

## 尺度自适应特征压缩跟踪\*

张路平, 韩建涛, 李 飏, 王鲁平

(国防科技大学 电子科学与工程学院, 湖南 长沙 410073)

**摘要:**为了对复杂环境中的目标进行长时间精确跟踪,提出一种尺度自适应特征压缩跟踪算法。通过结构约束性采样,获取不同位置不同尺度的扫描窗,离线计算不同尺度下的稀疏随机感知矩阵。在线跟踪时利用这些矩阵感知对应尺度的图像采样块,实现特征降维,提高运算速度。利用朴素贝叶斯分类器对降维特征进行判决,在线学习更新分类器参数,找出具有最高分类得分的采样块及其尺度作为新的跟踪结果,实现跟踪位置及尺度的自适应更新。实验结果表明,该算法能适应目标的基本姿态变化及尺度缩放,不依赖于目标初始跟踪区域尺度选取,跟踪结果具有较强的鲁棒性。

**关键词:**特征压缩跟踪;尺度自适应;结构约束性采样;稀疏随机感知矩阵;朴素贝叶斯分类器

**中图分类号:**TP311 **文献标志码:**A **文章编号:**1001-2486(2013)05-0146-06

## The scale adaptive feature compressed tracking

ZHANG Luping, HAN Jiantao, LI Biao, WANG Luping

(College of Electronic Science and Engineering, National University of Defense Technology, Changsha 410073, China)

**Abstract:** In order to track target accurately during a long term in complicated environment, an adaptive scale feature compressed tracking algorithm is presented. A number of scanning windows with different scales and positions were obtained by construction constraint sampling. To reduce the feature dimension and improve the processing speed, the sparse random perceived matrices of different scales which can be easily computed offline were adopted to extract the features of different sampling image patches with relevant scales online. The sampling patch having a maximal classification score was regarded as the new tracking result by classifying the compressing feature via a naive bayes classifier and updating the parameters through online learning, which can realize the adaptive update of tracking location and scales. Experimental results show that the algorithm can adapt itself to the basic attitude and scale change, which is robust and does not depend on the scale selection of the initial tracking area.

**Key words:** feature compressed tracking; scale adaptive; structural constraint sampling; the sparse random perceived matrix; naive bayes classifier

目标跟踪是计算机视觉领域的一个重要研究方向,在视频监控、智能机器人定位与导航、人机交互、军事应用、异常行为分析等方面有着广泛的应用。根据跟踪时使用的信息类别,将跟踪分为基于目标表示的跟踪和基于目标定位的跟踪,前者主要包括模型匹配法、特征匹配法、分割法、基于检测的跟踪算法。后者将跟踪问题转换为在贝叶斯理论框架下,已知目标状态先验概率不断求解最大后验概率的过程,包括 Meanshift、粒子滤波及其改进算法。由于目标自身状态及周围环境的改变,对目标进行长时间精确跟踪面临诸多挑战,如目标姿态变化、光照变化、目标遮挡、帧丢失等。

近年来一种基于在线学习的目标跟踪方法受到了广泛关注,它通过建立在线更新分类器实现目标跟踪,其关键在于将序列图像中的前景目标

从背景中分割出来,将跟踪视为一种特殊的二元分类问题。文献[1]提出了一种协同跟踪方法,运用两个独立的特征来训练支持向量机分类器,但是当目标姿态变化较大时会导致跟踪失败。文献[2]利用一种增长的子空间模型来适应目标外观的变化。文献[3]利用稀疏矩阵对目标进行处理,通过组合稀疏线性特征对目标建模,但复杂的计算限制它在实时系统中的应用。文献[4-6]利用一个正采样及少量的负采样来更新分类器,但分类器易受噪声影响,导致跟踪漂移。文献[7-9]采用在线半监督学习方法对样本进行标记训练,在一定程度上避免了漂移发生。文献[10]提出一种实时压缩跟踪方法,它利用随机感知矩阵对图像特征进行降维,从而提高运算速度,但跟踪过程中尺度无法随目标尺度自适应改变,

\* 收稿日期:2013-03-01

基金项目:国家部委资助项目;国家863计划资助项目

作者简介:张路平(1985—),男,云南曲靖人,博士研究生,E-mail:zhangluping-002@163.com;

李飏(通信作者),男,研究员,博士,博士生导师,E-mail:Libiao\_cn@sina.com

容易导致跟踪失败,而且跟踪精度在一定程度上依赖于初始目标区域及搜索半径大小的选取。

为了在保持跟踪实时性的同时提高其鲁棒性,本文提出一种尺度自适应特征压缩跟踪算法。首先利用多尺度扫描窗口对目标周围不同区域进行正负采样,获取仿射图像块,建立目标结构约束集。利用满足压缩感知 RIP<sup>[11]</sup> (Restricted Isometry Property) 条件的随机感知矩阵对采样图像进行降维,用降维特征训练朴素贝叶斯分类器并进行目标检测。通过在线学习目标的各种形态变化,更新分类器参数。

## 1 目标结构约束性采样

为了处理尺度问题,文献[10]用一组矩形滤波器与图像采样块进行卷积,获取不同尺度下的特征,然而在跟踪过程中,该滤波器组的最大尺度始终保持为初始选定尺度,跟踪过程中若目标变小,则存在尺度与之相对应的滤波器,提取的特征能反映目标的尺度变化;若目标尺度超过初始选定区域大小或存在较大形变时,对应的矩形滤波器只能提取部分目标特征,特别是在目标自身灰度分布相近或目标边界与周围背景灰度分布差异不大时,就容易引起跟踪漂移,主要原因是最大矩形滤波器始终保持一个固定尺度,无法适应更大的尺度变化。为了自适应产生与变化目标相对应的矩形滤波器,本文根据视频图像尺寸及初始选定目标区域大小,产生一序列扫描窗口,建立目标结构约束集。扫描窗口应尽量包含目标状态可能变化的所有尺寸和位置。为了平衡跟踪精度及速度,扫描窗口不能取得太密集。通过在线学习寻找当前帧中与变化目标最相符的扫描区域。将人工选定的待跟踪目标用初始矩形框表示为  $B_0 = \{x, y, w, h\}$ , 其中  $(x, y)$  为矩形框左上角坐标,  $w, h$  分别为矩形框的宽度及高度。通过对初始矩形框进行各种尺度缩放、平移变换,产生一序列扫描窗口。扫描窗口参数设置如下:窗口的尺度缩放系数为 1.2,水平方向的步长为宽度的 10%,垂直方向的步长为高度的 10%,最小扫描窗口大小为 40 个像素。对于一幅  $240 * 320$  大小的图像,这组参数大概产生 50K 的扫描窗,具体数量取决于图像大小及初始矩形框的纵横比。

由于扫描窗口比较多,同一区域可能同时被多个扫描窗包含,用重叠度来表征任意两个扫描窗的空间相似性,其定义如下:

$$\text{overlap}(B_A, B_B) = \frac{B_A \cap B_B}{B_A \cup B_B - B_A \cap B_B} \quad (1)$$

其中  $B_A \cap B_B, B_A \cup B_B$  分别表示扫描窗  $B_A$  与  $B_B$  交集与并集。

为了将目标从背景中分离出来,提高目标判别的精度,采用正结构及负结构来约束正负图像采样块数量。正结构采样块主要是紧邻被跟踪目标运动轨迹的区域,负结构采样块为远离轨迹的背景区域。初始正样本为与选定目标窗口重叠度较高的区域,负样本为远离选定目标区域且方差大于正样本方差 1/4 的扫描区域。

## 2 随机感知矩阵

文献[12-13]指出:如果信号可以被压缩,例如自然图像或者声音信号,那么就能利用少量的随机线性组合测量方法保持信号大部分显著性信息,并能利用这些信息最大限度地恢复原始信号。为了降低计算量,需寻找一个满足 RIP 条件的稀疏测量矩阵对采样图像特征空间做投影,得到一个低维压缩子空间,该压缩子空间可以较好地保留高维图像特征空间的信息。利用稀疏测量矩阵提取目标和背景特征,将它们作为在线学习、更新分类器的正样本和负样本特征。

某一特定尺度下的随机感知矩阵证明  $R \in \mathcal{R}^{n * m}$ , 可将一个高维图像空间的  $x \in \mathcal{R}^m$  变换为低维空间中的  $v \in \mathcal{R}^n$ , 即

$$v = Rx \quad (2)$$

其中  $n \ll m$ , 理想情况下低维特征  $v$  可以完全保留高维特征  $x$  的信息,或者说保持原始空间中各样本的距离关系。Johnson-Lindenstrauss<sup>[14]</sup> 推论表明:随机选择一个适当的高维子空间,原始空间两点的距离投影到这个子空间,能以较高的概率保持这种距离关系。Baraniuk<sup>[15]</sup> 证明满足 Johnson-Lindenstrauss 推论的随机感知矩阵同样满足压缩感知理论中的 RIP 条件。如果  $x$  是可压缩的(或者说是稀疏的),当随机感知矩阵  $R$  满足 Johnson-Lindenstrauss 推论,就可以通过误差最小化从  $v$  中以较高概率恢复  $x$ 。

## 3 目标特征压缩

一个典型的满足 RIP 条件的测量矩阵是随机高斯矩阵<sup>[14]</sup>  $R \in \mathcal{R}^{n * m}$ , 其矩阵元素  $r_{ij}$  满足  $N(0, 1)$  分布,定义如下:

$$r_{ij} = \sqrt{s}^* \begin{cases} 1, & p_d = \frac{1}{2s} \\ 0, & p_d = 1 - \frac{1}{s} \\ -1, & p_d = \frac{1}{2s} \end{cases} \quad (3)$$

Achlioptas 证明当  $s = 2$  或  $s = 3$ , 上述矩阵满足 Johnson-Lindenstrauss 推论。该矩阵元素可通过一个均匀随机数发生器产生, 而且当  $s = 3$  时, 这个矩阵非常稀疏, 计算量将会减少  $2/3$ , 而且只需存储  $\mathbf{R}$  中的非零元素, 所需存储空间很小。

用随机测量矩阵  $\mathbf{R}$  中某一行中的一个非零元素去感知  $\mathbf{x}$  中的一个元素, 等价于用一个方形窗口滤波器和输入图像某一固定位置的灰度值进行卷积<sup>[10]</sup>。通过结构约束性采样, 得到不同尺度下的图像采样块。为了增强某一特定尺度  $w * h$  下采样块特征的可分性、适应性及多样性, 将该尺度下的样本  $z \in \mathcal{R}^{w * h}$ , 与一系列多尺度的矩形滤波器  $\{h_{1,1}, h_{1,2}, \dots, h_{w,h}\}$  进行卷积, 每一种尺度下的矩形滤波器定义如下:

$$h_{p,q}(x, y) = \begin{cases} 1, & x_i \leq x \leq x_i + p \wedge y_i \leq y \leq y_i + q \\ 0, & \text{otherwise} \end{cases} \quad (4)$$

其中  $(x_i, y_i)$  为矩形滤波器左上角坐标,  $p, q$  分别为该滤波器的宽度及高度,  $1 \leq p \leq w, 1 \leq q \leq h$ , (4) 式表明, 将图像采样块与某一尺度下的矩形滤波器进行卷积, 等价于计算该滤波器内部的图像特征。将经过矩形滤波后的图像矩阵扩展成一个列向量, 然后将各种尺度下的列向量连接成一个高维多尺度图像特征向量  $x \in \mathcal{R}^{H * 1}$ , 用对应尺度下的随机感知矩阵  $\mathbf{R} \in \mathcal{R}^{W * H}$ , 将  $\mathbf{x}$  投影到低维空间  $\mathbf{v}$ 。不同尺度下的随机感知矩阵只需在获取初始目标跟踪区域后计算一次便可得到, 且在跟踪过程中保持不变, 因此后续处理中可通过尺度索引方式获取特定尺度下的  $\mathbf{R}$ 。 $\mathbf{v}$  中的每一个元素  $v_i$  是不同尺度空间分布的线性组合。测量矩阵  $\mathbf{R}$  的系数有正有负, 压缩特征可以像广义 Haar-Like<sup>[8]</sup> 特征一样计算相关灰度差, 而 Haar-Like 特征又可用积分图像<sup>[16]</sup> 方法计算得到。利用稀疏测量矩阵对数目庞大的 Haar-Like 特征进行压缩, 稀疏感知理论确保压缩后的特征可以最大限度地保留原始图像块信息, 故可以直接对压缩域中的投影特征进行分类, 避免维数灾难。

#### 4 分类器构建及更新

对每一个采样样本  $z \in \mathcal{R}^m$ , 其低维特征为  $\mathbf{v} = (v_1, v_2, \dots, v_n)'$ ,  $\mathbf{v} \in \mathcal{R}^n, m \geq n, v$  中的每一个元素都是由一组 Haar-Like 特征线性组合而成。假定  $\mathbf{v}$  中的元素是相互独立, 构建朴素贝叶斯分类器<sup>[17]</sup> 对正负样本压缩特征进行分类:

$$\begin{aligned} H(\mathbf{v}) &= \log \frac{\prod_{i=1}^n p(y = 1 | v_i)}{\prod_{i=1}^n p(y = 0 | v_i)} \\ &= \log \frac{\prod_{i=1}^n p(v_i | y = 1) p(y = 1)}{\prod_{i=1}^n p(v_i | y = 0) p(y = 0)} \end{aligned} \quad (5)$$

$y = 1$  表示正样本,  $y = 0$  表示负样本, 假定两类样本的先验概率相等, 则 (5) 式可以化简为

$$H(\mathbf{v}) = \sum_{i=1}^n \log \frac{p(v_i | y = 1)}{p(v_i | y = 0)} \quad (6)$$

Diaconis 和 Freedman<sup>[18]</sup> 证明高维随机矢量的随机投影几乎都是高斯分布的。因此, 分类器  $H(\mathbf{v})$  中的条件概率  $p(v_i | y = 1)$  和  $p(v_i | y = 0)$  也是高斯分布, 用四个在线估计参数  $\{\mu_i^+, \sigma_i^+, \mu_i^-, \sigma_i^-\}$  来表征, 其中:

$$\begin{aligned} p(v_i | y = 1) &\sim N(\mu_i^+, \sigma_i^+) \\ p(v_i | y = 0) &\sim N(\mu_i^-, \sigma_i^-) \end{aligned} \quad (7)$$

通过最大似然估计对以上四个参数进行增量更新:

$$\begin{aligned} \mu_{i+} &= \lambda \mu_i^+ + (1 - \lambda) \mu_{i+} \mu_i^- = \lambda \mu_i^- + (1 - \lambda) \mu_{i-} \\ \sigma_{i+} &= \sqrt{\lambda (\sigma_i^+)^2 + (1 - \lambda) (\sigma_{i+})^2 + \lambda (1 - \lambda) (\mu_i^+ - \mu_{i+})^2} \\ \sigma_{i-} &= \sqrt{\lambda (\sigma_i^-)^2 + (1 - \lambda) (\sigma_{i-})^2 + \lambda (1 - \lambda) (\mu_i^- - \mu_{i-})^2} \end{aligned} \quad (8)$$

其中:

$$\begin{aligned} \mu_{i+} &= \frac{1}{N} \sum_{k=0}^{N-1} v_i(k), \quad \mu_{i-} = \frac{1}{M} \sum_{k=0}^{M-1} v_i(k), \\ \sigma_{i+} &= \sqrt{\frac{1}{N} \sum_{k=0}^{N-1} (v_i(k) - \mu_{i+})^2} \\ \sigma_{i-} &= \sqrt{\frac{1}{M} \sum_{k=0}^{M-1} (v_i(k) - \mu_{i-})^2} \end{aligned}$$

其中  $\lambda$  为学习因子,  $M, N$  分别为正、负样本采样数。

#### 5 尺度自适应特征压缩跟踪算法

本文主要针对刚性目标, 为了增强跟踪过程中对目标尺度及姿态变化的自适应性, 减少对初始矩形框大小的依赖, 同时又不降低跟踪的实时性, 在得到初始帧目标区域的基础上进行尺度缩放、平移变换, 获取一序列不同尺度、不同位置的扫描窗口, 并离线计算对应尺度下的稀疏随机感知矩阵  $\mathbf{R}$ 。跟踪算法如下:

(1) 设第  $k$  帧跟踪到的目标为  $\mathbf{B}_k = (x_k, y_k, w_k, h_k)$ , 其中  $(x_k, y_k)$ 、 $(w_k, h_k)$  分别为矩形框  $\mathbf{B}_k$  的左上角坐标、宽度及高度,  $\mathbf{B}_0$  为初始帧选定的

目标区域。

(2) 通过结构约束性采样获取第  $k + 1$  帧的不同位置、不同尺寸的图像采样集  $\mathbf{D}_{k+1} = (\mathbf{B}_{k+1} \parallel \text{overlap}(\mathbf{B}_{k+1}, \mathbf{B}_k) > \gamma)$ , 其中  $\gamma$  为重叠度门限。在得到每一个采样块的位置及尺度后, 通过尺度映射使用对应尺度的随机感知矩阵对该采样块进行特征提取(降维), 得到对应的特征向量  $\mathbf{v}$ , 使用朴素贝叶斯分类器  $H(\mathbf{v})$  对上述降维特征向量进行分类, 找到使分类得分最高的采样块作为当前帧跟踪到的目标  $\hat{\mathbf{B}}_{k+1}, \hat{\mathbf{B}}_{k+1} = \max_{\mathbf{v}_l \in \mathbf{VD}_{k+1}} \arg(H(\mathbf{v}_l))$ ,  $\mathbf{VD}_{k+1}$  为图像块采样集  $\mathbf{D}_{k+1}$  对应的降维特征向量集,  $\hat{\mathbf{B}}_{k+1}$  包含跟踪框的位置及大小。

(3) 利用结构约束性采样获取目标周围的正负样本集  $\mathbf{D}_{k+1}^+$  及  $\mathbf{D}_{k+1}^-$ :

$$\mathbf{D}_{k+1}^+ = (\mathbf{B}_{k+1} \parallel \text{overlap}(\mathbf{B}_{k+1}, \mathbf{B}_k) > \alpha)$$

$$\mathbf{D}_{k+1}^- = (\mathbf{B}_{k+1} \parallel \text{overlap}(\mathbf{B}_{k+1}, \mathbf{B}_k) < \beta)$$

其中:  $\beta < \gamma < \alpha$

(4) 利用样本集对应尺度的随机感知矩阵提取图像特征, 根据(8)式, 用这些特征更新分类器参数, 返回(2)。

## 6 实验结果分析

在 2GB 内存、2.8GHz 主频的电脑上利用 MATLAB 与 C 混合编程方式实现本文算法, 由于不同尺度下的随机感知矩阵可以离线计算得到, 不需实时计算, 在线跟踪处理速度可达 10f/s, 与 CT 法大致相同。

若跟踪框始终保持不变, 可能会引起跟踪漂移, 从而致使跟踪失败, 主要原因如下:

(1) 当运动目标尺度缩小或姿态变化时, 大量的背景区域将进入跟踪框内, 框内目标区域所占比例减少, 利用朴素贝叶斯分类器分类时, 背景部分的分类得分大于目标部分, 判决得到新的跟踪位置将偏向背景区域, 特别是当与目标边界相邻的背景区域的灰度分布与目标灰度分布相差不大时, 新的跟踪中心就会偏向背景区域, 导致跟踪失败。

(2) 当运动目标尺度变大, 目标自身灰度分布相似区域变大, 部分区域的灰度分布趋于一致, 以固定尺度对这些区域进行正采样时, 分类器对灰度分布相近的图像采样块的分能力趋于平均, 这将引起跟踪中心在目标相似区域来回移动, 目标越大, 跟踪框越小, 这种现象越明显。在控制系统中, 这种现象将会引起伺服系统控制发散, 使跟踪、控制回路无法闭环。

本文选取两组视频跟踪领域常用的测试序列:

David 与 Bike。David 序列有 471 帧图像, 其中伴随有目标姿态改变、尺度缩小及光照变化。Bike 序列有 77 帧图像, 序列中运动目标尺度逐渐变大。

采用两种度量方式来评价算法的跟踪性能: 面积比 (Area Ratio) 与中心定位误差 (Center Location Error)。

目标缩小时, 面积比定义为: 跟踪框内目标区域面积与跟踪框面积的比值。

目标放大时, 面积比定义为: 跟踪框内目标区域面积与真实目标面积的比值。

中心定位误差定义为: 跟踪中心与真实目标中心之间的欧式距离。为了减小随机性, 每组序列重复进行 10 次实验, 取 10 次实验的均值作为最终结果。

选用三种经典跟踪算法 CT<sup>[10]</sup>、FragTrack<sup>[19]</sup>、MILTrack<sup>[20]</sup> 与本文方法进行比较, 着重分析了本文方法与 CT 法的差异。分别从两组序列中选取几帧具有典型运动特征的跟踪图像来对算法进行分析。图 1 给出了 CT (Compressive Tracking) 法与本文方法的跟踪效果图, 矩形框表示跟踪结果,



(a) CT 法跟踪 David 序列



(b) 本文方法跟踪 Bike 序列



(c) CT 法跟踪 Bike 序列



(d) 本文方法跟踪 Bike 序列

图 1 两种方法跟踪结果

Fig. 1 Tracking results of above methods

框中的点代表跟踪中心。David 序列中第 8 帧及第 62 帧显示了当目标姿态及尺度变化不大时 CT 法及本文方法均能很好地跟上目标, 但是当目标姿态变化明显且伴随尺度缩小时, CT 法虽然能跟上目标, 但跟踪框内包含了许多背景部分, 致使跟

踪中心向背景区域偏移,而本文方法能自适应目标状态变化,跟踪中心始终在目标上,如第 174、199 帧所示。Bike 序列中目标尺度逐渐变大,CT 法跟踪框只包含目标部分区域,而本文方法跟踪框包含了整个目标。表 1 给出了四种方法得到的平均中心定位误差。虽然 Frag 方法能解决跟踪过程中的部分遮挡问题,但由于目标外观模型不更新,它不能适应目标姿态变化情形,故其中心定位误差最大,如表 1 所示,而利用本文方法得到的中心定位误差是四种方法中最小的。

表 1 平均中心定位误差(像素)

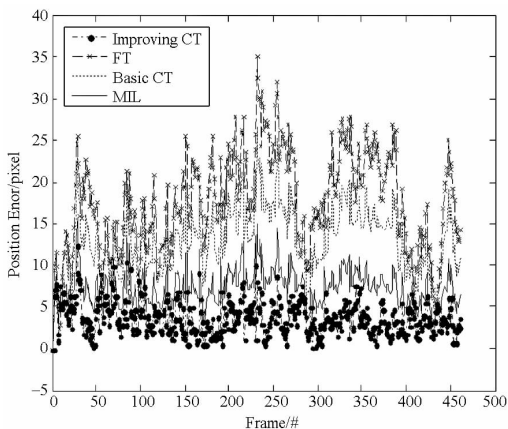
Tab. 1 Average center location errors (pixels)

Sequence	CT	MIL	Frag	Ours
David	13	7	18	4
Bike	11	6	16	2

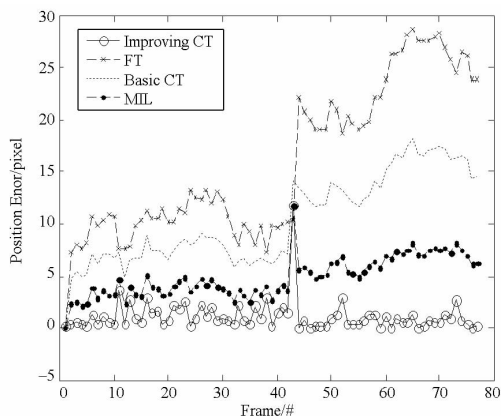
图 2 显示了四种方法得到的中心定位误差曲线。由于另外三种方法都不具备尺度自适应性,得到的跟踪中心与真实目标中心之间的误差开始较小,但随着目标姿态改变而逐渐变大。由于 MIL 将多个正负采样样本打包,对训练样本标签进行模糊化处理达到弱化监督效应的目的,故跟踪精度比单

采样本精度高,跟踪误差相对较小。由于本文方法具有良好的尺度自适应性,跟踪中心与真实目标中心之间的误差始终很小,不随目标姿态及尺度变化,中心定位误差小,跟踪精度高。

图 3 显示了选用不同尺度的初始跟踪框对跟踪结果的影响。在 David 序列中,目标先变小后变大,CT 法跟踪框始终保持不变,框中目标所占区域减少,面积比随目标尺度变小而减小。初始跟踪框越大,面积比越小,跟踪框越容易偏离目标,目标越容易丢失。在 Bike 序列中,目标逐渐变大,初始跟踪框越小,面积比越小,跟踪框越容易来回漂移,目标越容易丢失。因此,CT 法初始跟踪框的选取依赖于目标尺度具体变化,选取不当就容易造成目标丢失。但本文方法对于两组序列均能自适应目标尺度变化,初始时刻一旦选定目标区域,跟踪框就能随目标尺度变化而变化,不依赖于初始框尺度大小选择及目标尺度的具体变化,面积比保持一个较高的值(约为 0.9),如图 3 (c)、3(d)所示。由此说明,无论目标尺度怎样变化,跟踪框均能较好地捕获到真实目标,本文方法具有较强的鲁棒性。




(a) David 序列定位误差




(b) Bike 序列定位误差

图 2 中心定位误差


Fig. 2 The center location error




(a) CT 法 David 序列



(b) CT 法 Bike 序列



(c) 本文方法 David 序列



(d) 本文方法 Bike 序列

图3 不同尺寸下的面积比

Fig.3 The area ratio under different scales

## 7 结束语

本文提出的跟踪算法能准确跟踪目标并可自适应目标尺度变化。通过多扫描窗口采样,获取最佳匹配采样块及其尺度,减少对初始目标区域大小选择的依赖。利用离线计算的稀疏感知矩阵对采样图像块降维,提高处理速率。本文主要针对单目标进行自适应跟踪,对于多目标跟踪特别是多个相似目标的跟踪,将是本文未来的研究方向。

## 参考文献 (References)

- [1] Fang F, Brennan S, Zhao Q. Co-tracking using semi-supervised support vector machines [C]//Proceedings of IEEE Conference on Computer Vision. Rio de Janeiro, Brazil, 2007.
- [2] Ross D, Lim J, Lin R, et al. Incremental learning for robust visual tracking [J]. International Journal on Computer Vision, 2008, 77(1): 125 - 141.
- [3] Mei X, Ling H. Robust visual tracking and vehicle classification via sparse representation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2011, 33(4): 1619 - 1632.
- [4] Avidan S. Support vector tracking [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2004, 26(8): 1064 - 1072.
- [5] Collins R, Liu Y, Leordeanu M. Online selection of discriminative tracking features [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005, 27(10): 1631 - 1643.
- [6] Grabner H, Grabner M, Bischof H. Real-time tracking via online boosting [C]//Proceedings of British Machine Vision Conference, 2006: 47 - 56.
- [7] 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.
- [8] Babenko B, Yang M H. Robust object tracking with online multiple instance learning [J]. IEEE Transactions on Pattern

Analysis and Machine Intelligence, 2011, 33(2): 1619 - 1632.

- [9] Kalal Z, Matas J, Mikolajczyk K. P-N learning: bootstrapping binary classifier by structural constraints [C]//Proceedings of International Conference on Computer Vision and Pattern Recognition, 2010: 49 - 56.
- [10] Zhang K H, Zhang Lei, Ming-Hsuan Y. Real time compressive tracking [C]//Proceedings of European Conference on Computer Vision, Part III, 2012: 866 - 879.
- [11] Candes E, Tao T. Decoding by linear programming [J]. IEEE Trans. Inform. Theory, 2005, 51(3): 4203 - 4215.
- [12] Donoho D. Compressed sensing [J]. IEEE Trans. Inform. Theory, 2006, 52(8): 1289 - 1306.
- [13] Candes E, Tao T. Near optimal signal recovery from random projections and Universal encoding strategies [J]. IEEE Trans. Inform. Theory, 2006, 52(8): 5406 - 5425.
- [14] Achlioptas D. Database-friendly random projections; Johnson-Lindenstrauss with binary coins [J]. Comput. Syst. Sci, 2003, 66(6): 671 - 687.
- [15] Baraniuk R, Davenport M, Devore R. A simple proof of the restricted isometry property for random matrices [J]. Constructive Approximation, 2008, 28(7): 253 - 263.
- [16] Viola P, Jones M. Rapid object detection using a boosted cascade of simple features [C]//Proceedings of International Conference on Computer Vision and Pattern Recognition, 2001: 511 - 518.
- [17] Ng A, Jordan M. On discriminative vs generative classifier: a comparison of logistic regression naive bayes [C]//Proceedings of Neural Information Processing Systems, 2002: 841 - 848.
- [18] Diaconis P, Freedman D. Asymptotics of graphical projection pursuit [J]. Annals of Applied Statistics, 1984, 12(8): 228 - 235.
- [19] Adam A, Rivlin E. Robust fragments-based tracking using the integral histogram [C]//Proceedings of International Conference on Computer Vision and Pattern Recognition, 2006: 798 - 805.
- [20] Babenko B, Yang M H. Visual tracking with online multiple instance learning [C]//Proceedings of International Conference on Computer Vision and Pattern Recognition, 2009: 983 - 990.