

运动状态与尺度估计的核相关目标跟踪方法

朱航江¹ 朱帆² 潘振福¹ 朱永利¹

(华北电力大学计算机系 保定 071003)¹ (首都师范大学哲学系 北京 100048)²

摘要 视觉跟踪在视频智能监控和机器人等领域有着广泛应用。基于相关滤波分类器,提出了具有运动状态估计和目标尺度估计的视觉目标跟踪方法。该方法将粒子滤波与核相关滤波方法相结合,首先估算运动目标的位置,然后执行尺度相关滤波器来估算目标的尺度,以使算法对尺度变化的运动目标具有更强的适应能力。该方法在传统的 KCF 跟踪算法的基础上引入了一种基于概率的运动状态估计方法,可以获得更加稳定的目标信息,并减少背景干扰信息的引入,从而在复杂场景下具有更强的抗干扰性。使用 benchmark 数据集对所提方法进行了测试实验,并和其他已有的若干视觉跟踪方法进行了对比实验,结果验证了所提算法的高效性,且所提方法在目标尺度变化、光照变化、姿态变化、部分遮挡、旋转及快速运动等复杂情况下均有较强的适应性。

关键词 目标跟踪,机器视觉,相关滤波器,运动状态估计,尺度空间估计

中图分类号 TP391 文献标识码 A

Visual Object Tracking Method with Motion Estimation and Scale Estimation

ZHU Hang-jiang¹ ZHU Fan² PAN Zhen-fu¹ ZHU Yong-li¹

(Department of Computer Science, North China Electric Power University, Baoding 071003, China)¹

(Department of Philosophy, Capital Normal University, Beijing 100048, China)²

Abstract Visual tracking has a wide range of applications in various fields such as video intelligent monitoring and eyes of robot. Based on discriminatory correlation filter, a visual target tracking method with motion estimation and scale estimation method was proposed. First, this method combines translation kernel correlation filter and particle filter method to estimate the position of moving targets on the frame. And then, it executes the scale correlation filter to be stronger ability to adapt scale change of moving object. In traditional KCF tracking algorithm, this method introduces a motion state estimation method based on probability, which can obtain more stable signal of target, and reduces the introduction of the background interference information at the same time, leading to it has stronger anti-jamming in complex scenarios. On benchmark data set, we took experiment to test this method, and compared our method with the current advanced tracking methods to verify the efficiency of the proposed algorithm in this paper. It has strong adaptability under complex conditions, the change of scale, illumination, change of pose, partial sheltering, rotating and rapid movement etc.

Keywords Target tracking, Machine vision, Correlation filter, Motion state estimation, Scale estimation

近年来视觉目标跟踪已获得了高度的关注,成为了计算机视觉中最具吸引力的研究课题之一,被广泛应用于运动分析、行为识别、监控及人机交互等方面^[1-3]。尽管近年来目标跟踪技术取得了相当大的进展,但众多因素影响跟踪算法的性能,如光照变化、遮挡和背景混杂等,以至视觉目标跟踪仍然是一个具有挑战性的课题。目前不存在单一的方法能够成功地处理所有场景^[4]。相关滤波器分类方法可以在频域中使用快速傅里叶变换(fast Fourier transform, FFT)进行有效的计算^[5-6],由于其计算的高效性,近年许多研究者将其应用到目标跟踪领域中。2014 年的视觉目标追踪(The Visual Object Tracking VOT)挑战结果^[7]显示,基于相关滤波器的跟踪器是目前最优秀的目标跟踪算法之一,它具有优秀的跟踪性能。Bolme 等提出一种在灰度图像上学习一个最小输出平方

误差和相关滤波器(MOSSE)的跟踪方法,对目标外观变化有较强的适应性^[8];Danelljan 等提出了一种自适应颜色属性的跟踪方法,该方法将颜色特征属性集成到 CSK (Circulant Structure of Tracking-by-Detection with Kernels) 跟踪器^[9]中,并在将多维特征映射到高斯核空间后学习自适应相关滤波器^[11];Henriques 等对 CSK 方法进行了扩展,使用了梯度方向直方图(HOG)特征,提出了核相关滤波器(Kernelized Correlation Filter, KCF)及双相关滤波器(Dual Correlation Filter, DCF)跟踪器^[12]。由 Danelljan 等人在 CSK 以及 MOSSE 算法的基础上提出的基于相关滤波器的分类尺度空间跟踪器(Discriminative Spatial Scale Tracker, DSST)^[12]的性能更是在 VOT2014 视觉目标追踪挑战中位列第一。

另外,具有目标运动状态估计性能的粒子滤波框架在视

本文受河北省自然科学基金项目(F2014502069)资助。

朱航江(1992—),男,硕士生,主要研究方向为人工智能算法、数字图像处理, E-mail: hangjiang2011@163.com;朱帆(1989—),男,硕士生,主要研究方向为现代逻辑推理;潘振福(1989—),男,硕士生,主要研究方向为视觉目标跟踪、数字图像处理, E-mail: panzhenfu20@126.com;朱永利(1963—),男,博士,教授,博士生导师,主要研究方向为人工智能与知识工程、机器学习。

觉目标跟踪研究中有着至关重要的作用^[13]。文献^[16]表明,由大连理工大学卢湖川教授提出的一系列基于粒子滤波框架稀疏模型的视觉目标跟踪方法(如自适应局部稀疏结构化的外观模型^[14]、稀疏表原型方法^[15])位列前茅。

大多数检测跟踪方法(如 CSK, MOSSE, KCF 等)仅局限于目标位置估算,即在有显著尺度变化的视频序列中的表现较差。另一方面,一些现有尺度估计跟踪方法^[14-15,17]的计算效率低,从而在实时的应用场景中的适应性较差。

基于上述方法的优缺点,本文提出一种具有运动状态估计与目标尺度估计的视觉目标跟踪方法,该方法结合粒子滤波具有运动状态估计的特性与相关滤波器的高效性的优势,借鉴 DSST 尺度估计的尺度金字塔相关滤波方法,从而实现一种多尺度的相关滤波器跟踪方法。

1 KCF 跟踪算法

在 KCF 跟踪算法中,以核岭回归分类器为核心,构建循环样本矩阵来训练该分类器,对样本进行巧妙的变换使训练数据矩阵具有循环特性,通过离散傅里叶变换对角化可以减少几个数量级的存储与计算,从而达到对目标进行快速且有效检测跟踪的目的。

1.1 核岭回归分类器

KCF 跟踪算法采用核岭回归分类器,即 $f(z) = w^T \varphi(z)$ 。设从样本空间到 Hilbert 特征空间的非线性变换为 $x_i \rightarrow \varphi(x_i)$,定义核函数为 $\kappa(x, x') = \langle \varphi(x), \varphi(x') \rangle$,则优化问题的最优解为:

$$\min_w \sum_i (\langle w, \varphi(x_i) \rangle - y_i)^2 + \lambda \|w\|^2 \quad (1)$$

其中, x_i 为样本, y_i 为期望输出, λ 为一个固定的正则化参数。根据文献^[18]得其最优解为样本的线性组合:

$$w = \sum_i \alpha_i \varphi(x_i) \quad (2)$$

由式(2)可知,需要优化的变量是 α ,而不是 w 。

核岭回归问题的解由文献^[19]给出:

$$\alpha = (K + \lambda I)^{-1} y \quad (3)$$

1.2 循环矩阵

对样本 x 进行移位变换,可以获得循环矩阵 X ,即:

$$X = C(x) = \begin{bmatrix} x_1 & x_2 & x_3 & \cdots & x_n \\ x_n & x_1 & x_2 & \cdots & x_{n-1} \\ x_{n-1} & x_n & x_1 & \cdots & x_{n-2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ x_2 & x_3 & x_4 & \cdots & x_1 \end{bmatrix} \quad (4)$$

矩阵 X 完全由指定的样本向量 x (式(4)的第一行)循环移位生成。无论生成的向量 x 为何值,所有循环矩阵都能被离散傅里叶变换(DFT)矩阵对角化^[21],即:

$$X = F \text{diag}(\hat{x}) F^H \quad (5)$$

其中, F 是一个与 x 无关的常量矩阵,用来计算 DFT,如 $F(z) = \sqrt{n} Fz$; F^H 是 F 的共轭转置;而 \hat{x} 表示生成向量 x 的离散傅里叶变换, $\hat{x} = F(x)$ 。下文都采用“ $\hat{\cdot}$ ”来表示一个向量的傅里叶变换。

1.3 目标快速检测

根据文献^[11]提出的定理 1,若核函数 $\kappa(x, x')$ 是酉不变的,则核矩阵 K 为循环矩阵。因此,式(3)可根据循环矩阵的特性得到频域下的解:

$$\hat{\alpha} = \frac{\hat{y}}{\hat{k} + \lambda} \quad (6)$$

其中, $K = C(k)$, k 的元素 $k_i = \kappa(x, x_i)$ 。

假设核矩阵 K^z 由匹配模板和搜索窗口样本核相关运算所得。因匹配模板 X 和检测样本 Z 是基于元素向量 x 和 z 移位变换的循环结构矩阵,故 K^z 的每个元素是由 $\kappa(p^{i-1}z, p^{j-1}x)$ 组成的一个循环核矩阵,其中 p 为循环移位的单位阵。只需第一行元素来表示核矩阵:

$$K^z = C(k^z) \quad (7)$$

其中, k^z 是 x 与 z 的核相关运算。回归函数表示如下:

$$f(z) = \sum_i \alpha \kappa(x_i, z) = (K^z)^T \alpha \quad (8)$$

$f(z)$ 是一个矩阵,其元素为 z 向量的所有移位变换形式的输出响应,为了更有效地计算式(8),得到对角化后的等式:

$$\hat{f}(z) = \hat{k}^z \cdot \hat{\alpha} \quad (9)$$

其中, \cdot 为矩阵点乘运算; z 是预测包含目标的搜索窗口图像块,从中检测目标的位置; x 为从以前帧中学习获得的目标模型。对式(9)进行 DFT 逆运算,即可得检测样本 z 的响应矩阵,响应最大的位置即为目标所在的位置。更新模型 $\hat{\alpha}$ 和 \hat{x} 为:

$$\hat{\alpha}_t = (1 - \eta) \hat{\alpha}_{t-1} + \eta \hat{\alpha} \quad (10)$$

$$\hat{x}_t = (1 - \eta) \hat{x}_{t-1} + \eta \hat{x} \quad (11)$$

其中, η 为学习因子; $\hat{\alpha}_t, \hat{\alpha}_{t-1}$ 分别表示当前帧和上一帧更新获得的系数向量傅里叶变换; \hat{x}_t, \hat{x}_{t-1} 分别表示当前帧和上一帧更新获得的目标匹配模型的傅里叶变换 \hat{x} 。

2 KCF 尺度估计与运动状态估计扩展

针对传统的 KCF 跟踪方法采用固定的在线学习模式以及固定的目标跟踪矩形框的缺陷,本文提出一种具有目标运动状态估计与尺度空间估计的方法来对传统的 KCF 方法进行改进。结合粒子滤波器并为跟踪算法添加扰动因子,然后用随机逼近方法估计目标的运动状态,借鉴 DSST 尺度估计的尺度金字塔相关滤波方法,实现了一种多尺度的相关滤波器跟踪方法。所提方法的具体流程如图 1 所示。

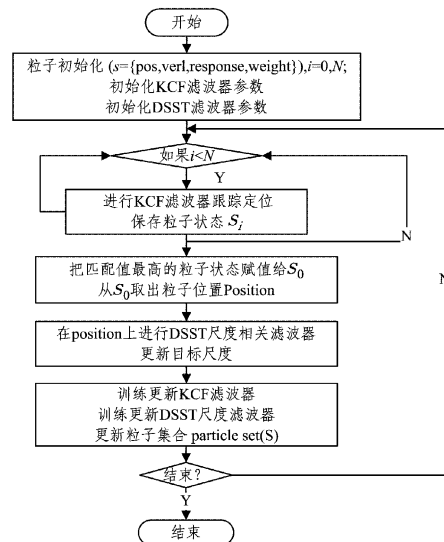


图 1 所提算法的流程图

图 1 中,粒子集合 s 将在第 2.1 小节详细介绍, N 为粒子数。算法先将粒子滤波框架与位置核相关滤波器结合,估算目标位置,再执行尺度相关滤波器估算目标尺度,如此循环。图 1 中涉及的算法将在 2.1 节和 2.2 节中介绍。

2.1 目标运动状态估计

传统的 KCF 跟踪方法以一种固定的在线学习模式对下一帧图片中的跟踪目标进行匹配,在算法中添加扰动因子,然后利用随机逼近方法来提高系统的精确度^[21]。而粒子滤波器(Particle Filter)^[22]是一种基于贝叶斯理论和蒙特卡罗方法的求解后验概率的实用性滤波器,可以给传统的 KCF 跟踪算法引入噪声数据并能从这些数据中估计目标的运动状态。此处的随机变量被形象地称为粒子,当粒子趋于个数无穷时可以逼近任何形式的概率分布。

粒子滤波器的关键思想是通过带权样本粒子集合 $S = \{(s(n) | n=1, \dots, N)\}$ 近似概率分布,每个样本 s 代表核相关滤波器的响应模型。

2.1.1 目标模型与粒子样本集合的描述

采用第 1 节讲述的核相关滤波器的最高响应值分布函数作为目标位置模型的描述。定义每个核相关滤波器最高响应值分布的采样样本,即粒子模型为:

$$s = \{pos, v, response, \pi\} \quad (12)$$

$$pos = \{x, y\} \quad (13)$$

$$v = \{v_x, v_y\} \quad (14)$$

其中, pos 为粒子的初始位置, x 和 y 为粒子对应的坐标, v 为粒子的运动速度, v_x 为粒子对应 x 方向上的速度, v_y 为粒子对应 y 方向上的速度, $response$ 为该粒子经过核相关滤波器后得到的最高响应值, π 为该粒子的权重值。

粒子样本集合的更新通过系统状态变化方程传播: $S_t = AS_{t-1} + w_{t-1}$ 。其中, A 为状态转移矩阵, w_{t-1} 为高斯噪声。

2.1.2 基于核相关最高响应值的粒子滤波算法

初始化 $t-1$ 时刻的粒子样本集合 S_{t-1} 和目标模型,粒子初始权值均为 $\frac{1}{N}$,初始状态为 s_0 ,算法如下。

重采样:根据权重 $s_t^i \cdot \pi$ 从集合 S_{t-1} 中挑选 N 个样本。

(1)对权重数组计算归一化累计概率 c_{t-1}^k :

$$c_{t-1}^k = \frac{\sum_{i=1}^k s_{t-1}^i \cdot \pi}{\sum_{i=1}^N s_{t-1}^i \cdot \pi} \quad (15)$$

(2)产生 N 个在 $[0, 1]$ 区间满足均匀分布的随机变量,构成数组 r 。

(3)对于 r 中的每个元素,分别用二分查找法搜索归一化累计概率数组,得到含有 N 个最小索引的数组 j , j 满足 $c_{t-1}^{j[i]} \geq r[i]$ 。

(4)更新粒子样本集合, $s_{t-1}^i = s_{t-1}^{j[i]}$ 。

传播:根据系统状态方程 $S_t = AS_{t-1} + w_{t-1}$,计算新的粒子集合 S_t ,估计新粒子的位置。

观测:根据状态集合 S_t 中的每一个样本,进行核相关滤波器的位置估算,然后更新估计从而获得新的权重概率。

(1)状态集合 S_t 中的每一个粒子进入位置核相关滤波器,得到核相关滤波器最高响应值,更新粒子的状态:

$$s_t^i \cdot response = \max(f_{trans}(s_t^i) \cdot response) \quad (16)$$

$$s_t^i \cdot pos = f_{trans}(s_t^i) \cdot pos \quad (17)$$

(2)对于集合 S_t 的每个粒子,针对前一帧的目标状态 s_0 更新粒子速度:

$$s_t^i \cdot v_x = s_t^i \cdot pos_x - s_0 \cdot pos_x \quad (18)$$

$$s_t^i \cdot v_y = s_t^i \cdot pos_y - s_0 \cdot pos_y \quad (19)$$

(3)根据集合 S_t ,计算各个粒子的权重值:

$$s_t^i \cdot \pi = \frac{s_t^i \cdot response}{\sum_{k=0}^N s_t^k \cdot response} \quad (20)$$

估计:根据权重估算集合 S_t 经过核相关滤波器后的最大响应值的最大值,提取位置坐标作为目标跟踪输出:

$$s_0 = \{s_t^k | s_t^k \cdot response = \max(s_t^i \cdot response), i=1, \dots, N\} \quad (21)$$

2.2 目标尺度估计

传统的 KCF 跟踪方法始终固定地以初始化的矩形框去搜寻下一帧中的目标,不能很好地适应目标尺度发生变化的目标跟踪情况,且将尺度估计纳入一个跟踪器中需要很高的计算代价。本文采用一个通过学习独立于定位滤波器的滤波器来进行快速的尺度估算方法,这样有助于把尺度空间的搜索区域限制在更小范围。此外,还可以自由地选择每个独立的滤波器的特征描述。因此,在上述定位框架下,通过学习另一个一维相关滤波器来估算图像中的目标尺度。

2.2.1 一维分类相关滤波器

采用一维的特征映射表示图像信号,如图 2 所示。




图 2 一维特征映射表示尺度金字塔

采用一个矩形图像块 J 中提取的特征映射 f 来表示目标。目标是寻找一个最优的相关滤波器 h ,使得一维分类相关滤波器的最小化误差输出为:

$$\epsilon = \|h * f - g\|^2 + \lambda_s \|h\|^2 \quad (22)$$

其中, g 是希望相关输出值, f 为训练样本,参数 $\lambda(\lambda > 0)$ 为正则化参数。根据文献^[12]及式(22)得:

$$H = \frac{G^* F}{F^* F + \lambda_s} \quad (23)$$

其中,大写字母表示式(22)中对应符号的傅立叶变换。 G^* 表示 g 的共轭矩阵的傅立叶变换。可以通过最小化输出误差 ϵ 对所有图像块进行训练以获得一个最优滤波器 h 。为了获得一个鲁棒的近似值,我们分别更新相关过滤器 H_t (见式(23))的分子 A_t 和分母 B_t :

$$A_t = (1 - \eta)A_{t-1} + \eta G_t^* F_t \quad (24a)$$

$$B_t = (1 - \eta)B_{t-1} + \eta F_t^* F_t \quad (24b)$$

其中, η 是一个学习速率参数。检测矩形区域的特征映射使 Z 用式(25)计算相关滤波响应向量 Y 。然后通过寻找最大相关响应值 y_{\max} 来估算新的目标尺度。

$$Y = F^{-1} \left\{ \frac{\bar{A}Z}{B + \lambda} \right\} \quad (25)$$

2.2.2 特征金字塔

在一个已估算出目标位置的框架下,在该位置上提取样本的 s 层 PCA-HOG 特征金字塔。使用一维高斯函数作为相应的所需的相关输出 g ,然后使用式(25)计算该特征金字塔的相关响应向量 Y ,通过最高相关响应值 y_{\max} 估算新的目标尺度。

设 $P \times R$ 和 S 分别表示当前帧中的目标大小和尺度大小。对于每个 $n \in \left\{ \left\lfloor -\frac{s-1}{2} \right\rfloor, \dots, \left\lfloor \frac{s-1}{2} \right\rfloor \right\}$, 提取以目标为中心、大小为 $a^n P \times a^n R$ 的图像块 J_n , 其中 a 表示各个特征层之间的尺度因子。提取图像块 J_n 的特征映射作为训练样本, 尺度金字塔的第 n 层的特征描述值为 $f(n)$, 最后采用式(24)更新尺度过滤器 h_{scale} 。

3 性能评估方法

我们定量地分析本文算法的精度和成功率。此外, 从时间鲁棒性和空间鲁棒性两个方面来评估所提跟踪算法的鲁棒性^[23]。

(1)精度(Precision)。一个广泛使用的跟踪精度评价指标是中心位置误差, 即平均跟踪目标和手动标注的中心位置之间的欧氏距离。使用所有的帧序列平均中心位置误差来评价算法对该序列的整体性能。然而, 当跟踪失去目标时, 输出位置可以是随机的, 平均误差值可能是对跟踪性能的一个不正确统计^[24]。最近精度评估采用跟踪估计位置在给定阈值距离范围内的帧数的百分比来测量跟踪的整体性能。一般使阈值取 20 像素。

(2)成功率(Success Rate)。另一个评估指标是边界框重叠率, 即使用跟踪边界框 r_t 和人工标注真实边界框 r_a , 将成功率定义为 $S = \frac{|r_t \cap r_a|}{|r_t \cup r_a|}$, 其中 \cap 和 \cup 分别代表两个框区域的交集和并集, $|\cdot|$ 表示像素的数量。然后计算跟踪帧的数量重叠率 S , 若 S 大于给定的阈值 t_0 , 则定义为成功跟踪, 以此测量算法在一个帧序列上的性能。

(3)鲁棒性评估(Robustness Evaluation)。传统的跟踪器评估方法是从人工标注的第一帧开始测试序列以及测量其平均精度或成功率, 其称为一遍过评估(One-Pass Evaluation, OPE)。然而一种跟踪算法可能对初始化很敏感, 不同的开始帧可能使算法的性能变得更糟或者更好。因此, 采用两个方面来分析初始化跟踪算法的鲁棒性, 即扰动初始化时间(即在不同的帧开始)和空间(即从不同的边界框开始)。这些测试方法也称为时间鲁棒性评估(Temporal Robustness Evaluation, TRE)和空间鲁棒性评估(Spatial Robustness Evaluation, SRE)。

1)时间鲁棒性评估。将不同的帧数位置作为初始化第一帧, 跟踪器从初始化位置运行到结束的序列, 即一段整个序列。对每段图像序列进行跟踪以评估数据统计, 采用统计数据总体评估算法鲁棒性。

2)空间鲁棒性评估。对 benchmark 数据集图像序列样本中的第一帧人工标注初始边界框进行移位或扩展。本文使用 8 空间变化(包括 4 个中心移位、4 个角移位)和 4 个尺度变化。空间变化目标边界框移位 10%, 尺度变化因子为 0.8, 0.9, 1.1 和 1.2。因此, 对每个图像序列进行 12 组测试, 以统计数据评估跟踪方法的性能。

4 实验与分析

为了验证本文算法的有效性, 对 Benchmark 数据集中富有挑战性的 50 组视频图像序列在时间鲁棒性与空间鲁棒性评估指标上进行了精度与成功率测试, 并与目前比较先进的视觉跟踪算法, 如 DSST^[12] (在视觉目标追踪(VOT2014)挑战中位列第一)、KCF^[11]、ASLA^[14]、CSK^[9], 进行了对比。

4.1 实验环境及参数

实验平台为 Matlab R2010b, 所有的实验均在 Intel Core i3 M390 CPU、主频 2.67GHz、4GB 内存配置的电脑上完成。实验中传统的 KCF 算法的参数保持不变。高斯核的标准差 σ 为 0.5, 学习因子 η 为 0.02, 正则化参数 λ 为 0.0001, 取 HOG 特征, 尺度因子 γ 取 1.5。

本文实验的参数设置如下: 尺度相关滤波器正则化参数 $\lambda_s = 0.01$, 我们所需的相关输出 g 的尺度滤波器的高斯标准差为 1.5, 用 $s = 33$ 作为尺度范围, 尺度因子 $a = 1.02$, 学习率 $\eta = 0.025$ 。

4.2 实验结果与分析

采用一遍过精度评估中本文算法与先进算法的比较结果如图 3 所示, 横坐标为跟踪位置中心与实际标注的目标中心的误差阈值(单位为像素), 纵坐标为精度值, 矩形框里取阈值为 20 像素的精度作为评估标准。在 OPE 精度评估中本文算法与 KCF 持平, 比 DSST 高 1.5%, 比 CSK 高 36.6%, 比 ASLA 高 39.7%。

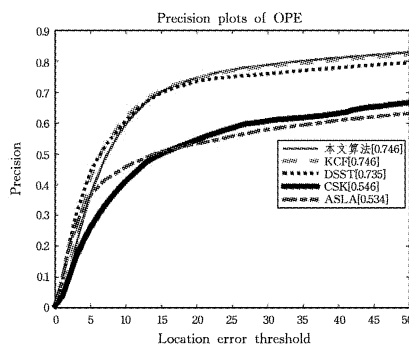


图 3 在 OPE 精度评估中所提算法与其他算法的比较

空间鲁棒性(SRE)的精度评估结果如图 4 所示。本文算法比 KCF 高 1.3%, 比 ALSA 高 21.3%, 比 CSK 高 32.8%。

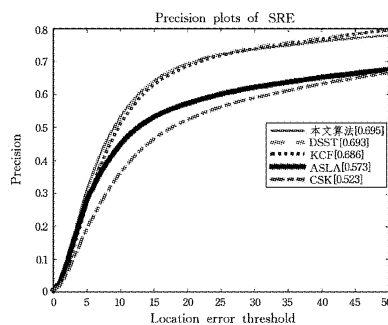


图 4 在 SRE 精度评估中所提算法与其他算法的比较

时间鲁棒性(TRE)的精度评估结果如图 5 所示。本文算法比 KCF 高 0.2%, 比 DSST 高 4.2%, 比 ASLA 高 26.0%, 比 CSK 高 26.8%。

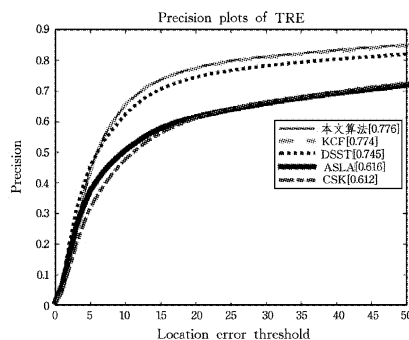


图 5 在 TRE 精度评估中所提算法与其他算法的比较

在一遍过成功率评估中本文算法与先进算法的比较结果如图 6 所示,横坐标为跟踪结果与实际标注的目标覆盖面积比阈值,纵坐标为成功率值,矩形框中取覆盖面积阈值为 0.5 的成功率值。本文算法比 DSST 高 3.5%,比 KCF 高 9.7%,比 ALSA 高 34.4%,比 CSK 高 55.2%。

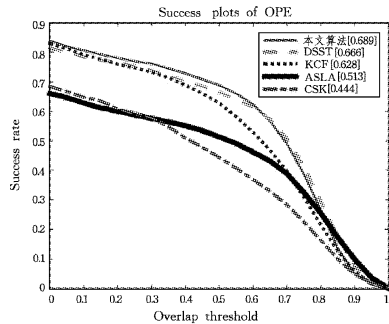


图 6 在 OPE 成功率评估中所提算法与其他算法的比较

空间鲁棒性(SRE)成功率的比较结果如图 7 所示。本文算法比 KCF 高 9.6%,比 ALSA 高 19.6%,比 CSK 高 49.8%。

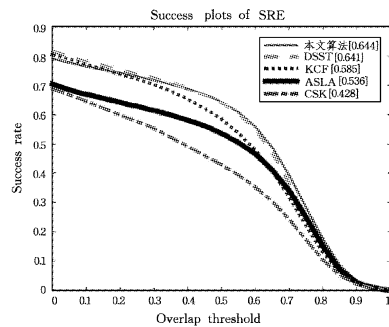


图 7 在 SRE 成功率评估中所提算法与其他算法的比较

时间鲁棒性(TRE)成功率的比较结果如图 8 所示。

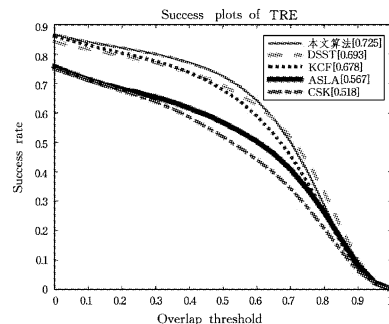


图 8 在 TRE 成功率评估中所提算法与其他算法的比较

本文算法比 DSST 高 4.6%,比 KCF 算法高 6.9%,比 ALSA 高 27.9%,比 CSK 高 40.0%。

4.3 质量与效率评估

使用 benchmark 数据集进行跟踪质量的对比实验,本文算法与目前已有先进算法的跟踪质量的部分实验比较结果如图 9 所示,其中图 9(a)为 carScale 图像序列,图 9(b)为 couple 图像序列,图 9(c)为 david3 图像序列,图 9(d)为 faceocc2 图像序列,图中细实线方框为本文算法跟踪结果,虚线方框为 DSST 跟踪结果,点线为 ALSA 跟踪结果,粗实线为 CSK 跟踪结果。由图 9 可以看出,某些算法对某些图像序列未能有效跟踪,而所提算法对 4 组图像序列均能进行有效跟踪。本研究对 benchmark 数据集中的 50 组图像序列均进行了对比实验,实验的总体对照结果在图 3—图 8 中得到了体现,这表明所提算法具有很强的稳定性与适应性。

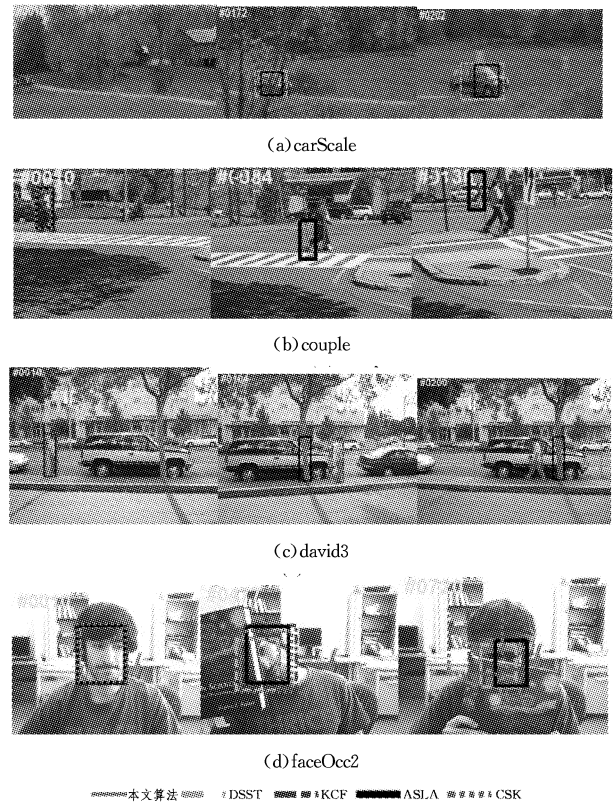


图 9 本文算法与先进算法的运行质量的比较结果

本文跟踪算法与目前已有先进算法的评估结果对照表如表 1 所列。

表 1 本文跟踪算法与目前先进算法的评估结果对照表

评估方式	跟踪算法				
	本文算法	DSST	KCF	ALSA	CSK
图像处理速度/fps	29.185	20.657	129.867	1.391	209.634
一遍过(OPE)精度	0.746	0.735	0.746	0.534	0.546
空间鲁棒性(SRE)精度	0.695	0.693	0.688	0.573	0.523
时间鲁棒性(TRE)精度	0.776	0.745	0.774	0.616	0.612
一遍过(OPE)成功率	0.689	0.666	0.628	0.513	0.444
空间鲁棒性(SRE)成功率	0.644	0.641	0.585	0.536	0.428
时间鲁棒性(TRE)成功率	0.725	0.693	0.678	0.567	0.518

其中精度评估采用跟踪估计位置在给定阈值 20 像素距离范围内的帧数的百分比。成功率评估采用跟踪框与实际标注框重叠率 50%的帧数的百分比。表 1 中,所提算法的跟踪

效率比 DSST 算法高 41.28%,这表明所提算法具有更高的时效性,可以胜任实时任务。

结束语 鉴于核相关滤波器的时效性,本文结合粒子滤

波的运动状态估计与相关滤波器尺度估计的优越性,提出了一种具有运动状态估计与目标尺度估计的视觉目标跟踪方法。先将粒子滤波框架与位置核相关滤波器结合以估算出目标位置,这种基于概率的运动状态估计方法可以获得更加稳定的目标信号,同时减少了背景干扰信息的引入,从而在复杂场景下具有更强的抗干扰性。然后,通过执行尺度相关滤波器估算目标尺度,以使本算法对尺度变化的运动目标具有更强的适应能力。将本方法与目前先进的跟踪方法进行了比较对照实验,结果验证了本文算法的高效性;在目标发生尺度变化、光照变化、姿态变化、部分遮挡、旋转及快速运动等复杂情况下,所提方法均有较强的适应性,具有重要的理论和应用研究价值。

参 考 文 献

- [1] YILMAZ B A, et al. Object Tracking: A Survey [J]. ACM Journal of Computing Surveys, 2006, 38(4): 13.
- [2] CANNONS K. A review of visual tracking [J]. Dept. comput. sci. eng, 2008; 42.
- [3] ZHANG K, ZHANG L, LIU Q, et al. Fast Visual tracking via dese spatio-temporal context learning [C]//Proc. of the European Conference on Computer Vision. 2014.
- [4] PETROSINO A, KRISTAN M, MATAS J, et al. The visual object tracking vot2015 challenge results [C]//Computer Vision-ICCV. 2016; 564-586.
- [5] CASASENT D. Unified synthetic discriminant function computational formulation [J]. Applied Optics, 1984, 23(10): 1620-1627.
- [6] HESTER C F, CASASENT D. Multivariant technique for multi-class pattern recognition [J]. Applied Optics, 1980, 19(11): 1758-1761.
- [7] KRISTAN M, PFLUGFELDER R, Leonardis A, et al. The Visual Object Tracking VOT2014 challenge results [J]. Lecture Notes in Computer Science, 2014, 8926: 191-217.
- [8] BOLME D S, BEVERIDGE J R, DRAPER B, et al. Visual object tracking using adaptive correlation filters [C]//2010 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2010; 2544-2550.
- [9] HENRIQUES J F, RUI C, MARTINS P, et al. Exploiting the Circulant Structure of Tracking-by-Detection with Kernels [J]. Lecture Notes in Computer Science, 2012, 7575(1): 702-715.
- [10] DANELLJAN M, KHAN F S, FELSBURG M, et al. Adaptive Color Attributes for Real-Time Visual Tracking [C] // 2014 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2014; 1090-1097.
- [11] HENRIQUES J F, CASEIRO R, MARTINS P, et al. High-Speed Tracking with Kernelized Correlation Filters [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2014, 37(3): 1.
- [12] DANELLJAN M, HÄGER G, KHAN F, et al. Accurate scale estimation for robust visual tracking [C]//British Machine Vision Conference. Nottingham, BMVA Press, 2014.
- [13] NUMMIARO K, KOLLER-MEIER E, GOOL L V. An adaptive color-based particle filter [J]. Image & Vision Computing, 2003, 21(1): 99-110.
- [14] LU H, JIA X, YANG M H. Visual tracking via adaptive structural local sparse appearance model [C]//IEEE Conference on Computer Vision & Pattern Recognition. IEEE Computer Society, 2012; 1822-1829.
- [15] DONG W, LU H, YANG M H. Online object tracking with sparse prototypes [J]. IEEE Transactions on Image Processing, 2013, 22(1): 314-325.
- [16] WU Y, LIM J, YANG M H. Object Tracking Benchmark [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2015, 37(9): 1834-1848.
- [17] ZHONG W. Robust object tracking via sparsity-based collaborative model [C]//IEEE Conference on Computer Vision & Pattern Recognition. 2012; 1838-1845.
- [18] SCHÖLKOPF B, SMOLA A. Learning With Kernels: Support Vector Machines, Regularization, Optimization, and Beyond [J]. Journal of the American Statistical Association, 2005, 16(3): 781-781.
- [19] RIFKIN R, YEO G, POGGIO T. Regularized Least-Squares Classification [J]. Acta Electronica Sinica, 2003, 190(1): 93-104.
- [20] GRAY R M. Toeplitz and circulant matrices: a review [J]. Foundations & Trends@ in Communications & Information Theory, 2005, 2(3): 155-239.
- [21] 张华军, 赵金, 罗慧. 基于拟牛顿法的同时扰动随机逼近算法 [J]. 华中科技大学学报(自然科学版), 2014(9): 1-4.
- [22] 王法胜, 赵清杰. 一种用于解决非线性滤波问题的新型粒子滤波算法 [J]. 计算机学报, 2008, 31(2): 346-352.
- [23] WU Y, LIM J, YANG M H. Online Object Tracking: A Benchmark [C]//2013 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2013; 2411-2418.
- [24] BABENKO B, YANG M H, BELONGIE S. Robust Object Tracking with Online Multiple Instance Learning [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2011, 33(8): 1619-1632.