

复杂背景下目标检测的级联分类器算法研究*

高文^{1)2)†} 汤洋¹⁾ 朱明¹⁾²⁾

1) (中国科学院长春光学精密机械与物理研究所, 长春 130033)

2) (中国科学院航空光学成像与测量重点实验室, 长春 130033)

(2013年12月3日收到; 2013年12月23日收到修改稿)

目标检测与跟踪一直是图像处理与计算机视觉领域的热门研究方向之一, 其对军事上的成像制导、跟踪军事目标等以及民事方面的安防监控、智能人机交互等方面均有着重要的研究价值. 将特征匹配问题看成是一种更普遍的二分类问题, 将这种难解的高维计算变成二分类问题, 使计算复杂度大大减小, 这类方法以大数定律和贝叶斯法则为理论依据, 本文提出一种非树形结构的分类器, 并从理论上推导出其实现公式, 将1bitBP特征应用到分类器中, 同时采用计算量由小到大的三个分类器进行级联从而实现鲁棒精确的目标检测. 从实验结果来看, 本文算法能够对目标的尺度变化、旋转、部分遮挡、形变、模糊、背景变化等复杂情况有较好鲁棒性, 并且检测精度相对较高, 而本文算法的计算复杂度低、计算量小, 有较高的应用价值.

关键词: 目标跟踪, 目标检测, 随机树, 分类器

PACS: 42.30.Va, 42.30.Tz, 07.05.Pj, 02.50.-r

DOI: 10.7498/aps.63.094204

1 引言

复杂背景下的目标检测^[1,2]与跟踪一直是图像处理^[3,4]与计算机视觉^[5,6]领域的热门研究方向之一, 其对军事上成像制导、跟踪军事目标等以及民事方面安防监控、智能人机交互等方面均有重要研究价值^[7-9]. 复杂背景下目标检测的难点在于对目标的有效表征以及适应在对比度低、背景杂乱、目标模板与检测过程中的拍摄角度不同、光照不同造成的目标尺度、旋转角度、光照等外观差别较大的宽基线匹配问题.

对目标的表征在某种程度上决定了匹配方法, 由Tomasi等^[10]提出的光流法, 其提取图像中差分矩阵的特征值较大的点作为感兴趣点, 再采用最小二乘法拟合目标的运动参量从而检测到目标, 该方法假设目标运动变化较小, 因此对于复杂背景下目标检测的应用有较大局限; Lowe^[11]提出尺度不变特征(SIFT), 其通过计算多尺度高斯差分图像并寻

找局部极大值点的方法得到在一定范围内尺度、旋转角度不变性, 但是其计算复杂度高, 特征向量维数高, 特征匹配计算量大, 很难保证实时性; 主成分分析(PCA)^[12,13]在尽量保证图像原特征的前提下将高维图像投影到低维空间, 是图像稀疏^[14-16]表示的雏形, 一直得到研究者青睐, 但其同样存在求向量基时计算矩阵分解时实时实现困难的问题.

自从Lepetit等^[17]提出将特征匹配问题看成一种更普遍的二分类问题, 将这种难解的高维计算变成二分类问题使计算复杂度大大减小, 从而将统计学习、机器视觉等方面理论引入目标检测跟踪, 为解决目标检测和跟踪问题提供了新思路.

Grabner等^[18]把自适应提升(Adaboost)算法设计成可以在线更新的方式, 在跟踪的过程中分类器用于实现对前景目标和背景分类并根据上一帧分类结果进行在线学习和更新, 这类方法最大问题是如何在跟踪过程中选择合适的正例和负例. Babenko^[19]受到文献^[20]启发提出一种在线多示例Boost跟踪方法来减小正例和负例选择错所带来

* 中国科学院航空光学成像与测量重点实验室开放基金(批准号: Y2HC1SR121)资助的课题.

† 通讯作者. E-mail: cwenzi@126.com

的影响. 文献 [21] 提出一种在线随机森林方法, 跟踪过程通过在线随机森林分类器的学习来适合外观变化. 随后 Leistner [22] 以随机森林的原则设计了在线随机朴素贝叶斯分类器, 减少了计算量却可获得类似的效果.

这类方法以大数定律和贝叶斯法则为理论依据, 文献 [21] 中采用随机树分类器进行目标特征匹配, 虽然计算复杂度大幅下降, 但这种分级的树形结构限制了其特征数量以及进一步的优化.

通过对随机树分类器的学习研究, 本文提出一种非分级结构的分类器对随机树的问题进行改进, 并从理论上推导出其实现公式, 将 1bitBP 特征应用到分类器中, 采用文献 [23] 中的 Sliding Window 搜索策略, 并在初始化非树形结构分类器时, 采用文献 [19] 的包袋思想在目标周围选取五个图像区域作为目标一起进行分类器训练, 并受 D-BRIEF 特征 [24] 的启发, 在初始化时进行对目标图像旋转、缩放建立完整的目标全视角数据库从而对于目标旋转、缩放、外观局部变化等有很好的鲁棒性, 并且这些工作都只是在初始化进行对于处理速度没有任何影响. 为进一步减少计算量, 受积分图启发提出平方积分图, 对方差公式进行推导演化成采用积分图和平方积分图优化的方差分类器作为前置分类器进行初步筛选, 对满足方差阈值条件的图像块进行非分级结构分类器处理, 并通过最近邻分类器来进一步提高分类精度, 从而实现了采用计算量由小到大的三个分类器进行级联的鲁棒精确目标检测, 通过实验及分析可得本文提出的方法在计算量和处理精度上均有明显优势, 并且对于尺度变化和旋转有很好的鲁棒性, 具有极高实用价值.

2 非树形结构分类器

2.1 随机森林

随机森林 (RF) [25] 是一种统计学习理论, 它利用步步为营重抽样方法从原始样本中抽取多个样本, 对每个样本进行决策树建模, 然后组合多棵决策树, 通过投票得出最终预测结果. 大量理论和实证研究证明 RF 具有很高的预测准确率, 对异常值和噪声有很好的容忍度, 不容易出现过拟合.

将目标检测问题看作分类问题, 则输入为待处理的图像序列以及选定的目标 (目标可通过在第一帧中点选也可事先给定), 通过分类器得到图像序

列中各个图像块的标记, 即输入图像中的某一区域是目标或者背景.

设 C 是一个代表类的随机变量, 则其取值为 0 或 1, 代表背景或目标, $f_j, j = 1, \dots, N$ 是待分类的图像块上计算得到的特征集, 可以利用后验概率 $P(C = c_i | f_1, f_2, \dots, f_N)$ 实现对特征集所表示的目标进行分类, 那么我们寻找的是

$$\hat{c}_i = \arg \max_{c_i} P(C = c_i | f_1, f_2, \dots, f_N), \quad (1)$$

这里, $c_i = 0, 1$, 由贝叶斯公式可将 (1) 式写为

$$\begin{aligned} & P(C = c_i | f_1, f_2, \dots, f_N) \\ &= \frac{P(f_1, f_2, \dots, f_N | C = c_i) P(C = c_i)}{P(f_1, f_2, \dots, f_N)}. \end{aligned} \quad (2)$$

假设一个统一的先验概率 $P(C)$, 上式中分母是一个不依赖于类的尺度因子, 则分类问题简化为寻找

$$\hat{c}_i = \arg \max_{c_i} P(f_1, f_2, \dots, f_N | C = c_i). \quad (3)$$

当 N 非常大 (如 $N = 300$) 时方程 (3) 中联合概率的完整表达是不可行的, 因为每个类都需要大概 2^N 次估算 [17]. 因此本文中采用一种非分级结构的分类器, 该分类器采用不同于树状的非分级结构不需要计算量如此庞大的联合概率.

2.2 非树形结构分类器

随机森林求分类器时, 计算量非常大, 若假定各特征独立, (3) 式可简化为

$$\begin{aligned} & P(f_1, f_2, \dots, f_N | C = c_i) \\ &= \prod_{j=1}^N P(f_j | C = c_i). \end{aligned} \quad (4)$$

虽然假设他们相互独立, 会使问题简化为各特征概率相乘, 但这种方法完全忽略特征间的依赖性, 而对于图像特征, 特征间的依赖关系与所选择的特征有关.

为计算复杂度低且保证特征的有效性, 本文采用 1bitBP 特征 (1-bit Binary Pattern), 即图像块的左半块与右半块比较, 若左边大于右边, 那么特征值取为 1, 否则为 0, 如下所示:

$$\text{BP}^1(I) = \delta(S_{\text{left}} - S_{\text{right}}), \quad (5)$$

其中, S_{left} 表示图像块 $I(x, y)$ 中左侧半块的像素之和, 同理得 S_{right} ; $\delta(x)$ 为冲激函数.

1bitBP 特征可以看成是 2bitBP 特征 [26] 的简化, 反过来 2bitBP 特征可以理解两个 1bitBP 特征的一种特殊联合, 那么采用多个 1bitBP 特征联合, 联合的方式会更加灵活. 1bitBP 特征也可以理解为是一种特殊的 Haar 特征 [27], 即 Haar 特征中的 2-矩形特征. 从它与上面提到的经过实验证实有效性的特征的内在联系的分析, 可以预见该特征的有效性.

对于 1bitBP 特征, 特征间的依赖关系与特征间的位置有关, 我们假定当两个 1bitBP 特征的位置足够远时, 两个特征是相互独立的, 那么我们通过特征选取位置的远近可以将 N 个 1bitBP-

M 特征划分成 M 个大小为 $S = N/M$ 组, 令组内的特征点位置较近, 具有相关性, 而组间的特征距离较远而具有相互独立性, 那么后验概率 $P(f_1, f_2, \dots, f_N | C = c_i)$ 可表示为

$$P(f_1, f_2, \dots, f_N | C = c_i) = \prod_{k=1}^M P(F_k | C = c_i), \quad (6)$$

其中, $F_k = \{f_\sigma(k, 1), f_\sigma(k, 2), \dots, f_\sigma(k, s)\}$, $k = 1, \dots, M$, 代表第 k 特征组; $\sigma(k, j)$ 代表组内各特征索引. 图 1 为各组特征内的相对位置示意图.

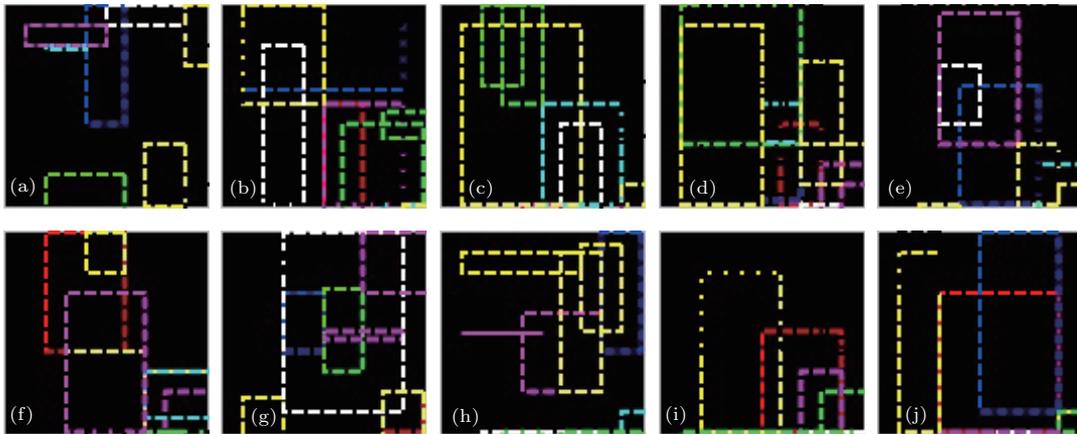


图 1 特征相对位置示意图 (a)–(j) 分别为 10 组特征的相对位置图

2.3 非树形结构分类器中后验概率的求解

我们通过建立一个特征中只有一些依赖性关系的模型来实现 Semi-Naive Bayesian approach (半无经验贝叶斯方法) [28]. 这种方法的可行性已经在文献 [29] 中得到证实.

为求解 $P(F_k | C = c_i)$ 我们引入一个事件 $\Theta(F_k)$, 这个事件指“ F_k 的经验概率是可靠的”, 那么我们可以把 $P(F_k | C = c_i)$ 解释为

$$\begin{aligned} P(F_k | C = c_i) &= P(F_k | C = c_i, \Theta(F_k)) P(\Theta(F_k)) \\ &+ P(F_k | C = c_i, \overline{\Theta(F_k)}) P(\overline{\Theta(F_k)}), \quad (7) \end{aligned}$$

其中, $P(F_k | C = c_i, \Theta(F_k))$ 是 $P(F_k | C = c_i)$ 的经验概率, $P(F_k | C = c_i, \overline{\Theta(F_k)})$ 是一个常数, 可是取 $1/H$, 我们对 $P(\Theta(F_k))$ 建模:

$$P(\Theta(F_k)) = \frac{\sum_i n_{k,i}}{\sum_i (n_{k,i} + u)}, \quad (8)$$

其中, $n_{k,i}$ 是特征 F_k 的训练样本属于 i 类的数量. 当训练集能真实代表类内真实变化, (8) 式随训练样本数增加而趋于 1, 则 $P(\overline{\Theta(F_k)})$ 趋于 0, (7) 式可简化为

$$P(F_k | C = c_i) = \frac{n_{k,i} + u}{\sum_k (n_{k,i} + u)}, \quad (9)$$

$\sum_k n_{k,i}$ 是所有属于 i 类的特征数. 事实上只要 $u > 1$ 并不影响结果, 所以取 $u = 1$. 这个因子可以解释为狄里克雷先验值 (Dirichlet prior), 因为类的条件概率以多项式建模 [30].

这种方法还非常灵活, 因为可以通过改变 fern 的数量和大小来使性能和效率相互制衡.

由 (9) 式可知, 对于只有两类 (正和负, 即目标和背景), 每个特征是正类的后验概率为

$$P(F_k | C = 1) = \frac{n_{k,1}}{n_{k,1} + n_{k,0}}, \quad (10)$$

其中, $n_{k,1}$ 是 F_k 的训练样本属于正类的数量, $n_{k,0}$ 是 F_k 的训练样本属于负类的数量.

3 基于级联分类器的目标检测

虽然采用非树形结构, 计算量大大减小, 数据之间依赖关系也减小了, 但是对于整幅图像的搜索, 其计算量仍然很大, 且将计算量浪费在无用区域本身也是对效率的一种损失, 因此, 本文采用级联分类器构架, 首先采用计算量小且计算复杂度低的分类器对整幅图像进行预处理, 从而去除大部分无关区域的图像块, 然后再采用本文提出的非树形结构的分类器进行处理, 最后采用最近邻分类器对误匹配进行剔除, 从而在减少计算量的同时保证了匹配检测的精度.

3.1 基于积分图的方差分类器

方差作为描述图像的纹理复杂度的一个普遍参数, 其对图像的纹理复杂程度有很好的区分能力, 其计算公式如下:

$$\begin{aligned} \sigma(X) &= \frac{1}{K} \sum_{i=0}^{K-1} (x_i - \mu)^2 \\ &= \frac{1}{K} \sum_{i=0}^{K-1} (x_i)^2 - \left(\frac{1}{K} \sum_{i=0}^{K-1} x_i \right)^2, \end{aligned} \quad (11)$$

其中, $\mu = \frac{1}{K} \sum_{i=0}^{K-1} x_i$ 为该图像区域的均值, K 为该图像区域的像素个数, 可使用积分图^[31]来计算可加速运算, 受积分图启发对于公式最右边求平方和也可利用类似的平方积分图得到.

图像中任意点 (x, y) 的积分图即图像中该点的左上部区域的所有像素点灰度值之和, 其用 $ii(x, y)$ 表示, 公式为 $ii(x, y) = \sum_{x' \leq x, y' \leq y} i(x', y')$, 其中 $i(x', y')$ 表示图像中点 (x', y') 的灰度.

$$ii2(x, y) = \sum_{x' \leq x, y' \leq y} i^2(x', y'). \quad (12)$$

则平方积分图可表示为(12)式, 求积分图和平方积分图, 只需遍历一次图像, 计算开销很小. 不管窗口的大小如何, 它的灰度值之和和灰度值平方和都可以用图像窗口四个角的积分图和平方积分图的加减运算得到, 对于图像中的任意位置的任意大小的图像块的方差均可通过对积分图和平方积分图的简单组合计算得到. 通过设定方差阈值则可以进行图像的预分类, 首先将纹理比较少的图像块去除, 减少后面的计算量.

3.2 最近邻分类器(NN)

为进一步提升分类器精度, 对于由非树形结构分类器处理得到的目标结果进行最近邻分类器的进一步筛选以剔除误匹配. 最近邻分类器采用相关系数作为相似性度量, 其公式如下:

$$\begin{aligned} \rho &= \frac{E\{[X - E(X)][Y - E(Y)]\}}{\sqrt{E[X - E(X)]^2 \cdot E[Y - E(Y)]^2}} \\ &= \left\{ N \sum_{i=0}^{N-1} x_i y_i - \sum_{i=0}^{N-1} x_i \sum_{i=0}^{N-1} y_i \right\} \\ &\quad \times \left[N \sum_{i=0}^{N-1} x_i^2 - \left(\sum_{i=0}^{N-1} x_i \right)^2 \right]^{-1/2} \\ &\quad \times \left[N \sum_{i=0}^{N-1} y_i^2 - \left(\sum_{i=0}^{N-1} y_i \right)^2 \right]^{-1/2}. \end{aligned} \quad (13)$$

因相关系数取值范围是 $[-1, 1]$, 所以将其进行归一化. 则 S 的取值范围为 $[0, 1]$,

$$S = \frac{1}{2} \rho + \frac{1}{2}. \quad (14)$$

3.3 本文算法的实现

本文提出一种基于级联分类器(cascade classifier, CC)的目标检测跟踪(Target Detection, TD, CCTD)算法, 该方法采用三级分类器级联的构架实现有效、精确的目标检测, 第一级分类器为采用积分图和平方积分图加速的方差分类器进行图像区域的初筛选, 第二级分类器采用本文提出的非树形结构的分类器进行目标检测, 第三级采用最近邻分类器使用归一化相关系数对第二级分类器得到的结果进行进一步误匹配的剔除, 从而实现用计算量小的分类器先剔除大部分非目标区域, 并用归一化相关进行误匹配剔除的有效、精确目标检测.

为了对于连续图像序列中的快速目标以及目标丢失后重新出现等复杂情况的适应性, 我们采用文献^[23]中的Sliding Window搜索策略, 实现对不同尺度目标的鲁棒性. 具体流程见图2.

在初始化非树形结构分类器时, 采用文献^[19]的包袋思想在目标周围选取五个图像区域作为目标一起进行分类器训练, 并受D-BRIEF^[24]的启发, 在初始化时进行对目标图像旋转、缩放建立完整的目标全视角数据库从而对于目标旋转、缩放、外观局部变化等有很好的鲁棒性, 并且这些工作都只是在初始化进行对于处理速度没有任何影响.

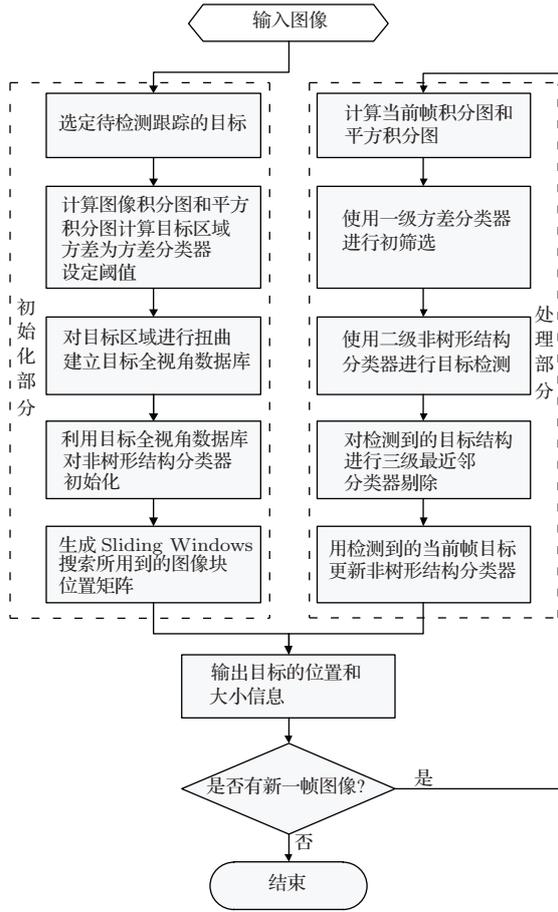


图2 本文算法处理流程图

4 实验结果与分析

实验部分是在CPU主频为2.8 GHz内存为2.0 G的PC机上进行的,共分两部分:第一部分是对于本文算法自身鲁棒性的评估实验,实现选取了一组序列,并选定第一帧中的熊猫作为实验对象,对各后续帧逐帧计算,图3所示为各帧检测到的目标区域,初始目标为一只熊猫的侧面,整个视频序列中熊猫一直处于运动状态从而发生了非刚体形变,并且在出现树等局部遮挡时检测跟踪稳定,熊猫在整个运动中,给画面的视角呈现了大角度的旋转和超平面旋转,并伴有不同程度的尺度缩放,并且在如371帧中目标与背景的对比度降低,同时有一定程度的模糊,本文算法均能稳定检测到目标,从实验结果可以看出,本文算法对于目标的旋转、缩放、模糊、局部形变等有一定的鲁棒性,能够适应复杂场景。

第二部分实验是对比试验,与文献[19]中的多实例学习(Multiple Instance Learning, MIL)方法进行了对比实验,这组序列中我们选中的目标是一辆白色的车(图4(a)所示),整个视频中出现了模糊、完全遮挡、部分遮挡、尺度缩放以及小角度的视角旋转,实验结果如图4,图中本文算法简称为

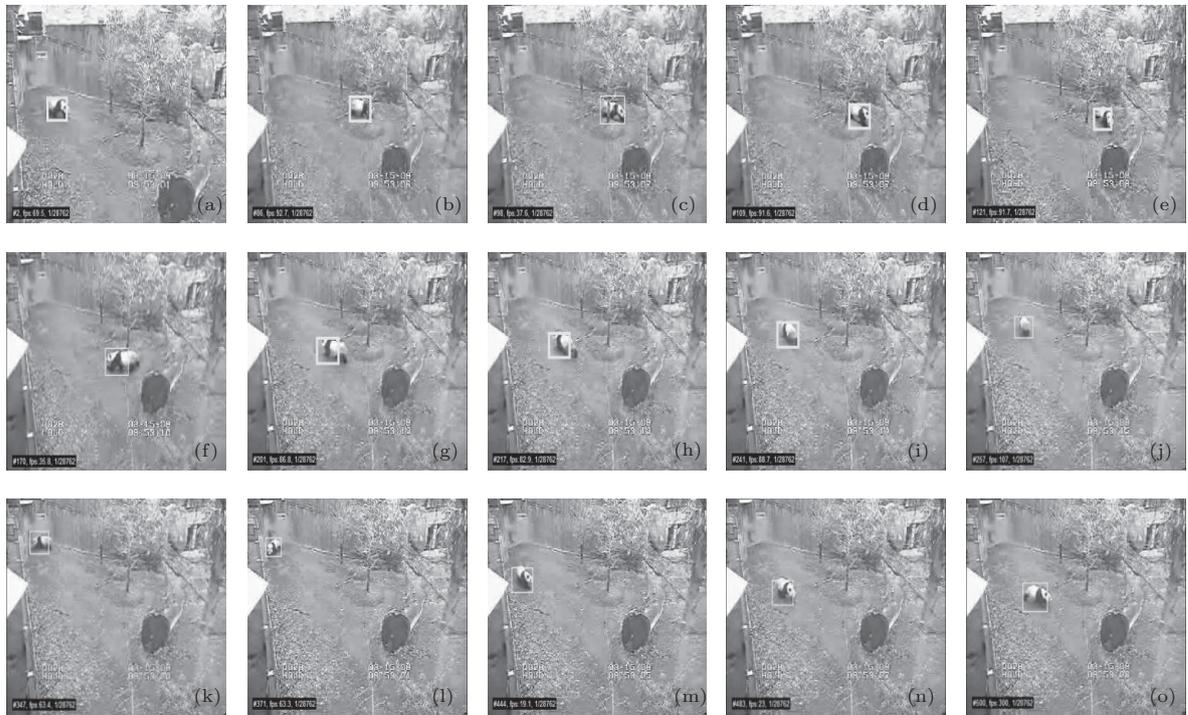


图3 实验一的部分实验结果 (a)—(o) 分别是第2, 86, 98, 109, 121, 170, 201, 217, 241, 257, 345, 371, 444, 483, 500 帧的实验结果

CCTD 用黑色实线框表示, 文献[19]的算法简称为MIL用黑色虚线表示. 图4(b)为第31帧目标被部分遮挡后, MIL 算法均出现明显偏移, 而本文算法未出现偏移, 图4(c)和(d)也说明了这种现象; 图4(f), (g), (h)中, 均是出现部分遮挡, 且遮挡均出现在目标中间部分, 本文算法跟踪良好, 而MIL均出现一定程度的偏移; 而到第249帧(图4(i)所示)由于前面出现的遮挡导致MIL跟踪丢失, 虽然后续又重新跟上目标(图4(j), (k), (l)所示)但仍然存在偏移; 图4(m)目标完全被遮挡, MIL发生跟踪错误; 当目标重新出现在图像中时(如图4(n)

所示), 本文算法迅速检测到了目标并且跟踪稳定, MIL丢失目标.

为说明本文算法的定位精度, 采用手动标记目标的真实位置并逐帧计算两种算法得到的跟踪结果与真实位置的重叠率 overlap, 其公式如下:

$$\text{overlap} = \frac{\sum_2 I}{\sum_1 I + \sum_3 I - \sum_2 I}, \quad (15)$$

式中 $\sum_1 I$ 和 $\sum_3 I$ 分别为图像块1和图像块3的像素和, $\sum_2 I$ 为图像块1和图像块3的重叠区域图像块2的像素和, 如图5示意图所示.

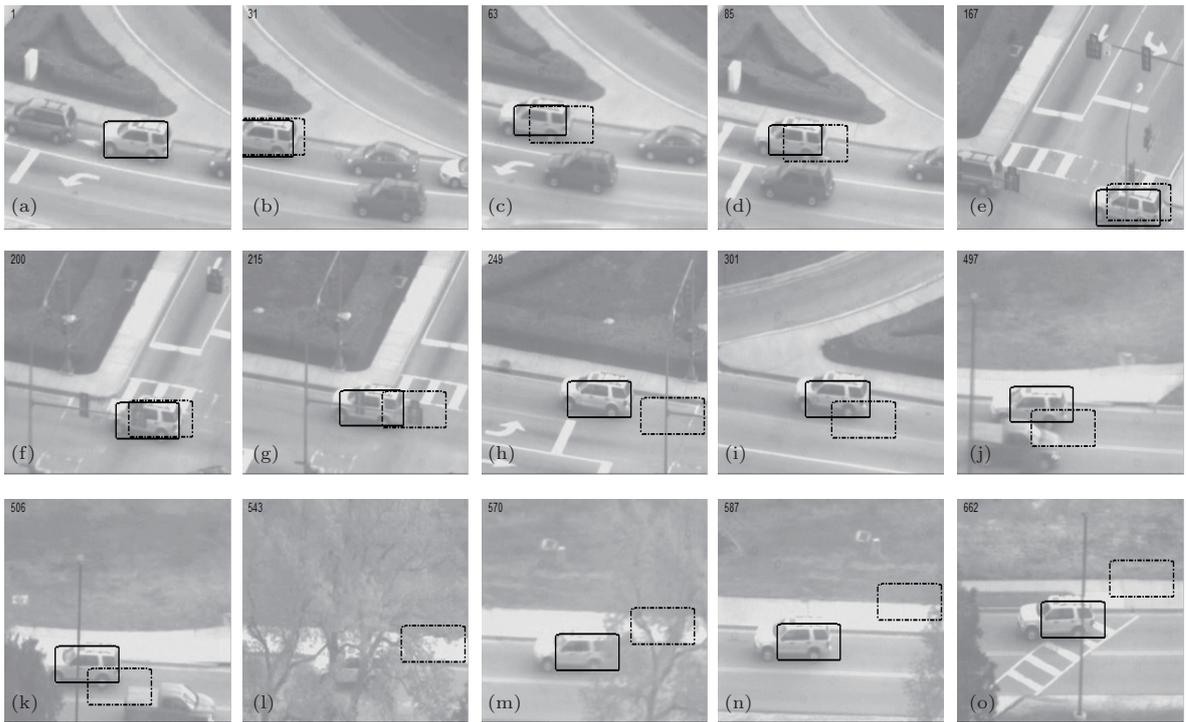


图4 实验二的部分实验结果 (a)—(o)分别是第1, 31, 63, 85, 167, 200, 215, 249, 301, 497, 506, 543, 570, 587, 662帧的实验结果

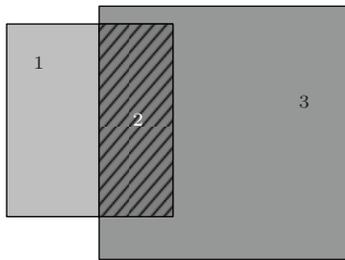


图5 重叠率示意图

图6为实验二中本文算法得到的跟踪结果与真实位置的重叠率曲线(黑色实线)与文献[19]中的方法得到的跟踪结果与真实位置重叠率曲线(黑

色虚线)对比图, 从图中可以看出本文算法(多处于图中的上部)对于定位精度明显高于MIL算法(多处于图中下部).

第三部分对比实验为某摩托车拉力赛的视频录像, 与当前比较流行、效果较好的 Online Boost [17], Semi-Boost [18], Beyond Semi-Boost [32], MIL [19] 以及 coGD [33] 算法进行对比, 图7中分别为青色、蓝色、黄色、黑色和粉色, 本文算法为绿色. 每帧大小为 470×310 , 共1000帧, 目标为一个赛车手(大小为 25×36), 视频较长, 可体现出长期跟踪, 中间有全部阻塞, 对本文算法的检测能力有了很好的测试, 目标外观变化多样, 对鲁棒性能很高要求.

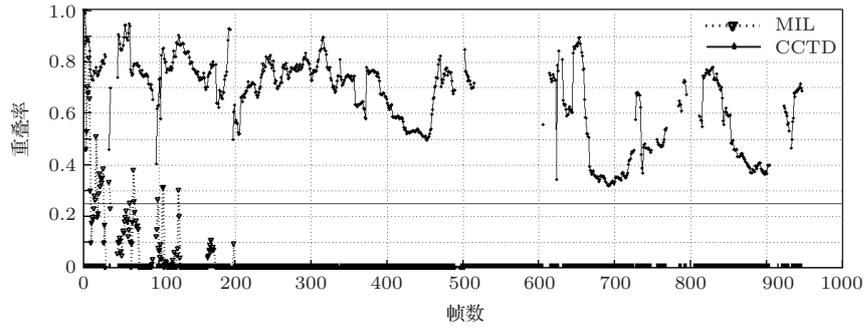


图6 重叠率曲线图

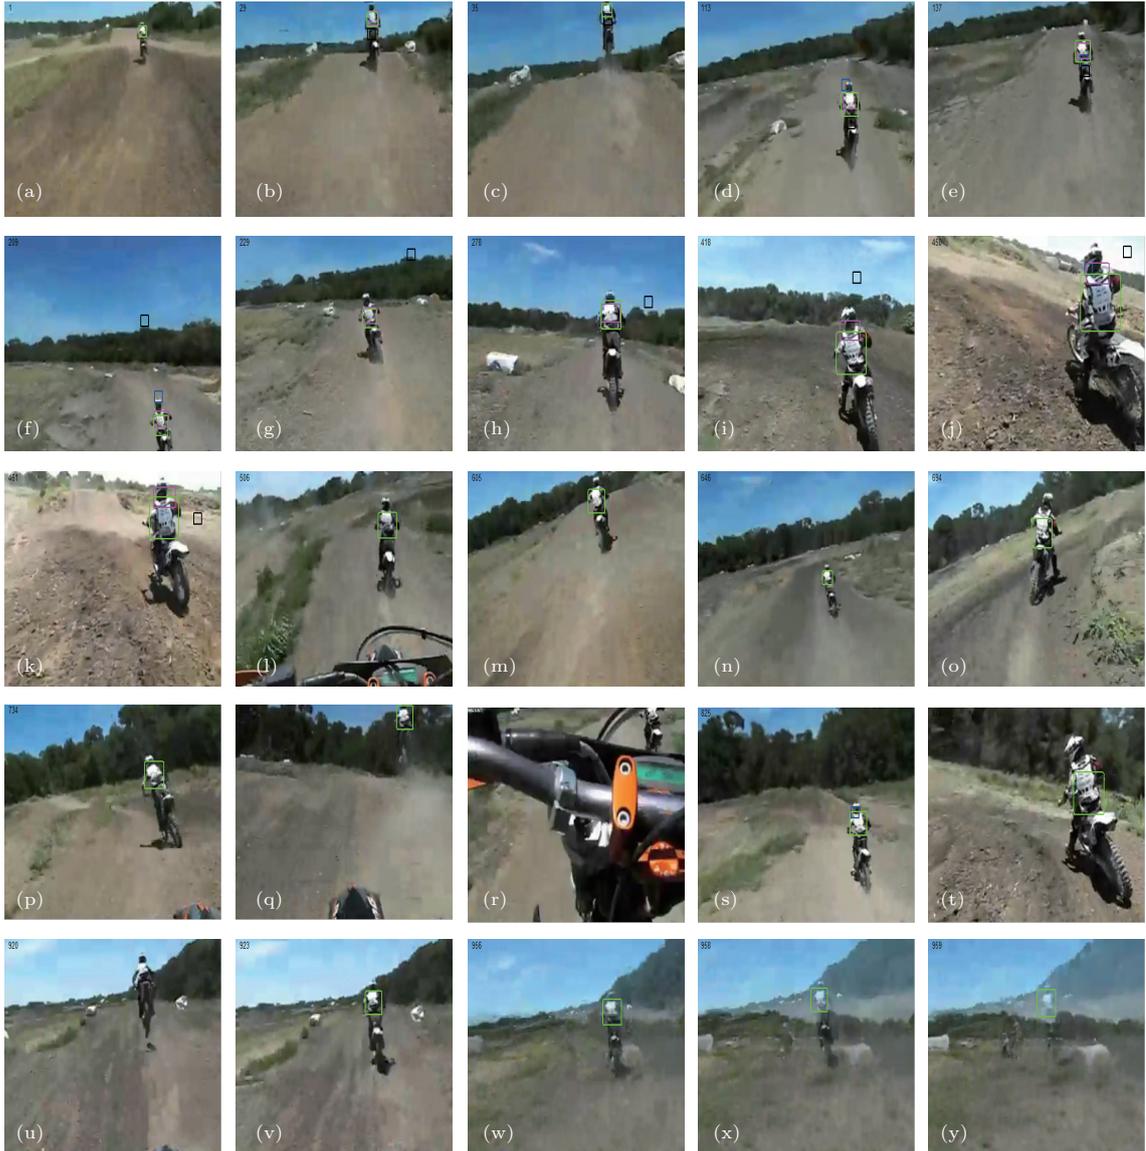


图7 实验三部分实验结果 (a)—(y) 分别是 1, 29, 35, 113, 137, 209, 229, 278, 418, 450, 461, 506, 605, 646, 694, 734, 788, 797, 825, 874, 920, 923, 956, 958, 959 帧的实验结果

从实验结果来看, 对于视频中的开始一段时间中出现的尺度变化(如图7(b), (c))各算法均有较好的效果, 经过一段时间的快速运动到113帧(如图7(d))时 Beyond Semi-Boost 已经丢失, 而 Semi-

Boost 和 MIL 算法也出现了明显偏移; 到229帧(如图7(g))尺度变大且出现旋转时仅有本文算法与 coGD 算法保持正确的跟踪状态; 到418帧(如图7(i))目标尺度变化非常大并且出现旋转和局部

形变 coGD 算法出现偏移和尺度计算错误, 本文算法能够很好地检测出目标; 当到 506 帧(如图 7(m)) 后仅有本文算法有检测结果, 且对尺度变化、旋转、局部形变、背景色度变化较大时(如图 7(n), (o), (p), (q), (s), (t)) 均有较好的检测结果, 到 920 帧时

(图 7(u)) 本文算法也出现了漏检现象, 由于目标的向上超平面旋转导致的; 到 923 帧(图 7(v)), 目标对比度增大时检测稳定; 后续的图 7(w), (x), (y) 目标出现了不同程度的模糊, 本文算法检测稳定, 其他算法均无检测结果输出。

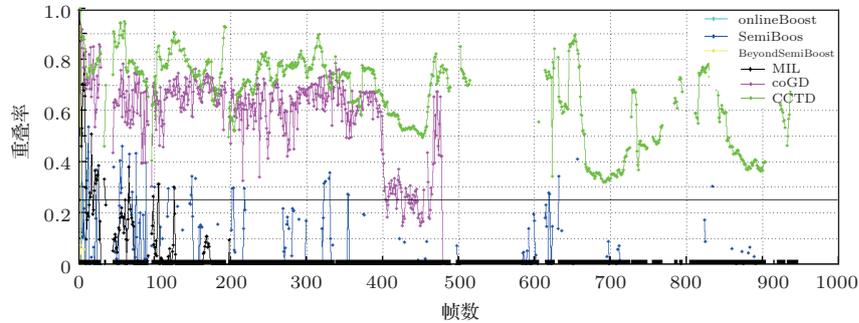


图 8 重叠率曲线图

图 8 为第三部分实验的检测区域与真实位置的重叠率曲线图, 可见本文算法的检测精度由于其他对比算法。

5 结 论

本文对复杂背景下目标检测的级联分类器算法进行了研究, 提出一种非树形结构的分类器并从理论上推导出其实现公式, 将 1bitBP 特征应用到分类器中, 同时采用计算量由小到大的三个分类器进行级联从而实现鲁棒精确的目标检测, 从实验结果来看, 本文算法能够对目标的尺度变化、旋转、部分遮挡、形变、模糊、背景变化等复杂情况有较好鲁棒性, 并且检测精度相对较高, 有较高的应用价值。

参考文献

- [1] Li T W, Shi A G, He S H 2009 *Acta Phys. Sin.* **58** 794 (in Chinese) [李天伟, 石爱国, 何四华 2009 物理学报 **58** 794]
- [2] Guo G R, Wang H Q, Jiang B 2006 *Acta Phys. Sin.* **55** 3985
- [3] Wang M W, Zhai H C, Gao L J 2009 *Acta Phys. Sin.* **58** 1662 (in Chinese) [王明伟, 翟宏琛, 高丽娟 2009 物理学报 **58** 1662]
- [4] Zhang J S, Zhang Z T 2010 *Chin. Phys. B* **19** 104601
- [5] Sun J F, Wang Q, Wang L 2010 *Chi. Phys. B* **19** 104203
- [6] CHEN G Y, GUO Z X, ZHANG C P 2003 *Chinese Phys. Lett.* **20** 2161
- [7] Yan J, Wu M Y 2012 *Opt. Precision Eng.* **20** 439 (in Chinese) [颜佳, 吴敏渊 2012 光学精密工程 **20** 439]
- [8] Zhu Q P, Yan J, Zhang H 2013 *Opt. Precision Eng.* **21** 437 (in Chinese) [朱秋平, 颜佳, 张虎 2013 光学精密工程 **21** 437]
- [9] Gong J L, He X, Wei Z H 2012 *Opt. Precision Eng.* **20** 413 (in Chinese) [龚俊亮, 何昕, 魏仲慧 2012 光学精密工程 **20** 413]
- [10] Shi J, Tomasi C 1994 *Conf. on Computer Vision and Pattern Recognition*, 1994
- [11] Lowe D G 2004 *International Journal of Computer Vision* **60** 91
- [12] Ross D, Lim J, Lin R S, Yang M H 2008 *Int J Comput Vis.* **77** 125
- [13] Ma Y, Lv Q B, Liu Y Y, Qian L L, Pei L L 2013 *Acta Phys. Sin.* **62** 204202 (in Chinese) [马原, 吕群波, 刘扬阳, 钱路路, 裴琳琳 2013 物理学报 **62** 204202]
- [14] Duarte M F, Baraniuk R G 2012 *IEEE Trans. Image Proc.* **21** 494
- [15] Shi W J, Li J 2012 *Opt. Precision Eng.* **20** 2095 (in Chinese) [石文轩, 李婕 2012 光学精密工程 **20** 2095]
- [16] Chen T, Li Z W, Wang J L, Wang B, Guo S 2012 *Opt. Precision Eng.* **20** 2523 (in Chinese) [陈涛, 李正炜, 王建立, 王斌, 郭爽 2012 光学精密工程 **20** 2523]
- [17] Lepetit V, Fua P 2006 *IEEE Trans. Pattern Analysis and Machine Intelligence*, **28** 1465
- [18] Grabner H, Leistner C, Bischof H 2008 *European Conf. on Computer Vision*
- [19] Babenko B, Yang M-H, Belongie S 2009 *IEEE Conf. on Computer Vision and Pattern Recognition*, Washington, DC 2009 p983
- [20] Viola P, Platt J, Zhang C 2005 *Neural Information Processing Systems*, 2005
- [21] Saffari A, Leistner C, Santner J 2009 *IEEE 12th International Conf. on Computer Vision Workshops* Washington DC 2009 p1393
- [22] Leistner C, Saffari A, Bischof H 2010 *20th International Conf. on Pattern Recognition*, Washington DC 2010 p3545

- [23] Viola P, Jones M, Snow D 2005 *International Journal of Computer Vision* **63** 153
- [24] Tomasz T, Vincent L 2012 *European Conf. on Computer Vision (ECCV)* 2012
- [25] Breiman L 2001 *Machine Learning* **45** 5
- [26] Kalal Z, Matas J, Mikolajczyk K 2010 *Conf. on Computer Vision and Pattern Recognition*, 2010
- [27] Viola P, Jones M 2001 *Conf. on Computer Vision and Pattern Recognition*, **2001** p511
- [28] Zheng F, Webb G 2005 *the Fourth Australasian DataMining Conference (AusDM05)*, Sydney, 2005 p141
- [29] Hoiem D, Sukthankar R, Schneiderman H, Huston L 2004 *Conf. on Computer Vision and Pattern Recognition*, 2004, 02 p490
- [30] Amit Y, Geman D 1997 *Neural Computation*, **9** 7
- [31] Bay H, Ess A, Tuytelaars T 2008 *Computer Vision and Image Understanding* **10** 346
- [32] Stalder S, Grabner H, Gool L V 2009 *IEEE 12th International Conf. on Computer Vision Workshops (ICCV)* 2009
- [33] Yu Q, Dinh T B, Medioni G 2008 *European Conf. on Computer Vision*. 2008

Study on the cascade classifier in target detection under complex background*

Gao Wen^{1)2)†} Tang Yang¹⁾ Zhu Ming¹⁾²⁾

1) (Changchun Institute of Optics, Fine Mechanics and Physics, Chinese Academy of Sciences, Changchun 130033, China)

2) (Key Laboratory of Airborne Optical Imaging and Measurement, Chinese Academy of Sciences, Changchun 130033, China)

(Received 3 December 2013; revised manuscript received 23 December 2013)

Abstract

Method of target detection and tracking is one of the hot topics in image processing and computer vision field, which is significant not only in military such as imaging guidance and military target tracking, but also for civil use such as security and monitoring and the intelligent man-machine interaction. Treating the feature matching problem as a more general equinoctial classification question, can turn the intractable high-dimensional problem to a classification problem and deplete computer complexity. This method is based on the law of large numbers and Bayes rule. In this paper we propose a non-hierarchy structure classifier, for which the equation for calculation is theoretically derived, and apply 1bitBP feature to the classifier; and for further reducing the amount of calculation, we use integral image and square integral image to variance classifier as preprocessor, and then use non-hierarchy classifier to handle the patches which meet the variance demand and use the nearest neighbor to further improve the accuracy, and finally realize target detection and tracking based on cascade classifier. Our experimental results show that the method proposed is far superior in calculation amount and processing precision, and is robust to scale changing and rotation, so the method proposed in this paper is of high practical value.

Keywords: target tracking, target detection, ran tree, classification

PACS: 42.30.Va, 42.30.Tz, 07.05.Pj, 02.50.-r

DOI: 10.7498/aps.63.094204

* Project supported by the Key Laboratory of Airborne Optical Imaging and Measurement, Chinese Academy of Sciences (Grant No. Y2HC1SR121).

† Corresponding author. E-mail: cwenzi@126.com