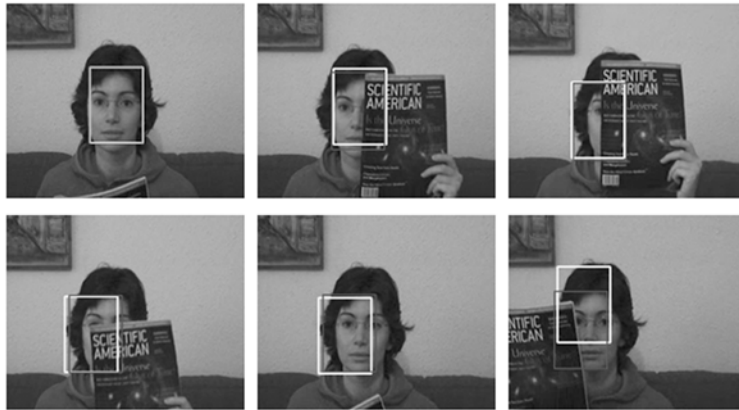


图 1 OLB tracker 对 Face 视频序列的跟踪结果(第 1,292,375,432,442 和 536 帧)

Fig. 1 Tracking results of Face sequence using OLB tracker (Frame 1,292,375,432,442 and 536)

3 子区域分类器

传统在线 Boosting 算法中用于目标定位的

强分类器由特征选择器构成,如式(3)所示,其中的 N 个 h_n^{sel} 并未包含其在目标区域内的位置信息。本文中提出的在线 Boosting 算法中的强分类器由带有所处位置信息的子区域分类器构成:

$$H(x) = \sum_{t=1}^T \omega_t H_t^{\text{sr}}(x), \quad (5)$$

式(5)中, T 代表目标划分的子区域个数; $H_t^{\text{sr}}(x)$ 代表第 t 个子区域分类器; ω_t 为第 t 个子区域分类器在 $H(x)$ 中的权重。这样做的好处是在某些子区域被遮挡时, 能够增强其他子区域分类器的权重来构成强分类器。其中的子区域分类器 $H_t^{\text{sr}}(x)$ 由 N_t 个特征选择器构成:

$$H_t^{\text{sr}}(x) = \sum_{n=1}^{N_t} \alpha_n h_n^{\text{sel}}(x). \quad (6)$$

因此, 目标定位所需的式(4)的形式如式(7)所示:

$$\omega^+ = \arg \max_w \sum_{t=1}^T \left(\omega_t \left(\sum_{n=1}^{N_t} \alpha_n h_n^{\text{sel}}(p_w) \right) \right). \quad (7)$$

在传统在线 Boosting 框架中加入子区域分类器后, 新的目标跟踪算法中需要考虑以下几个问题: 特征池中特征的更新过程、子区域分类器权重 ω_t 的取值和子区域的划分方式。

3.1 特征更新

在特征更新中, 和传统在线 Boosting 算法中特征选择器共用特征池不同的是, 本文采用 T 个特征池 $h_m^t (t=1, \dots, T; m=1, \dots, M_t)$, 分别对应于 T 个子区域分类器。因此, 当新样本到来时, 共需生成 T 个子区域分类器 $H_t^{\text{sr}}(x)$, 而构成每个子区域分类器 N_t 的个特征选择器 $h_n^{\text{sel}}(x)$ 通过在特征池 h_m^t 中经过 N_t 次挑选产生, 同时对 h_m^t 中的特征进行更新。

子区域分类器 $H_t^{\text{sr}}(x)$ 的置信度代表了子区域 t 的被遮挡情况, 当子区域 t 被遮挡时, $H_t^{\text{sr}}(x)$ 变小。为避免遮挡对特征池更新的影响, 在跟踪过程中本文对最小值的 $H_t^{\text{sr}}(x)$ 所对应的特征池选择不更新(而传统在线 Boosting 算法中不论样本是否被遮挡均对全部特征进行更新, 如式(1)(2)所示)。设 t^- 代表最小的子区域分类器编号:

$$t^- = \arg \min_t (H_t^{\text{sr}}(x)), \quad (8)$$

那么, 特征池 $h_m^{t^-}$ 中的 M_{t^-} 个特征不参与特征的更新过程, 避免了被遮挡样本导致池中特征的累积错误。

3.2 权重 ω_t 的取值

权重 ω_t 的取值可以采用多种方式, 本文中采用对除了 $H_t^{\text{sr}}(x)$ 之外的子区域选择器赋予相同权重的方式, 即:

$$\omega_t = \frac{1}{T-1} (t \neq t^-), \quad (9)$$

同时取 $\omega_{t^-} = 0$, 这样做的原因是往往遮挡导致被遮挡的子区域分类器表现最差。因此, 在目标定位时, 采用式(7)能有效剔除掉被遮挡子区域对目标定位的影响(实验结果表明, 当目标未发生遮挡时, 舍弃掉表现最差的子区域分类器也不影响目标的定位)。

3.3 子区域的划分

算法初始化时需将目标分成若干子区域。当子区域面积太小时, 特征池中的特征过少会导致子区域分类器分类能力下降; 而当子区域面积太大会降低抗遮挡能力, 当子区域数目 $T=1$ 并且其面积等于目标区域面积时即变为传统的在线 Boosting 算法。所以本文采取一种简单的划分方法(在本文实验中一直采用该划分方式), 如图 2 所示, 将目标区域横向和纵向分别对等划分为两部分。子区域的数目即为横向两个和纵向两个, $T=4$ 。



图 2 本文中采用的子区域划分示意图

Fig. 2 Scheme of divided subregions

4 跟踪算法流程

传统在线 Boosting 算法在目标进入遮挡时易出现“漂移”和跟丢的问题, 而本文采用了子区域分类器降低遮挡发生对目标定位和对在线训练中特征更新的影响。首先按图 2 中方法得到 T 个子区域并生成个特征池 h_m^t , 初始化特征池中每个特征的分类正确样本权值和分类错误样本权值 $\lambda_m^{\text{corr}} = \lambda_m^{\text{wrong}} = 1$, 随后每帧中的跟踪算法流程如表 1 所示。

从表 1 中可以看出, 本文的跟踪算法框架相比传统在线 Boosting 算法框架仅更改了强分类器和特征池的组成形式。因此, 本文提出的用于遮挡处理的子区域分类器机制同样可以方便地加进文献[4]和文献[11]的跟踪算法框架之中。

表 1 本文提出的基于子区域分类器的目标跟踪算法

Tab. 1 Proposed SROLB tracker algorithm

算法 1 基于子区域分类器的目标跟踪算法
 根据本帧中的跟踪窗口得到样本 $(x, y), y \in \{0, 1\}$
 For $t=1, \dots, T (t \neq t^*)$ //每个不满足式(8)的子区域分类器

 样本初始权值: $\lambda_0^s = 1$
 For $n=1, \dots, N_t$ //每个特征选择器

 For $m=1, \dots, M_t$ //特征池 h_m^t 中的每个特征

 按式(1)(2)更新特征

 计算特征目前的累积错误率 ϵ_m

 End For

 得到第 n 个特征选择器 h_n^{sel}

 计算特征选择器的权重 α_n

 更新样本权值 λ_{t+1}^s

 End For

 按式(6)得到子区域分类器 $H_t^r(x)$

End For

按式(9)和(5)更新强分类器

按式(7)在下一帧中进行目标定位

5 实验结果及分析

在下面两组实验中本文算法的关键参数设置如下: $T=4, N_t=30, M_t=150$, 其余参数均与传统在线 Boosting 算法一致。实验均在 Intel 酷睿双核 T5800 的 CPU, 2G 内存配置的电脑上使用

Visual Studio 2005 编程实现。

实验 1 采用本文算法 (SROLB tracker) 对 Face 视频序列进行跟踪的部分结果如图 3 中所示, 其中每帧上叠加的数字为子区域分类器的评价置信度从大到小排列, 如第 292 帧处于子区域分类器 1 的置信度最高。可以看出, 当目标被严重遮挡时 (第 375 帧), 子区域分类器 3 的置信度最低, 这正是由于子区域 3 被完全遮挡造成的, 此时子区域分类器 3 并未纳入式(7)进行目标定位 ($t^*=3, \omega_3=0$), 所以本文算法相较传统在线 Boosting 算法很好地抑制了“漂移”的发生。当目标未发生遮挡时 (第 442 帧), 本文算法利用置信度最高的三个子区域分类器仍然能准确定位目标。值得注意的是, 目标从第 375 帧到第 432 帧发生连续遮挡过程, 本文算法仍能准确定位目标, 这正是因为连续遮挡时仍能持续利用未被遮挡的子区域分类器来进行定位的结果。

图 4 给出了跟踪过程中随着目标被遮挡部位不同, 4 个子区域分类器的置信度变化曲线图。可以看出, 子区域分类器 3 和 4 起伏变化明显。从第 300 帧到第 400 帧的时间内, 目标人脸的左脸被持续遮挡直到完全遮挡, 因此这段时间内子区域分类器 3 的置信度一直是最底的。从第 450 帧开始, 目标人脸的下部被持续遮挡, 因此子区域分类器 4 的置信度迅速下降, 并一直保持最低。图 4 也表明了本文中采用子区域分类器来判断遮挡情况的可行性。

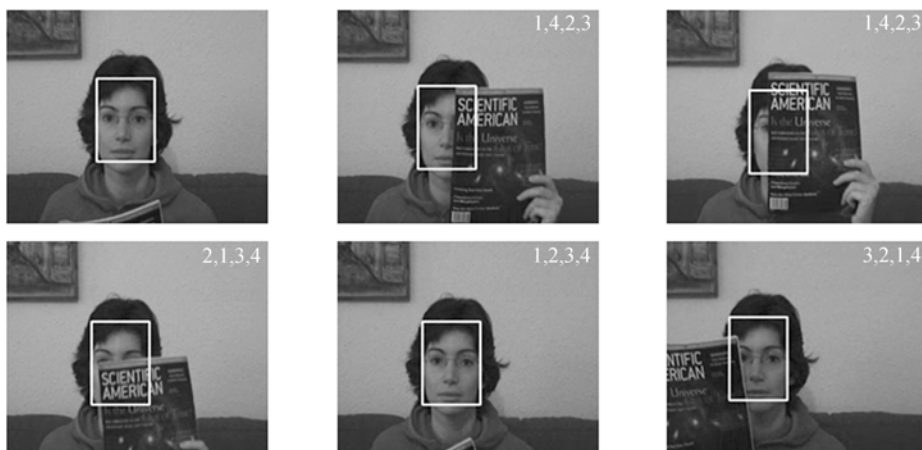


图 3 本文的 SROLB tracker 对 Face 视频序列的跟踪结果 (第 1, 292, 375, 432, 442 和 536 帧)

Fig. 3 Tracking results of Face sequence using proposed SROLB tracker (Frame 1, 292, 375, 432, 442 and 536)

实验 2 图 5 中给出了分别采用传统在线 Boosting 算法和本文算法对视频序列 Tiger^[9] 的

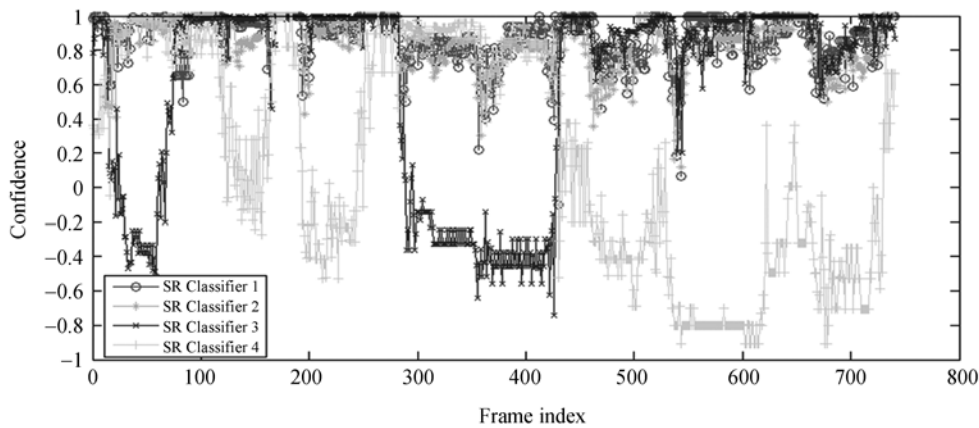


图 4 Face 视频序列中各子区域分类器的置信度曲线

Fig. 4 Confidences of sub-regional classifiers according to occlusions in Face sequence

跟踪结果。上排是 OLB tracker 的跟踪结果(其中白色矩形框是 $N=120, M=600$ 时的跟踪结果,黑色矩形框是 $N=150, M=750$ 时的跟踪结果);下排是 SROLB 的跟踪结果。该视频中目标的特点是除了不断被树叶遮挡外,还伴有自身角度的变化。可以看出,本文算法中的跟踪窗口能

很好地定位在目标之上;而两种参数配置的 OLB 跟踪窗口均完全偏离目标(白色:第 203 帧;黑色:第 150 帧)。值得注意的是,当 OLB 中在线训练使用的特征个数(黑色)多于本文算法中的 600 个(4×150)时,仍然丢失目标,这正是由于 OLB 中没有遮挡处理机制所造成的。图 6 给出了上述



图 5 Tiger 视频序列的跟踪结果(第 1,98,150,203 和 333 帧。上排:OLB,下排:SROLB)

Fig. 5 Tracking results of Tiger sequence (Frame 1, 98, 150, 203 and 333. Upper:OLB, Lower:SROLB)




图 6 Tiger 视频序列的跟踪误差

Fig. 6 Tracking errors of Tiger sequence

3 种跟踪算法的跟踪误差曲线图。

由于本文算法中仅将共用的特征池划分为了独立的 4 个特征池,并未增加特征更新过程中特征的总个数,所以在特征更新阶段未增加算法的运行时间;并且目标定位时使用的特征选择器个数($4 \times 30 = 120$ 个)也和传统在线 Boosting 算法中(120 个)的相同,因此在每个候选位置上的评价次数不变,所以目标定位阶段算法的运算量也未增加。实验 1 和实验 2 中采用本文算法的处理帧率分别为 10、15 frame/s。

6 结 论

针对传统在线 Boosting 算法在目标发生遮挡时易发生跟踪“漂移”和目标丢失的缺陷,本文首先分析了该缺陷产生的原因,即目标定位时缺乏对遮挡的判断机制和特征更新时被遮挡样本造成的累积错误。然后提出了子区域分类器的概

念,并给出了本文的改进办法。首先将特征池划分为多个子区域分类器对应的子区域特征池,然后在跟踪过程中仅利用置信度高的子区域分类器组成强分类器以降低被遮挡子区域对目标定位的影响,并且采用对置信度高的子区域分类器所对应的子区域特征池进行更新的方法,有效解决了特征在线更新的问题。本文对不同视频序列中的目标进行跟踪,实验结果表明,本文算法在目标大面积发生遮挡和持续遮挡时仍能准确跟踪目标,当目标大小为 36 pixel \times 40 pixel 时,平均处理帧率为 15 frame/s。当目标大小发生变化时,本文算法中可以采用文献[3]中将跟踪窗口放大和缩小然后选取置信度最大的跟踪窗口作为最后目标的方法来解决这一问题。但这种“试探”的方法会导致计算量至少增加为原来的 3 倍,如何更好地解决目标大小发生变化并且伴有遮挡时的跟踪问题是本文后续研究的重点。

参考文献:

- [1] 颜佳,陈淑珍,吴敏渊,等. 应用 Mean Shift 和分块的抗遮挡跟踪[J]. 光学精密工程, 2010, 18(6): 1413-1419.
YAN J, CHEN SH ZH, WU M Y, *et al.*. Anti-occlusion tracking algorithm based on Mean Shift and fragments[J]. *Opt. Precision Eng.*, 2010, 18(6):1413-1419. (in Chinese)
- [2] 王国良,刘金国. 基于粒子滤波的多自由度运动目标跟踪[J]. 光学精密工程, 2011, 19(4):864-869.
WANG G L, LIU J G. Moving object tracking with multi-degree-of-freedom based on particle filters[J]. *Opt. Precision Eng.*, 2011, 19(4): 864-869. (in Chinese)
- [3] COLLINS R, YANX L, LEORDEANU M. Online selection of discriminative tracking features [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2005, 27(10):1631-1643.
- [4] AVIDAN S. Ensemble tracking[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2007, 29(2):261-271.
- [5] GRABNER H, GRABNER M, BISCHOF H. Real-time tracking via on-line boosting[C]. *Proceedings of British Machine Vision Conference*, 2006,1:47-56.
- [6] 程有龙,李斌,张文聪,等. 融合先验知识的自适应行人跟踪算法[J]. 模式识别与人工智能, 2009, 22(5):704-708.
CHENG Y L, LI B, ZHANG W C, *et al.*. An adaptive pedestrian tracking algorithm with prior knowledge[J]. *Pattern Recognition and Artificial Intelligence*, 2009, 22(5):704-708. (in Chinese)
- [7] TAKAYOSHI Y, HIRONOBU F, SHIHONG L, *et al.*. Human tracking based on soft decision feature and online real boosting[C]. *19th International Conference on Pattern Recognition*,2008:1-4.
- [8] GRABNER H, LEISTNER C, BISCHOF H. Semi-supervised on-line boosting for robust tracking[C]. *Proceedings of European Conference on Computer Vision*, 2008:234-247.
- [9] GODEC M, GRABNER H, LEISTNER C, *et al.*. Speeding up semi-supervised on-line boosting for tracking[C]. *Proceedings of the Austrian Association for Pattern Recognition*,2009:1-12.
- [10] TANG F, BRENNAN S, ZHAO Q, *et al.*. Co-tracking using semi-supervised support Vector Machines[C]. *Computer Vision and Pattern Recognition, IEEE Computer Society Conference*, 2009: 1-8.
- [11] BABENKO B, MING-HSUAN Y, BELONGIE S. Visual tracking with online multiple instance learn-

- ing[C]. *Computer Vision and Pattern Recognition, IEEE Computer Society Conference*, 2009: 983-990.
- [12] FATIH P. Integral histogram: a fast way to extract histograms in Cartesian spaces[C]. *Computer Vision and Pattern Recognition, IEEE Computer Society Conference*, 2005:829-836.
- [13] ADAM A, RIVLIN E, SHIMSHONI I. Robust fragments-based tracking using the integral histogram [C]. *Computer Vision and Pattern Recognition, IEEE Computer Society Conference*, 2006, 1: 798-805.

作者简介:



颜 佳(1983—),男,湖北天门人,博士后,2010年于武汉大学获得博士学位,主要从事目标跟踪、机器视觉等方面的研究。E-mail: yanjiaapple@tom.com



吴敏渊(1964—),男,湖北武汉人,副教授,1984年、1989年于武汉测绘科技大学分别获得学士、硕士学位,主要从事图像处理、机器视觉等方面的研究。E-mail: wmy@eis.whu.edu.cn

●下期预告

空间遥感相机碳纤维机身结构的研究

郭 疆,邵明东,王国良,孙继明

(中国科学院 长春光学精密机械与物理研究所,吉林 长春 130033)

碳纤维复合材料具有密度小、强度大、模量高的特点,在空间光学遥感器上运用碳纤维复合材料可以极大地减轻遥感器重量,但由于碳纤维复合材料具有各向异性、吸湿不稳定性,使其在稳定性要求较高的空间遥感上的应用受到了限制。本文的离轴三反相机的一些关键部件采用了碳纤维复合材料,复合材料占整机重量的32%。本文的离轴三反相机机身结构为非对称形状,且光学系统中主、次镜间距为850 mm、反射镜接口定位精度要求间隔0.005 mm、偏心0.005 mm、倾斜5",针对光学系统对机身结构的要求,选择了碳纤维复合材料,设计了合适的相机机身结构形式,通过有限元软件对设计结果反复进行分析、优化和复核,完成了机身结构的优化设计。计算结果表明,该机身结构具有较好的刚度、较轻的质量,能够满足光学设计对间隔,偏心和倾斜的要求,通过对总装完成的相机进行的力学环境试验、热真空试验等试验的验证,证明了该相机机身结构在力、热等环境条件下稳定性优良,其一阶谐振频率在120 Hz以上,相机调制传递函数为0.2以上,满足离轴三反空间相机各反射镜的空间位置精度和稳定性的要求。