

## 尺度补偿的相关核滤波器跟踪

张润东 张凤元

(北京化工大学信息科学与技术学院 北京 100029)

**摘要** 相关核滤波器跟踪是工程实际中非常实用的跟踪算法,它的算法简单,只需要在下一帧进行一个样本的密集采样就能对目标进行跟踪,但是对于有尺度变化的目标跟踪的适用性不足。采用了尺度补偿的相关核滤波器跟踪算法,对相关核滤波器跟踪进行了改进。首先使用了点跟踪补偿机制对相关核滤波器尺度和位移进行补偿;其次采用了压缩感知提取的特征建立模板对目标进行建模,在关键帧进行目标的重检测来防止尺度估计带来的跟踪误差。通过实验对提出的算法进行了标准视频库的测试,并在中心点误差和实际跟踪覆盖率两个指标上与原算法进行了对比分析。实验结果表明,提出的具有尺度补偿的跟踪算法提高了相关核滤波器跟踪在有尺度属性变化视频序列中的准确率和实用性。

**关键词** 目标跟踪,相关核滤波器,压缩感知,点跟踪,尺度估计

中国法分类号 TP391.4 文献标识码 A

### Kernelized Correlation Filters Tracking with Scale Compensation

ZHANG Run-dong ZHANG Feng-yuan

(College of Information Science and Technology, Beijing University of Chemical Technology, Beijing 100029, China)

**Abstract** Kernelized correlation filters is a very useful tracking algorithm in practice, whose algorithm is simple and requires only one dense sampling in the next frame for tracking, however the applicability is insufficient when tracking object with scale changes. In this paper, we used kernelized correlation filter tracking algorithm with scale compensation to improve the original algorithm. Firstly, we used point tracking compensation mechanism for this algorithm to compensate for scale changes and shift change. Secondly, we modeled the target with features extracted from compressed sensing and detected the tracking object in key frame for the sake of error in the scale estimation. The algorithm is tested in standard tracking library and compared with original tracking tracking algorithm in center error and the actual overlapped rate. The results show that the tracking algorithm with scale compensation in this paper improves accuracy and practicality when used in video with scale attributes.

**Keywords** Object tracking, Kernelised correlation filter, Compressive sensing, Point tracking, Scale estimation

视频目标跟踪需要在一个视频文件或者一组连续的图片序列中提取目标的特征,并在连续帧中正确地找到目标的位置,因此视频目标的过程包括特征提取、跟踪判决和模型更新 3 个过程。

文献[1,8]是对目标的颜色空间特征进行统计提取,前者依靠 meanshift 优化迭代寻找最优点,后者依靠高斯过程的随机采样搜索最符合目标颜色空间模型的目标位置。这种依靠统计的跟踪算法由于不能详细地描述跟踪的目标本身的特征,因此跟踪精度不高。

文献[2,7]通过提取 haar 特征,并进行 boosting 训练,在特征特征池中选择最有利于区分跟踪目标和背景环境的特征作为弱分类器,并通过弱分类器级联成强分类器,进行最优位置判决,这种类型的跟踪方法由于需要对跟踪的特征建立正负样本模型,在目标背景发生相似性干扰时容易产生跟踪漂移。

文献[9,10]使用机器学习中的 SVM 理论,以上一帧的跟踪结果为中心,进行采样特征提取,并使用以中心点为中心的高斯分布或者与跟踪目标覆盖率相关的因子作为训练标

签,最后放入 SVM 训练器,在判决下一帧目标位置时将 SVM 评估输入最高的搜索点作为目标移动的位置。

自相关滤波器作为一种利用提取特征进行线性映射滤波器算法,是最近几年发展起来的,其中经典的算法包括文献[4,11,12]中提出的算法。自相关滤波器优于 SVM 之处在于不必像基于 SVM 的算法那样进行稀疏采样,而采用了密集采样方法,在上一帧的跟踪结果的基础上只需进行一帧的采样,并对该采样样本进行圆周移位,通过线性映射判断当前帧目标移动的位置。

针对相关核滤波器跟踪没有考虑到尺度因素和突变因素的问题,提出了有尺度因子补偿的相关核滤波器跟踪,使得跟踪算法在实际应用中对跟踪具有尺度变化的物体有更好的实用性。

### 1 相关核滤波器跟踪算法

在以 SVM 机器学习的跟踪中,SVM 取跟踪目标附近的样本  $(x_1, y_1), \dots, (x_n, y_n)$  作为训练样本,训练的的目的是要使

下式的残差最小:

$$\min_{\omega, b} \sum_{i=1}^n L(y_i, f(x_i)) + \lambda \|\omega\|^2 \quad (1)$$

SVM 使用 SMO 训练程, 训练过程繁琐, 时间复杂度高。文献[13]说明如果  $L$  采用平方残差计算, SVM 具有相同效果的训练精度, 并且计算时间更短。文献[14]指出, 对于大多数的残差函数  $L$  (SVM 中的残差函数), 对于特征向量向高维空间映射的函数  $f(x)$  可以表示为:

$$f^*(x) = \sum_{i=1}^l c_i K(x, x_i) \quad (2)$$

此时 SVM 的控制误差项  $\lambda \|\omega\|^2$  可以化为  $c^T K c$ , 其中  $K$  是核函数, 代表  $x$  和  $x_i$  第  $i$  和第  $j$  维度的相似度。此时 SVM 最小残差目标函数可以化为:

$$\min_{c \in R^l} \frac{1}{l} \sum_{i=1}^l L(y_i, \sum_{j=1}^l c_j K(x_i, x_j)) + \lambda c^T K c \quad (3)$$

如果参数函数  $L$  使用平方差残差表示  $L = (Y - f(x))^2$ , 则残差可表示为:

$$\min F(c) = \min \frac{1}{2l} \sum_{i=1}^l (y_i - Kc)^T (y_i - Kc) + \frac{\lambda}{2} c^T K c \quad (4)$$

通过对上式两边求  $c$  的导数, 即求出了式(1)所示的核函数中的参数。

$$(K + \lambda l I)c = y \quad (5)$$

文献[12]提出了稠密采样, 基本思想为: 设有一个一维向量  $x$ , 维度为  $n$ , 定义

$$x_i = P^i x, \forall i = 0, \dots, n-1 \quad (6)$$

其中  $P$  是形如下式的矩阵:

$$P(u) = \begin{bmatrix} u_0 & u_1 & u_2 & \dots & u_{n-1} \\ u_1 & u_2 & u_3 & \dots & u_0 \\ \vdots & \vdots & \vdots & & \vdots \\ u_{n-1} & u_0 & u_1 & \dots & u_{n-2} \end{bmatrix} \quad (7)$$

当  $u_0 = 1, u_{i \neq 0} = 0$  时, 式(6)相当于对向量  $x$  做了移位运算, 可以看作在对矩形区间采样过程中矩形框从左向右移动。由式(3)所示, 对于单样本的 KRLS 训练结果可以表示为:

$$y' = \sum_j \alpha_j k(x_i, z) \quad (8)$$

其中,  $k$  即为式(5)中训练的 KRLS 系数。式(8)结果越大, 相当于 SVM 相应越大, 候选样本越接近于跟踪目标。

$x_i$  和  $z$  的所有循环平移后的图像的分类结果表示为:

$$y^i = \sum_j \alpha_j k(P^i z, P^i x) \quad (9)$$

表示矩阵形式:

$$y = C^T(k) * \alpha \quad (10)$$

其中

$$k_i = k(z, P^i x) \quad (11)$$

对式(10)两边做傅里叶变换, 得:

$$F(y) = F(C^T(k) * \alpha) = F(k) \cdot F(\alpha) \quad (12)$$

再次取傅里叶反变换, 得:

$$y = F^{-1}(F(k) \cdot F(\alpha)) \quad (13)$$

上式可以在单样本采样的基础上寻找下一帧目标的位置, 只需要在上一帧跟踪结果的基础上根据式(5)求出 KRLS 训练系数  $\alpha$ , 以及上一帧模板模型和这一帧的互相关核函数  $K$ , 对两者的傅里叶变换取反变换求出的最大相应位置即为跟踪目标的最新移动位置。

## 2 点跟踪补偿对相关核滤波器跟踪的改进

FB 点跟踪<sup>[6, 15]</sup>是在对稀疏光流点跟踪的基础上舍去偏

差大的跟踪点, 保留跟踪中的好点, 利用相邻的两帧进行正向和反向跟踪, 最终确定目标位置。假设需要跟踪的点  $x_t$  在相邻两帧的轨迹为  $(x_t, x_{t+1})$ , 对  $x_{t+1}$  反向跟踪的点  $\hat{x}_t$ , 该次跟踪的  $fb$  误差表示为原点  $x_t, x_t$  的欧氏距离  $d_{fb} = \|x_t - \hat{x}_t\|$ , 当  $d_{fb}$  大于阈值时, 表示该点跟踪误差大, 应当舍去。

用点跟踪提供的特征点集合  $S'$  和  $S^{t+1}$  对目标尺度和位移进行估计。设  $Distance(i)$  为  $S'$  和  $S^{t+1}$  中对应点  $i$  之间的距离。将所有两对点的位移变化取出中间值, 作为精确确定的位移变化数值。对于尺度变化和角度变化分别采用以下公式。

$$shift = med(\|x_i^{t+1} - x_i^t\|) \quad (14)$$

$$s = med\left(\frac{\|x_i^{t+1} - x_j^{t+1}\|}{\|x_i^t - x_j^t\|}\right), i \neq j \quad (15)$$

相关核滤波器的采样判决阶段利用上步估计的位移和尺度进行多个采样点和多尺度的评估。使用的参数将在实验部分给出。

## 3 利用压缩感知建立目标重检测模型

文献[6]基于压缩理论使用观测矩阵提取目标特征, 具体做法是采用随机高斯矩阵对目标 haar 特征进行压缩后进行特征提取, 提取公式如下:

$$v = Rx \quad (16)$$

其中,  $x \in R^{n \times 1}$  为原始图像 haar 特征组成的列向量,  $R \in R^{k \times n}$  ( $k \ll n$ ) 为一个稀疏观测矩阵。  $v$  是  $k$  维列向量, 表示经过压缩后提取的特征。

在基于压缩感知的特征提取中, 假设提取的特征向量为  $v = (v_1, v_2, \dots, v_n)^T$ , 对于每一个分量  $v_i$ , 高维随机向量在进行低维度的随机映射后服从高斯分布。

$$p(v_i | y = 1) \sim N(\mu_i^1, \sigma_i^1) \quad (17)$$

对于压缩感知提取的特征也需要有尺度不变性, 对此文献[16]指出: 对于测量矩阵压缩成的一个低维度观测向量  $v$ , 对于每一个分量  $v_i$ , 都是由若干个 haar 特征和相应的随机高斯分布组成的权值加权而成, 对于尺度不变性的证明, 只需要证明其中一个加权矩形分量具有尺度不变性。

$$\begin{aligned} x_j(sy) &= F_{sw_j, sh_j}(sy) \otimes Z(sy) \\ &= F_{sw_j, sh_j}(a) \otimes Z(a) |_{a=sy} \\ &= \frac{1}{(s^2 \tau_i h_i)} \int_{u \in \Omega} Z(a-u) du \\ &= \frac{1}{(s^2 \tau_i h_i)} \int_{u \in \Omega} Z(y-u) |s^2| du \\ &= \frac{1}{\tau_i h_i} \int_{u \in \Omega} Z(y-u) du \\ &= F_{sw_j, sh_j}(y) \otimes Z(y) \\ &= x_j(y) \end{aligned}$$

其中,  $\tau_i, h_i$  分别表示 haar 特征的长宽,  $s\tau_i, sh_i$  分别表示尺度扩大了的 haar 特征长宽, 由上式可看出有尺度的压缩感知特征的 haar 不再是固定矩形框内的相对于左上点的绝对距离, 而是相对于矩形宽与长的比例。

压缩感知模型设计如下。

(1) 压缩特征的初始化: 初始化高斯特征的矩形相对位置和相对大小。

(2) 压缩感知模型的提取: 在关键帧提取压缩模型, 保存模型数据。

(3) 使用历史模型重建测:在关键帧使用压缩模型对相关核滤波器的跟踪结果进行评估,对应相似度低的跟踪结果进行重建测。

表 1 给出各个部分算法综合起来的基本步骤和程序流程。

表 1 程序步骤

1. 初始化:  
Frame=1,手动选择或者文件中读取跟踪目标位置,生成压缩感知随机高斯观测矩阵,并根据当前选择区域建立自相关核滤波器系数和目标特征模板,最后在跟踪区域检测 surf 特征点并保存。
2. 对下一帧读取的图像进行上一帧特征点的 FB 点跟踪,求出尺度估计变化  $s$  和补偿位移  $(xshift, yshift)$ 。
3. 对当前帧进行有位移补偿和尺度估计的相关核滤波器跟踪。
4. 对跟踪得到的目标进行压缩感知特征的提取并求得已知模型下的先验估计值  $value$ 。
5. 如果相关核滤波器跟踪的结果先验值小于  $KShred$  阈值,并且上一步得到的  $value$  值小于  $CShred$ ,说明模型跟踪偏差较大,转到第 6 步,否则转到第 7 步。
6. 使用已知压缩感知建立的目标模型,进行贝叶斯最优分类器,找到最优目标框得到位移补偿  $(cxshift, cyshift)$ ,再在位移补偿的基础上作一次相关核滤波器跟踪,作为重新检测和再跟踪的结果。
7. 如果相关核滤波器的跟踪结果评估值大于  $KShred$  阈值,并且  $value$  值小于  $CShred$ ,说明跟踪结果良好,但是压缩感知模型先验结果出现大偏差,则对跟踪结果加入进行压缩感知的模型中,作为一个新加入的模型。
8. 重新检测当前帧的 surf 特征点,作为下一帧跟踪的数据。
9.  $frame=frame+1$ ,返回到步骤 2。

#### 4 实验及结果分析

本文采用了具有尺度变化的视频序列作为算法有效性验证的实验数据,并与基本的相关核滤波器跟踪的方法以及其他尺度方法做对比。视频采用帧像素分别为  $640 \times 480$ ,采用高斯模型提取的特征数目为 50,尺度因子  $scale\_step$  为 1.05,  $scale\_weight$  为 0.95,高斯尺度因子  $\sigma = 0.1$ ,  $kcfShred$  为 0.15,  $ctShred$  为  $0.01 \times featureNum$ ,对于有尺度变化的跟踪采用  $\frac{G \cap T}{G \cup T}$  作为衡量尺度的覆盖率,  $G$  表示 groundtruth 即标准库中给出的目标面积,  $T$  表示跟踪到的目标。

实验数据如图 1—图 3 所示。

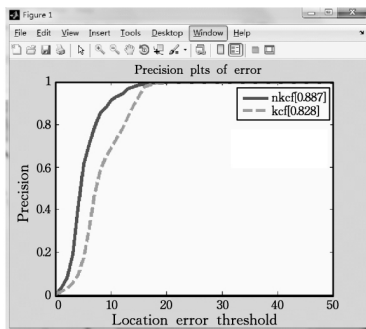


图 1 Trellis 跟踪精度

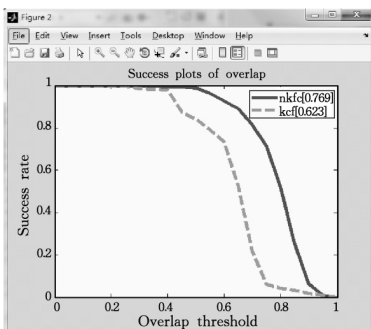


图 2 Trellis 成功覆盖率




图 3 Trellis 序列跟踪误差



图 4 Trellis 10,20,289,393,398,569 帧的跟踪结果

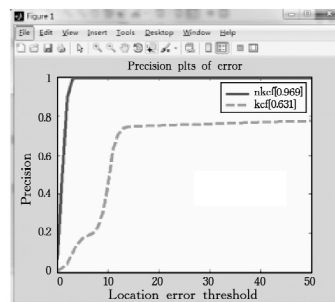


图 5 Carl 跟踪精度




图 6 Carl 成功覆盖率




图 7 Carl 序列跟踪误差

图 1—图 4 为 Trellis 视频序列的跟踪结果,在人物移动过程中出现尺度变化,从算法对比结果中可以看到,在尺度出现变化时,原始算法的跟踪模板由于未定值,会把跟踪目标周围环境考虑在模板内,造成模板不能完全描述人物的跟踪区域,并且尺度变化更有助于分析目标相对摄像机镜头距离的改变,视频出现了明暗的变化,说明有点跟踪补偿的相关核滤波器对敏

感变化有一定的适应性,不会对跟踪结果带来较大误差。



图8 Car1 10,100,300,600,750,1000 帧的跟踪结果

从图5—图8可以看出,Car1的视频中当尺度发生明显改变时,本算法可以非常准确地捕获目标的变化,从而准确地选取合适的模板作为训练数据。对于 dsst 算法中使用的核对应尺度的估计,是先使用原始的相关核滤波器进行一次跟踪,即对下一帧目标中心点的跟踪。再跟踪这个中心点提取不同尺度的模板(通常为 hog 特征)作为不同尺度的特征表示,并记为  $(M_1, M_2, \dots, M_n)$ ,使用公式:

$$H = \frac{-\bar{G}F}{\sum_{k=1}^d \bar{F}^k F^k + \lambda} \quad (17)$$

得到最大响应的尺度作为当前帧模型的尺度。相应的实验在文献[11]中视频中使用 dog1 测试,结果显示这种尺度估计在纹理表面清晰的图像中实用性比较好,这里给出在 Car1 中的实验结果。从图9—图11可以看出纹理不明显的图像中基于核滤波器的尺度估计没有点跟踪补偿那样好的估计效果。

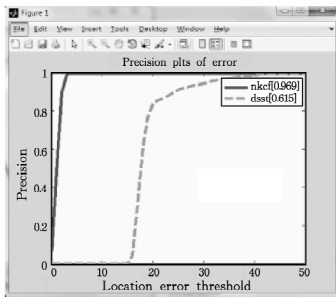


图9 Car1 dsst 和本文算法跟踪精度对比




图10 Car1 dsst 和本文算法成功覆盖率对比




图11 Car1 dsst 和本文算法跟踪误差的对比

为了验证压缩感知模型的作用,本文使用了 bolt 视频。

图12、图13是使用了压缩模型和尺度因子补偿后的跟踪效果。为了验证压缩模型的作用,本文作了对比实验,对算法中压缩模型的部分去掉后,bolt 的实验结果如图14所示。

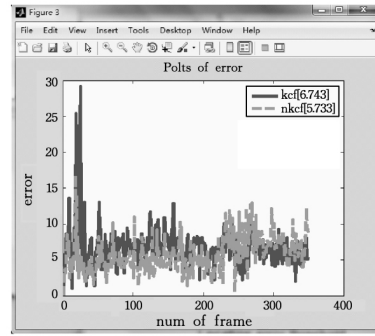


图12 bolt 中心误差

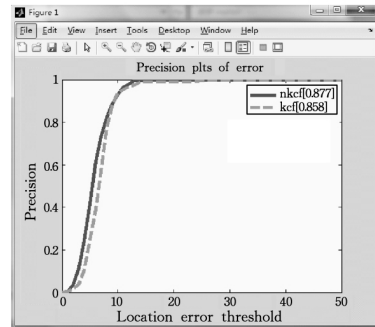


图13 bolt 跟踪精确度




图14 bolt 239,240,260,280,320,350 帧的跟踪结果

可以看出在 239 帧前后几帧之内,跟踪的目标发生了突变,突变对于点跟踪会使得尺度补偿对相关核滤波器提供错误的尺度补偿,使得关键帧出现错误,尺度估计过大,后续帧的跟踪也就出现了异常。在关键帧使用尺度不变的高斯模型可以重新检测目标,进行再次跟踪,对于快速重新捕获目标具有实际的应用意义。

该算法的不足:由于考虑了尺度因子,而尺度因子在现有算法中不成熟,在一些视频的测试过程中,对于低分辨率或者小目标图像的跟踪,由于目标的特征点较少,尺度估计往往有比较大的偏差;对于压缩模型,因为目标运动的模糊像素存在,使得相邻帧之间模型的压缩特征变化比较明显,重新检测会对目标跟踪产生负作用。在上文所描述的情况下,改进的跟踪算法没有原始的相关核滤波器跟踪算法准确。

结束语 本文提出的算法使用压缩感知提取目标特征作为跟踪目标的模型,并在相关核滤波器中加入了基于点跟踪的尺度因子。传统的相关核滤波器算法由于没有考虑适度尺度因子,或者没有存储移动目标在连续视频序列中的模型,会使得在跟踪目标发生突变时出现尺度判决异常及跟踪丢失的情况。本文提出了基于压缩感知模型的改进相关核滤波器的算法。通过程序设计了一个以压缩感知提取的高斯模型描述目标状态的模型,并与尺度因子融合,在相关核滤波器跟踪出现异常时,对移动目标进行重新精确定位,即重新检测的过程,

(下转第 214 页)

的图像块,通过图像块聚类得到聚类中心,并利用聚类中心重建出高分辨率图像,从而更加精确地对图像进行重建。实验证明,本文方法无论从视觉评价还是定量评价方面都能得到令人满意的超分辨重建结果。

但是在进行训练时,随着训练数据的增加,训练速度有所降低,如何解决该问题将是我們进一步研究的工作重点。

### 参 考 文 献

- [1] Glasner D, Bagon S, Irani M. Super-resolution from a single image[C]//Proceedings of IEEE International Conference on Computer Vision. 2009:349-356
- [2] 黄浩锋,肖南峰.基于组稀疏表示的医学图像超分辨率重建[J].计算机学报,2015,42(6A):151-153
- [3] Yang M C, Wang Y C F. A Self-Learning Approach to Single Image Super-Resolution[J]. IEEE Transactions on Multimedia, 2013,15(3):498-508
- [4] Kaibing Z, Dacheng T, Xinbo G, et al. Learning Multiple Linear Mappings for Efficient Single Image Super-resolution[J]. IEEE Transactions on Image Processing A Publication of the IEEE Signal Processing Society, 2015,24(3):846-861
- [5] Russell Hardie. A fast image super resolution algorithm using an adaptive wiener filter[J]. IEEE Transactions on Image Processing, 2007,16(12):2953-2964
- [6] Wu X, Zhang X. Image interpolation using texture orientation map and kernel fisher discriminant[C]//Proceedings of IEEE Conference on Image Processing(ICIP'OS). 2005:49-52
- [7] Wang L, Xiang S, Meng G, et al. Edge-Directed Single-Image Super-Resolution Via Adaptive Gradient Magnitude Self-Interpolation[J]. IEEE Transactions on Circuits & Systems for Video Technology, 2013,23(8):1289-1299
- [8] Pan Z X, Yu J, Xiao C B, et al. Dictionary Learning and Structur-

al Self-similarity-Based Codebook Mapping for Single Image Super Resolution[J]. Journal of Computer-Aided Design and Computer Graphics, 2015,27(6):1032-1038

- [9] Zhang K, Gao X, Tao D, et al. Single image super-resolution with non-local means and steering kernel regression. [J]. IEEE Transactions on Image Processing, 2012,21(11):4544-4556
- [10] 窦诺,赵瑞珍,岑翼刚,等.基于稀疏表示的含噪图像超分辨重建方法[J].计算机研究与发展,2015(4):943-951
- [11] Dong W, Zhang L, Lukac R, et al. Sparse Representation Based Image Interpolation With Nonlocal Autoregressive Modeling [J]. IEEE Transactions on Image Processing, 2013,22(4):1382-1394
- [12] 于伟,姚鸿勋,孙晓帅,等.面向图像超分辨率的上下文字典学习[J].计算机学报,2014,41(10):87-90
- [13] Yang J, Wright J, Huang T, et al. Image super resolution via sparse representation[J]. IEEE Transactions on Image Processing, 2010,19(11):2861-2873
- [14] In K, Younghee K, et al. Single-image super-resolution using sparse regression and natural image prior[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2010,32(6):1127-1133
- [15] Yang C Y, Yang M H. Fast direct super-resolution by simple functions[C]//Proceedings of the 2013 IEEE International Conference on Computer Vision. IEEE Computer Society, 2013:561-568
- [16] Wang Z, Bovik A C, Sheikh H R, et al. Image quality assessment: from error visibility to structural similarity [J]. IEEE Transactions on Image Processing, 2004,13(4):600-612
- [17] Channappayya S, Bovik A. Rate bounds on SSIM index of quantized images[J]. IEEE Transactions on Image Processing, 2008,17(9):1624-1639

(上接第 204 页)

这个过程比 SVM 训练建立的模型检测过程更快、更准确。最后通过实验和数据证明了改进的相关核滤波器算法具备有效性和优越性。

### 参 考 文 献

- [1] Comaniciu D, Ramesh V, Meer P. Real-time tracking of non-rigid objects using mean shift[C]//IEEE Conference on Computer Vision and Pattern Recognition, 2000. IEEE, 2000:142-149
- [2] Zhang Kai-hua, Zhang Lei, Yang M S. Real-time compressive tracking [C]//Proc of 12th European Conference on Computer Vision. 2012:864-877
- [3] Zhang Kai-hua, Zhang Lei, Yang M H. Fast Compressive Tracking[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2014,36(10):2002-2015
- [4] Henriques J F, Caseiro R, Martins P, et al. High-Speed Tracking with Kernelized Correlation Filters[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015,37(3):583-596
- [5] Grabner H, Bischof H. On-line Boosting and Vision[C]//2006 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. 2006:260-267
- [6] Kalal Z, Mikolajczyk K, Matas J. Tracking-Learning-Detection [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2012,34(7):1409-1422
- [7] Babenko B, Yang M H, Belongie S. Visual Tracking with Online Multiple Instance Learning[C]//IEEE Conference on Computer

Vision and Pattern Recognition. 2009:983-990

- [8] Nummiaro K, Koller-Meier E, Van Gool L. An adaptive color-based particle filter[J]. Image and Vision Computing, 2003,21(1):99-110
- [9] Hare S, Saffari A, Torr P H S. Struck: Structured Output Tracking with Kernels[J]. IEEE International Conference on Computer Vision, 2011,23(5):263-270
- [10] Zhang Jian-ming, Ma Shu-gao, Sclaroff S. MEEM: Robust Tracking via Multiple Experts Using Entropy Minimization[M]//Computer Vision-ECCV. 2014,2014:188-203
- [11] Danelljan M, Häger G, Khan F S, et al. Accurate Scale Estimation for Robust Visual Tracking[C]//British Machine Vision Conference. Nottingham, 2014
- [12] Henriques J F, Caseiro R, Martins P, et al. Exploiting the Circulant Structure of Tracking-by-detection with Kernels[C]//Computer Vision-ECCV 2012. 2012:702-715
- [13] Zhang Peng, Peng Jing. SVM vs Regularized Least Squares Classification[C]//Proceedings of the 17th International Conference on Pattern Recognition. 2004:176-179
- [14] Rifkin R, Yeo G, Poggio T. Regularized least-squares classification[J]. Nato Science Series Sub Series III: Computer and Systems Sciences, 2003,190:131-154
- [15] Kalal Z, Mikolajczyk K, Matas J. Forward-backward error: Automatic detection of tracking failures[C]//2010 20th International Conference on Pattern Recognition (ICPR). IEEE, 2010:2756-2759