

快速尺度自适应核相关滤波目标跟踪算法

何雪东, 周盛宗*

中国科学院福建物质结构研究所, 福建 福州 350002

摘要 针对大多数跟踪算法无法解决尺度变化问题和现有尺度解决方案存在冗余、固定的问题, 提出一种基于核相关滤波框架的由粗到细快速和新颖地解决尺度估计的方法, 考虑到仅利用响应图峰值进行比较存在不稳定性, 以检测响应图与期望输出图的欧氏距离作为峰值的可靠程度, 以两者的乘积作为最终比较结果; 该方法首先使用 3 个尺度因子确定目标尺度变化方向, 然后在尺度变化方向求解最优尺度; 在 OTB-100 的 26 个带有尺度变化属性的基准序列上进行实验, 并与现有其他先进跟踪算法进行定量和定性比较。结果表明: 提出的方法能够很好地解决尺度变化问题; 与核相关滤波相比, 所提出算法的平均距离精度提高了 18.8%, 曲线下面积提高了 19.6%, 跟踪速度是稳健视觉跟踪的精确尺度估计的 2.5 倍, 是特征整合尺度自适应核相关滤波跟踪算法的 6 倍。

关键词 机器视觉; 目标跟踪; 核相关滤波; 尺度估计; 遮挡检测

中图分类号 TP391.41

文献标识码 A

doi: 10.3788/LOP55.121501

Fast Scale Adaptive Kernel Correlation Filtering Algorithm for Target Tracking

He Xuedong, Zhou Shengzong*

Fujian Institute of Research on the Structure, Chinese Academy of Sciences, Fuzhou, Fujian 350002, China

Abstract Most tracking algorithms cannot solve the problem of scale variation and the existing scale solutions are redundant and fixed. To solve the problems, a fast and novel scale estimation method based on kernel correlation filtering framework is proposed, which is coarse-to-fine. Considering that the peak value of the response graph is not stable, the Euclidean distance of the detection response graph and the expected output graph are used as the reliability of the peak value. The product is taken as the final comparison result. Firstly, three scale factors are used to determine the direction of scale variation, and then solve the optimum in the direction of scale variation. The proposed algorithm is experimented on 26 benchmark sequences with scale variation attribute of OTB-100, and is quantitatively and qualitatively compared with other existing advanced tracking algorithms. The results show that the proposed method can solve the scale variation problem well. The proposed method is 18.8% higher in mean distance precision and 19.6% higher in area under curve than those of the kernel correlation filter. The tracking speed is 2.5 times of the accurate scale estimation for robust visual tracking, and is 6 times of the scale adaptive kernel correlation filter tracker with feature integration.

Key words machine vision; target tracking; kernel correlation filtering; scale estimation; occlusion detection

OCIS codes 150.0155; 100.4999; 100.3008

1 引言

可视化目标跟踪是计算机视觉中的研究热点之一, 在智能交通、机器人、人机交互、无人驾驶等视觉场景中得到了广泛的应用。近年来, 目标跟踪领域的研究取得了很大的进步, 但光照变化、运动模糊、

背景混乱、遮挡、尺度变化等因素的影响使得利用单一跟踪模型很难解决目标跟踪领域存在的问题。因此, 研究者们提出了大量的目标跟踪算法, 其中平方误差的最小输出和(MOSSE)^[1]第一次展示了相关滤波应用于跟踪算法的巨大潜能, 随后核检测跟踪的循环结构(CSK)^[2]、自适应颜色属性跟踪

收稿日期: 2018-06-20; 修回日期: 2018-06-27; 录用日期: 2018-07-05

* E-mail: zhousz@fjirsm.ac.cn

(CN)^[3],核相关滤波(KCF)^[4]的提出使相关滤波跟踪算法获得了越来越多的关注。

Henriques等^[2]提出CSK来研究一种基于循环结构的稠密采样策略,该策略可采集更多的样本,并且不影响跟踪的速度,取得了很好的效果。Danelljan等^[3]提出CN,使用颜色属性扩展稠密采样相关滤波跟踪器,并采用主成分分析^[5]将原本11维的颜色属性降为2维的颜色特征,并与灰度特征融合成3维特征,改进了目标的表现特征。Henriques等^[4]提出的KCF使用方向梯度直方图(HOG)特征和核机制,对稠密采样相关滤波跟踪器进行改进,得到基于HOG特征的KCF跟踪算法,在跟踪精度和稳健性上有了较大的提高。虽然上述算法实现了精度与稳健性的大幅度提升,但是这些基于相关滤波的跟踪算法采用的是固定大小的模板,仅评估目标的位置,不能处理目标尺度的变化,而能否自适应地处理尺度变化直接关系到跟踪算法的综合性能。

在相关滤波框架下的目标跟踪研究有效解决了目标尺度问题,其中效果最好的是使用尺度金字塔,国内大多数研究也是以KCF为基础添加尺度估计机制,例如高美凤等^[6]提出尺度自适应核相关滤波目标跟踪,王鑫等^[7]提出基于多层卷积特征融合的目标尺度自适应稳健跟踪,沈秋等^[8]提出基于自适应特征选择的多尺度相关滤波跟踪,李聪等^[9]提出特征融合的尺度自适应相关滤波跟踪算法,这些研究都是通过对目标区域进行多尺度采样或者使用不同的特征表征来提高跟踪精度。同样,稳健视觉跟踪的精确尺度估计(DSST)^[10]和特征整合尺度自适应核相关滤波跟踪算法(SAMF)^[11]均采用尺度固定的尺度因子,DSST使用一个独立的尺度滤波器,尺度个数为33,在目标位置确定后,以目标的不同尺度采样作为样本训练尺度滤波器,从而求得最优目标尺度。SAMF采用7个尺度模板,与DSST不同的是,SAMF寻求位置和尺度同时最优。DSST是基于MOSSE进行改进,增加了HOG与原始特征的融合。SAMF基于KCF并在HOG特征提取时增加了颜色特征,提高了外观表征的能力。判别式尺度空间跟踪(fDSST)^[12]是DSST的加速版。利用检测方案实现视觉跟踪中的尺度和纵横比适应性(KCFDPT)^[13],把类不可知的检测建议方法与相关滤波进行整合来解决尺度问题。

上述DSST与SAMF解决尺度变化的方法大同小异,均使用尺度模版,只是使用个数和对尺度设计的方法不同,最终效果类似。虽然上述2种方法

效果很好,但是DSST在大部分情况下可以实现实时检测,而SAMF不像DSST一样借助快速傅里叶变换(FFT),每一帧循环7次来求解位置与尺度同时最优,很难实现实时检测。考虑到KCF能够快速应对各种复杂情况,而DSST与SAMF不管尺度变化与否,对每一帧都重复同样次数的计算,并且为了进一步验证仅利用检测响应图的峰值来应对目标尺度的有效性,以响应图与期望输出图的欧氏距离作为峰值的可靠程度,以两者的乘积作为最终比较结果,先使用3个尺度因子确定目标尺度变化方向,然后在尺度变化方向求解最优尺度,可大幅减少计算量。由于通常情况下,目标尺度变化不大,又考虑到遮挡等复杂情况的影响,因此通过实验可知,迭代次数设置为5是最优的方法。

为了在确定最优位置后独立地评估目标尺度,本文提出一种由粗到细的快速、新颖的快速尺度自适应核相关滤波目标跟踪(FSAKCF)算法。该方法可以嵌入基于相关滤波的跟踪算法中进行快速尺度评估。与其他先进的未处理尺度的CSK、CN、KCF进行比较,以证明本文提出的方法能够处理尺度变化;并与先进的尺度处理算法DSST、SAMF、KCFDPT、fDSST进行比较,考察各算法的中心位置精度和跟踪速度。

2 KCF

KCF跟踪器基于CSK跟踪器进行扩展,以HOG特征代替原先的灰度特征,并把只能使用单通道的灰度特征改进为可以使用多通道的HOG特征或者其他特征。KCF使用目标周围区域的循环矩阵采集正负样本,利用岭回归训练目标检测器,并成功地利用循环矩阵在傅里叶空间可对角化的性质,将矩阵的运算转化为向量的Hadamard积,即元素的点乘,大幅减少了运算量,提高了运算速度,使算法满足实时性要求。并将线性空间的岭回归通过核函数映射到非线性空间,在非线性空间通过求解一个对偶问题和某些常见的约束,同样可以使用循环矩阵傅里叶空间对角化简化计算,给出了一种将多通道数据融入该算法的途径。

KCF是一种判别式追踪方法,一般在追踪过程中训练一个目标检测器,使用目标检测器检测下一帧预测位置是否为目标,然后使用新检测结果更新训练集,进而更新目标检测器。而在训练目标检测器时,一般选取目标区域为正样本,目标的周围区域为负样本,越靠近目标的区域为正样本的可能性越大。KCF跟踪算法主要包括分类器训练、快速检测

与模型更新 3 个部分。

2.1 分类器训练

利用岭回归进行分类器训练,原因是它可以提供一个简单的封闭形式的解决方案,并可以实现接近更复杂方法的性能,比如支持向量机(SVM)。训练的目的是找到一个函数 $f(\mathbf{z}) = \boldsymbol{\omega}^T \mathbf{z}$ (其中 \mathbf{z} 为样本数据, $\boldsymbol{\omega}$ 为分类器),使样本 \mathbf{x}_i 及其回归目标 y_i 的平方差最小化,即

$$\min_{\boldsymbol{\omega}} \sum_i [f(\mathbf{x}_i) - y_i]^2 + \lambda \|\boldsymbol{\omega}\|^2, \quad (1)$$

式中: λ 为控制过拟合归一化参数(防止 $\boldsymbol{\omega}$ 矩阵过于稀疏); $\|\cdot\|$ 为 L2 范数。最小值有一个闭式^[14],即

$$\boldsymbol{\omega} = (\mathbf{X}^T \mathbf{X} + \lambda \mathbf{I})^{-1} \mathbf{X}^T \mathbf{y}, \quad (2)$$

式中: \mathbf{X} 为数据矩阵, \mathbf{X} 的每行 \mathbf{x}_i 有一个样本; \mathbf{y} 为高斯标签函数, \mathbf{y} 的每个元素是一个回归目标 y_i ; \mathbf{I} 为单位矩阵。

将线性问题的输出用核机制映射到非线性空间 $\boldsymbol{\varphi}(\mathbf{x})$ (其中 \mathbf{x} 为训练阶段的样本数据),将 $\boldsymbol{\omega}$ 表示为线性样本组合,即

$$\boldsymbol{\omega} = \sum_i \alpha_i \boldsymbol{\varphi}(\mathbf{x}_i), \quad (3)$$

式中: α_i 为样本 \mathbf{x}_i 在非线性空间中对应的分量。因此,优化的变量是 α 而不是 $\boldsymbol{\omega}$, (3) 式表示 $\boldsymbol{\omega}$ 是相对于原始空间的对偶空间。

点乘形式的算法为 $\boldsymbol{\varphi}^T(\mathbf{x}) \cdot \boldsymbol{\varphi}(\mathbf{x}') = k(\mathbf{x}, \mathbf{x}')$, 其中 \mathbf{x}' 为检测阶段的样本数据, $k(\mathbf{x}, \mathbf{x}')$ 为两个样本的核相关函数。利用核函数计算(比如高斯核函数)所有样本对的点乘通常存储在 $n \times n$ 型核矩阵 \mathbf{K} 中,即

$$\mathbf{K}_{ij} = k(\mathbf{x}_i, \mathbf{x}_j), \quad (4)$$

式中: \mathbf{K}_{ij} 为样本 i 与样本 j 的核相关矩阵。由文献[14]的方法可得

$$\boldsymbol{\alpha} = (\mathbf{K} + \lambda \mathbf{I})^{-1} \mathbf{y}, \quad (5)$$

式中: $\boldsymbol{\alpha}$ 为系数 α_i 的向量,展示了在对偶空间中的解决方案。将(5)式转到傅里叶域进行求解,有

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

式中: $\hat{\alpha}$ 为当前帧目标位置的分类器参数; \hat{y} 为 y 的快速傅里叶变换。 $\hat{k}(\mathbf{x}, \mathbf{x}')$ 为 $k(\mathbf{x}, \mathbf{x}')$ 的傅里叶变换。由高斯核 $k(\mathbf{x}, \mathbf{x}') = \exp\left(-\frac{1}{\delta^2} \|\mathbf{x} - \mathbf{x}'\|^2\right)$ (其中 δ 为高斯函数的核带宽),得到

$$k^{xx'} = \exp\left\{-\frac{1}{\delta^2} [\|\mathbf{x}\|^2 + \|\mathbf{x}'\|^2 - 2\mathcal{F}^{-1}(\hat{x}^* \odot \hat{x}')] \right\}, \quad (7)$$

式中: \hat{x} 为 x 的傅里叶变换; \hat{x}^* 为 \hat{x} 的共轭; \mathcal{F}^{-1} 为傅里叶逆变换; \odot 为点乘。

2.2 快速检测

采用 2.1 节中训练的分类器检测下一帧目标的位置,即采集搜索区域内所有测试样本,获得分类器的响应输出,响应输出值最大的位置为下一帧目标所在的位置。对于给定的单个测试样本 \mathbf{z} , 分类器的响应输出为

$$f(\mathbf{z}) = \boldsymbol{\omega}^T \mathbf{z} = \sum_i a_i k(\mathbf{z}, \mathbf{x}_i). \quad (8)$$

对所有的候选块计算回归函数。注意到 $f(\mathbf{z})$ 是一个向量,包含所有 \mathbf{z} 的循环位移输出,即整个检测响应。将其对角化可得

$$f(\mathbf{z}) = \mathcal{F}^{-1}(\hat{k}^{xz} \odot \hat{\alpha}), \quad (9)$$

式中: \hat{k}^{xz} 为样本 x 与样本 z 的核相关傅里叶变换。

直观上来看,计算 $f(\mathbf{z})$ 所有位置上的值可以看作核值 k^{xz} 上的空间滤波操作。每个 $f(\mathbf{z})$ 是一个来自 k^{xz} 邻近核值并由学习系数 α 加权的线性组合。这是一个滤波操作,因此它可以更有效地在傅里叶域用公式表示。

2.3 模型更新

在目标跟踪过程中,目标经常会因环境和自身的变化而受到影响,需要及时更新目标表观模型来应对目标的变化。模型更新主要包括预测位置的目标表观模型 \hat{x} 和分类器参数 $\hat{\alpha}$ 2 个部分,一般采用线性内插法来更新模型参数,即

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

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

式中: t 为当前帧的序号; η 为学习率。当前帧目标位置的分类器参数 $\hat{\alpha}$ 由(6)式得出。

3 快速尺度自适应

3.1 快速尺度评估

针对现有大多数跟踪算法无法解决尺度变化问题和尺度解决方案存在冗余、固定的问题,提出一种快速尺度评估方法。该方法采用由粗到细的策略,粗略地确定目标尺度变化方向,以在该方向上迭代求解的响应图最大值作为最优尺度,从而实现快速尺度估计。为了进一步验证仅利用检测响应图的峰值应对目标尺度的有效性,以响应图与期望输出图的欧氏距离作为峰值的可靠程度,即

$$E_{R'_s} = \exp(-\|\mathbf{R}'_s - G\|^2), \quad (12)$$

式中: R'_s 为 t 帧尺度因子为 s 时的响应图; $E_{R'_s}$ 为误差权重, 表征响应图峰值的可靠程度; G 为高斯期望输出标签。最终比较结果为

$$T'_s = E_{R'_s} \max_t \{R'_s\}。 \quad (13)$$

快速尺度评估算法步骤如下。

1) 输入图像 I_t , 新的位置 P_t 和尺度 S_{t-1} , 模型大小 model_sz , 高斯标签 G , 模型参数 \hat{x}_t, \hat{a}_t , 误差权重与响应图峰值乘积 T'_c 。

2) 输出尺度因子 S_{factor} 。

①根据 P_t 和 S_{t-1} , 按尺度因子 0.985 和 1.015 分别提取尺度样本 z_{scale} 并缩放到 model_sz 大小。

②将 $z_{\text{scale}}, \hat{x}_t$ 和 \hat{a}_t 代入(7)式和(9)式, 求得响应图 R'_s , 将 R'_s 和 G 代入(12)式和(13)式, 分别求得误差权重与响应图峰值乘积 T'_i 和 T'_r 。

③比较 T'_i, T'_c 和 T'_r 的大小:

a) 如果 T'_c 最大, 则 $S_{\text{factor}} = 1$ 。

b) 如果 T'_i 最大, 则梯度 $n_{\text{step}+1} = n_{\text{step}} - 0.015$, $n_{\text{step}} = 0, N_{\text{iter}} = 5, T'_{\text{tmp}} = T'_i$; 执行步骤①和步骤②, 求得误差权重与响应图峰值乘积并与 T'_{tmp} 比较; 如果 T'_{tmp} 最大, 循环终止, 则循环执行步骤⑤, $S_{\text{factor}} = 0.985 + n_{\text{step}} + 0.015$ 。

c) 如果 T'_r 最大, 则 $n_{\text{step}+1} = n_{\text{step}} + 0.015$, $n_{\text{step}} = 0, N_{\text{iter}} = 5, T'_{\text{tmp}} = T'_r$; 执行步骤①和步骤②, 求得误差权重与响应图峰值乘积并与 T'_{tmp} 比较; 如果 T'_{tmp} 最大, 循环终止, 则循环执行步骤⑥, $S_{\text{factor}} = 1.015 + n_{\text{step}} - 0.015$ 。

3.2 快速尺度自适应目标跟踪算法

KCF 算法中的目标跟踪框固定不变, 当目标逐渐变大时, 只能捕捉到目标的某一部分, 当目标逐渐变小时, 跟踪的目标区域又易于掺杂干扰的背景信息。为了解决这一问题, 在原始算法的跟踪过程中加入 3.1 节中提出的尺度估计的方法。

快速尺度自适应目标跟踪算法步骤如下。

1) 输入图像 I_t , 位置 P_{t-1} , 尺度 S_{t-1} , 模型大小 model_sz , 高斯标签 G , 模型参数 $\hat{x}_{t-1}, \hat{a}_{t-1}$ 。

2) 输出位置 P_t , 尺度 S_t , 模型参数 \hat{x}_t, \hat{a}_t 。

位置评估:

①根据 P_{t-1} 和 S_{t-1} , 从 I_t 中提取样本 z 并缩放到 model_sz 大小。

②将 z, \hat{x}_{t-1} 和 \hat{a}_{t-1} 代入(7)式和(9)式, 求得响应图 R'_s , 将 R'_s 和 G 代入(12)式和(13)式, 求得误差权重与响应图峰值乘积 T'_c 。

③ P_t 为响应图最大值的位置。

尺度评估:

①参照 3.1 节, 获得 S'_{factor} 。

② $S_t = S_{t-1} S'_{\text{factor}}$ 。

模型更新:

①根据 P_t 和 S_t , 从 I_t 中提取样本 z_{scale} 并缩放到 model_sz 大小。

②根据(10)式和(11)式, 更新 \hat{x}_t 和 \hat{a}_t 。

4 实验

在 KCF 跟踪算法中嵌入所提出的快速尺度估计方法, 以解决目标尺度问题并极大地提高算法性能, 进一步与 DSST、SAMF、KCFDPT 和 fDSST 尺度估计算法进行比较, 并与其他先进的跟踪算法进行定性定量比较。

4.1 算法参数和实验配置

本文提出的方法仅使用了 HOG 特征, 特征的单元大小为 4×4 , 方向梯度设置为 9。目标填充为 1.5, 归一化参数为 10^{-4} , 期望输出标准差为 0.1, 高斯函数核大小为 0.5, 学习率设置为 0.02。

从评估基准 OTB-100^[15] 中挑选出 26 个包含尺度变化属性的基准序列, 序列属性如表 1 所示, 其中 SV 为尺度变化, MB 为运动模糊, FM 为快速运动, IPR 为平面内旋转, OPR 为平面外旋转, IV 为光照变化, OCC 为遮挡, OV 视野外, BC 为背景混乱, LR 为低分辨率, DEF 为变形。实验的软件平台为 MATLAB R2016b, 硬件平台为 Intel(R) Core(TM) i7-4790 CPU@3.60 GHz, 8 GB 内存的台式机。

4.2 评估方法

本文提出方法的性能通过文献[16]中的协议进行定量验证。提出方法的性能包括距离精度(DP)、中心位置误差(CLE)和重叠精度(OP)。第一度量 CLE 是基准和评估的目标位置的平均欧氏距离。第二度量 DP 是 CLE 小于某阈值序列中相对数量的帧数, 文献[16]中选择的阈值为 20 pixel。第三度量 OP 是边框重叠率超过某个 $t \in [0, 1]$ 的阈值, 本文中阈值为 0.5。

在精度图中根据某范围内的阈值来绘制平均 DP, 给出每种方法 20 pixel 上的平均 DP 分数。在成功率图中绘制平均 OP, 给出曲线下面积(AUC)。精度图和成功率图提供了 26 个序列的平均结果。最后, 给出本文提出的方法与现有其他先进跟踪算法的定量分析。

4.3 与其他先进跟踪算法的比较

为了评估本文提出的快速尺度估计方法的性能增益, 在 26 个序列上运行 9 种跟踪算法: CSK、CN、

表 1 26 个跟踪序列对应的帧数和序列属性

Table 1 Frame numbers and sequence attributes of

26 tracking sequences

Sequence	Frame number	Attribute
Boy	602	SV, MB, FM, IPR, OPR
Box	1161	IV, SV, OCC, MB, IPR, OPR, OV, BC, LR
David	471	IV, SV, OCC, DEF, MB, IPR, OPR
Car4	659	IV, SV
ClifBar	472	SV, OCC, MB, FM, IPR, OV, BC
CarScale	252	SV, OCC, FM, IPR, OPR
Crossing	120	SV, DEF, FM, OPR, BC
Dancer	225	SV, DEF, IPR, OPR
Doll	3872	IV, SV, OCC, IPR, OPR
Dog1	1350	SV, IPR, OPR
Dudek	1145	SV, OCC, DEF, FM, IPR, OPR, OV, BC
FleetFace	707	SV, DEF, MB, FM, IPR, OPR
Freeman1	326	SV, IPR, OPR
Girl	500	SV, OCC, IPR, OPR
Human8	128	IV, SV, DEF
RedTeam	1918	SV, OCC, IPR, OPR, LR
Singer2	366	IV, DEF, IPR, OPR, BC
Skating 1	400	IV, SV, OCC, DEF, OPR, BC
Singer1	351	IV, SV, OCC, OPR
Surfer	376	SV, FM, IPR, OPR, LR
Twinnings	472	SV, OPR
Toy	271	SV, FM, IPR, OPR
Vase	271	SV, FM, IPR
Walking	569	SV, OCC, DEF
Trellis	120	IV, SV, IPR, OPR, BC
Walking2	500	SV, OCC, LR

表 2 9 种跟踪算法的特点

Table 2 Characteristics of 9 tracking algorithms

Tracking algorithm	Characteristic	Scale adaptation
CSK	gray	no
CN	gray, color names	no
KCF	HOG	no
DSST	gray, HOG	yes
SAMF	gray, HOG, color names	yes
KCFDPT	HOG, color names	yes
fDSST	gray, HOG	yes
FSAKCF	HOG	yes
FSAKCF1	HOG	yes

图中的 OPE、SRE 和 TRE 分别提高了 19.6%、18.6%和 19.1%，所提出的基于 KCF 尺度估计方法有效地解决了 KCF 未处理尺度的问题。TRE 的精度均超过 DSST、KCFDPT、fDSST。图 2 所示为 FSAKCF 与 KCF 部分跟踪效果。由图 2 可知，与 DSST 与 SAMF 一样每帧计算同样的尺度模板不同，本文所提出的算法对于尺度不变化和变化幅度不大的模板，其速度接近 KCF 的速度，而对于采用固定尺度的 KCF，当目标变大时，不能很好地表征实际目标；当目标变小时，固定尺度的 KCF 会学习到更多的背景信息，很容易造成漂移。而本文提出的基于 KCF 的尺度估计方法可实时更新尺度，因此在精度和重叠率上都超过 KCF，并且提出算法的速度达到实时，是 DSST 的 2.5 倍，是 SAMF 的 6 倍。

5 结 论

提出了一种由粗到细快速解决目标尺度变化的方法。提出的尺度估计方法可以嵌入其他基于相关滤波框架的跟踪算法。与现有其他先进的 DSST 和 SAMF 这 2 种代表性尺度处理算法相比，本文提出的方法不仅解决了目标尺度变化问题，从而提高了跟踪性能，而且实时跟踪速度是 DSST 的 2.5 倍，是 SAMF 的 6 倍，解决了添加尺度处理机制导致跟踪不实时的问题。实验结果表明，提出的方法成功处理了目标尺度的变化，与 KCF 相比，平均位置误差和重叠率大幅提升。TRE 的精度均超过 DSST、KCFDPT、fDSST。

本文主要研究目标跟踪过程中目标尺度对跟踪性能的影响，虽然本文提出的方法能够有效应对部分遮挡和短时间遮挡，但对于全部遮挡和长时间遮挡情况下没有进行处理。在未来的研究中将更多地研究目标严重遮挡的情况。

KCF、DSST、SAMF、KCFDPT、fDSST，以及本文提出的方法 FSAKCF（仅以响应图的最大值作为比较标准）与 FSAKCF1（以误差权重与响应图峰值乘积作为比较标准）。所有方法都基于相关滤波框架。表 2 所示为这 9 种跟踪算法的特点。由表 2 可知，虽然这些跟踪算法是基于同一框架，但跟踪性能非常不同。图 1 所示为一次通过的评估（OPE）、空间稳健性评估（SRE）和时间稳健性评估（TRE），其中每种方法在 20 pixel 上的平均 DP 分数在精度图中给出，成功率图中给出了每种算法的 AUC 分数。由图 1 可知，与 KCF 相比，精度图中的 OPE、SRE 和 TRE 分别提高了 18.8%、16.9%和 17.3%，成功率

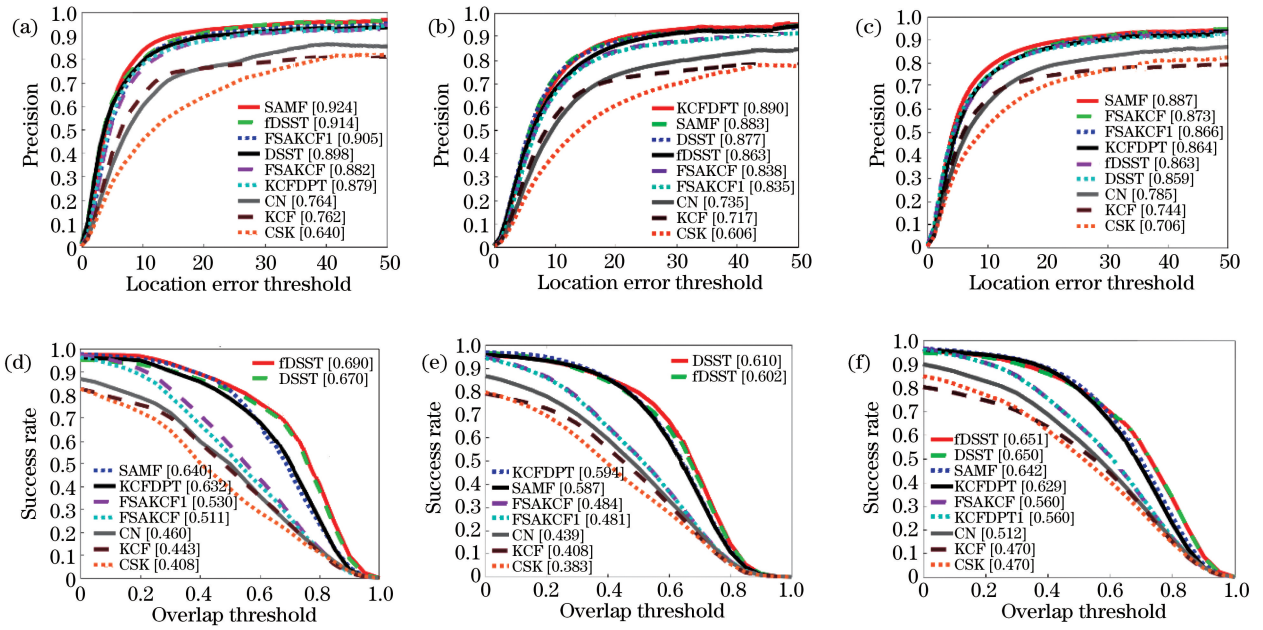


图 1 26 个序列的精度和成功率。(a) OPE 的精度;(b) SRE 的精度;(c) TRE 的精度;(d) OPE 的成功率;(e) SRE 的成功率;(f) TRE 的成功率

Fig. 1 Precision and success rate of 26 sequences. (a) Precision of OPE; (b) precision of SRE; (c) precision of TRE; (d) success rate of OPE; (e) success rate of SRE; (f) success rate of TRE




图 2 KCF 与 FSAKCF 在 David、CarScale、Dog1 序列上的跟踪效果。(a) David, 跟踪帧数为 11;(b) David, 跟踪帧数为 149;(c) David, 跟踪帧数为 462;(d) CarScale, 跟踪帧数为 11;(e) CarScale, 跟踪帧数为 167;(f) CarScale, 跟踪帧数为 242;(g) Dog1, 跟踪帧数为 11;(h) Dog1, 跟踪帧数为 733;(i) Dog1, 跟踪帧数为 1290

Fig. 2 Tracking effect of KCF and FSAKCF on sequences of David, CarScale, and Dog1. (a) David, tracking frame number of 11; (b) David, tracking frame number of 149; (c) David, tracking frame number of 462; (d) CarScale, tracking frame number of 11; (e) CarScale, tracking frame number of 167; (f) CarScale, tracking frame number of 242; (g) Dog1, tracking frame number of 11; (h) Dog1, tracking frame number of 733; (i) Dog1, tracking frame number of 1290

参 考 文 献

[1] Bolme D S, Beveridge J R, Draper B A, *et al.* Visual object tracking using adaptive correlation filters[C].

IEEE Conference on Computer Vision and Pattern Recognition, 2010: 2544-2550.

[2] Henriques J F, Caseiro R, Martins P, *et al.* Exploiting the circulant structure of tracking-by-

- detection with kernels[C]. European Conference on Computer Vision, 2012: 702-715.
- [3] Danelljan M, Khan F S, Felsberg M, *et al.* Adaptive color attributes for real-time visual tracking [C]. IEEE Conference on Computer Vision and Pattern Recognition, 2014: 1090-1097.
- [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, 2014, 37(3): 583-596.
- [5] Jolliffe I T. Principal component analysis[J]. Journal of Applied Statistics, 1986, 87: 41-64.
- [6] Gao M F, Zhang X X. Scale adaptive kernel correlation filtering for target tracking[J]. Laser & Optoelectronics Progress, 2018, 55(4): 041501.
高美凤, 张晓玄. 尺度自适应核相关滤波目标跟踪[J]. 激光与光电子学进展, 2018, 55(4): 041501.
- [7] Wang X, Hou Z Q, Yu W S, *et al.* Target scale adaptive robust tracking based on fusion of multilayer convolutional features[J]. Acta Optica Sinica, 2017, 37(11): 1115005.
王鑫, 侯志强, 余旺盛, 等. 基于多层卷积特征融合的目标尺度自适应稳健跟踪[J]. 光学学报, 2017, 37(11): 1115005.
- [8] Shen Q, Yan X L, Liu L F, *et al.* Multi-scale correlation filtering tracker based on adaptive feature selection [J]. Acta Optica Sinica, 2017, 37(5): 0515001.
沈秋, 严小乐, 刘霖枫, 等. 基于自适应特征选择的多尺度相关滤波跟踪[J]. 光学学报, 2017, 37(5): 0515001.
- [9] Li C, Lu C Y, Zhao X, *et al.* Scale adaptive correlation filtering tracing algorithm based on feature fusion [J]. Acta Optica Sinica, 2018, 38(5): 0515001.
李聪, 鹿存跃, 赵珣, 等. 特征融合的尺度自适应相关滤波跟踪算法[J]. 光学学报, 2018, 38(5): 0515001.
- [10] Danelljan M, Häger G, Khan F S. Accurate scale estimation for robust visual tracking [C] // Proceedings of the British Machine Vision Conference, 2014: 65.
- [11] Li Y, Zhu J K. A scale adaptive kernel correlation filter tracker with feature integration[C]. European Conference on Computer Vision, 2014: 254-265.
- [12] Danelljan M, Häger G, Khan F S, *et al.* Discriminative scale space tracking [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(8): 1561-1575.
- [13] Huang D F, Luo L, Wen M, *et al.* Enable scale and aspect ratio adaptability in visual tracking with detection proposals [C] // Proceedings of the British Machine Vision Conference, 2015: 185.
- [14] Rifkin R, Yeo G, Poggio T. Regularized least-squares classification[J]. Acta Electronica Sinica, 2003, 190(1): 93-104.
- [15] Wu Y, Lim J, Yang M H. Object tracking benchmark [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37(9): 1834-1848.
- [16] Wu Y, Lim J, Yang M H. Online object tracking: a benchmark [C]. IEEE Conference on Computer Vision and Pattern Recognition, 2013: 2411-2418.