

# 多尺度估计的核相关滤波器目标跟踪方法

潘振福 朱永利

华北电力大学计算机系, 河北 保定 071003

**摘要** 视觉目标跟踪在视频智能监控和机器人视觉导航等领域有着广泛的应用。针对传统的核相关滤波器(KCF)跟踪方法缺乏目标尺度估计,对目标尺度显著变化的视频序列表现效果很差的问题,提出了一种多尺度估计的改进方法。该方法借鉴了分类尺度空间跟踪器(DSST)采用尺度金字塔相关滤波器做尺度估计的手段,将灰度图像金字塔映射到一维特征向量,然后用该向量作为尺度相关滤波器的输入,得到最高响应值后估计出目标尺度。使用 benchmark 数据集对改进的算法做了测试实验,并和其他已有的若干视觉跟踪方法进行了对比实验,验证了本算法的高效性。本算法在目标尺度变化、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** 机器视觉; 目标跟踪; 相关滤波器; 尺度空间估计

**中图分类号** TP391 **文献标识码** A

**doi:** 10.3788/LOP53.101501

## Kernelized Correlation Filters Object Tracking Method with Multi-Scale Estimation

Pan Zhenfu Zhu Yongli

*Department of Computer Science, North China Electric Power University, Baoding, Hebei 071003, China*

**Abstract** Visual object tracking is widely used in various fields such as video intelligent monitoring and visual navigation of robot. Aiming at the problem that traditional kernelized correlation filter (KCF) tracking method is lack of target scale estimation, and performs poor in video sequence whose target scale changes observably, a multi-scale estimation modified method is proposed. This method uses reference for discriminative spacial scale tracker (DSST) to make scale estimation by adopting the scale pyramid correlation filter. The gray image pyramid is mapped to a one dimensional feature vector, and then this vector is used as input of scale correlation filter. The target scale is estimated from the highest response values. This modified method is tested on benchmark data set, and it is compared with the other current visual tracking methods. The results verify the high efficiency of the proposed algorithm. The proposed algorithm has strong adaptability under complex conditions, such as object scale change, illumination variation, posture change, partial sheltering, rotating and rapid movement.

**Key words** machine vision; target tracking; correlation filter; scale space estimation

**OCIS codes** 070.4550; 150.0155; 100.4999

## 1 引言

视觉目标跟踪近年来受到了人们的高度关注,成为了计算机视觉中最具有吸引力的研究课题之一,它被广泛应用于运动分析、行为识别、医学成像、监控及人机交互等方面<sup>[1-2]</sup>。尽管近年来目标跟踪技术取得了相当大的进展,然而众多因素影响跟踪算法的性能,包括光照变化、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<sup>[2]</sup>。相关滤波器分类方法可以

**收稿日期:** 2016-06-06; **收到修改稿日期:** 2016-06-16; **网络出版日期:** 2016-09-20

**基金项目:** 河北省自然科学基金(F2014502069)

**作者简介:** 潘振福(1989—),男,硕士研究生,主要从事计算机视觉方面的研究。E-mail: panzhenfu20@126.com

**导师简介:** 朱永利(1963—),男,博士,教授,博士生导师,主要从事人工智能与知识工程方面的研究。

E-mail: yonglipw@163.com

使用快速傅里叶变换(FFT)在频域中有效地计算<sup>[3-5]</sup>,由于其计算的高效性,近年来有许多研究者把相关滤波器应用到目标跟踪领域中。在视觉目标跟踪 2014 年挑战结果<sup>[4]</sup>中显示,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,相比于其他框架的跟踪算法<sup>[5-8]</sup>,具有更优秀的跟踪性能。例如,Bolme 等<sup>[6]</sup>提出一种在灰度图像上学习一个最小输出平方误差和滤波器(MOSSE)的跟踪方法,对目标外观变化有较强的适应性;Danelljan 等<sup>[7]</sup>提出了一种自适应颜色属性跟踪方法,将颜色特征属性集成到循环结构核目标跟踪(CSK)跟踪器<sup>[8]</sup>中,并通过把多维特征映射到高斯核空间学习的自适应相关滤波器;Henriques 等<sup>[9]</sup>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(KCF)及双相关滤波器(DCF)跟踪器。大多数检测跟踪方法,如 CSK、MOSSE、KCF 等,仅局限于目标位置估算,应用在有显著尺度变化的视频序列中的效果较差。

本文针对传统的 KCF 跟踪方法缺乏尺度估计的缺陷,提出了一个具有目标多尺度估计的视觉目标跟踪方法,借鉴分类尺度空间跟踪器(DSST)<sup>[10]</sup>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。

## 2 KCF 跟踪算法

在 KCF 跟踪算法中,以核岭回归分类器作为核心,构建循环样本矩阵来训练该分类器,对样本进行巧妙地变换使训练数据矩阵具有循环特性,就可以通过离散傅里叶变换(DFT)对角化,这样便能减少几个数量级的存储与计算,从而达到对目标快速有效检测跟踪的目的。

### 2.1 核岭回归分类器

KCF 跟踪算法采用核岭回归分类器,即利用样本找到一个对回归目标最小平方误差的函数  $f(\mathbf{z}) = \mathbf{w}^T \boldsymbol{\varphi}(\mathbf{z})$ ,其中  $\mathbf{w}$  为线性函数的系数向量。设从样本空间到希尔伯特特征空间的非线性变换为  $\mathbf{x}_i \rightarrow \boldsymbol{\varphi}(\mathbf{x}_i)$ ,定义核函数为  $\kappa(\mathbf{x}, \mathbf{x}') = \langle \boldsymbol{\varphi}(\mathbf{x}), \boldsymbol{\varphi}(\mathbf{x}') \rangle$ ,则优化问题的最优解可以表示为

$$\min_{\mathbf{w}} \sum_i (\langle \mathbf{w}, \boldsymbol{\varphi}(\mathbf{x}_i) \rangle - y_i)^2 + \lambda \|\mathbf{w}\|^2, \quad (1)$$

式中  $\mathbf{x}_i$  为样本,  $y_i$  为期望输出,  $\lambda$  为一个固定的正则化参数。根据文献[11]其最优解为样本的线性组合

$$\mathbf{w} = \sum_i \alpha_i \boldsymbol{\varphi}(\mathbf{x}_i). \quad (2)$$

由(2)式可知,需要优化的是系数向量  $\boldsymbol{\alpha}$ ,而不是  $\mathbf{w}$ 。判别函数响应可以表示为

$$f(\mathbf{z}) = \mathbf{w}^T \boldsymbol{\varphi}(\mathbf{z}) = \sum_i \alpha_i \boldsymbol{\varphi}(\mathbf{x}_i) \boldsymbol{\varphi}(\mathbf{z}_i) = \sum_i \alpha_i \kappa(\mathbf{x}_i, \mathbf{z}_i), \quad (3)$$

在非线性希尔伯特特征空间的点乘运算可以用核函数运算,  $\boldsymbol{\varphi}^T(\mathbf{x}) \boldsymbol{\varphi}(\mathbf{x}') = \kappa(\mathbf{x}, \mathbf{x}')$ ,两个样本矩阵之间的在希尔伯特特征空间的点乘运算结果是一个  $n \times n$  的矩阵,称核矩阵  $\mathbf{K}$ ,其元素为

$$K_{ij} = \kappa(\mathbf{x}_i, \mathbf{x}'_j), \quad (4)$$

核岭回归问题的解由文献[13]给出:

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

式中  $\mathbf{I}$  为单位矩阵,  $\mathbf{y}$  是期望输出。

### 2.2 循环矩阵

对样本  $\mathbf{x}$  进行移位变换,可以获得循环矩阵  $\mathbf{X}$ ,即

$$\mathbf{X} = \mathbf{C}(\mathbf{x}) = \begin{bmatrix} x_1 & x_2 & x_3 & \cdots & x_n \\ x_n & x_1 & x_2 & \cdots & x_{n-1} \\ x_{n-1} & x_n & x_1 & \cdots & x_{n-2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ x_2 & x_3 & x_4 & \cdots & x_1 \end{bmatrix}, \quad (6)$$

矩阵  $\mathbf{X}$  完全由指定的样本向量  $\mathbf{x}$  (第一行)循环移位生成。无论生成向量  $\mathbf{x}$  为何值,所有循环矩阵都能被 DFT 矩阵对角化<sup>[13]</sup>。也就是

$$\mathbf{X} = \mathbf{F} \text{diag}(\hat{\mathbf{x}}) \mathbf{F}^H, \quad (7)$$

式中  $\mathbf{F}$  是一个与  $\mathbf{x}$  无关的常量矩阵,用来计算 DFT,如  $\mathbf{F}(\mathbf{z}) = \sqrt{n}\mathbf{F}\mathbf{z}$ ,  $\mathbf{F}^H$  是  $\mathbf{F}$  的共轭转置,而  $\hat{\mathbf{x}}$  表示生成向量  $\mathbf{x}$  的 DFT,  $\hat{\mathbf{x}} = \mathbf{F}(\mathbf{x})$ 。下文中都用  $\hat{\cdot}$  来表示一个向量的傅里叶变换。

### 2.3 目标快速检测

根据文献[11]提出的定理 1,如果核函数  $\kappa(\mathbf{x}, \mathbf{x}')$  是酉不变的,则有核矩阵  $\mathbf{K}$  为循环矩阵。因此(5)式可根据循环矩阵的特性得到频域下的解

$$\hat{\boldsymbol{\alpha}} = \frac{\hat{\mathbf{y}}}{\hat{\mathbf{k}} + \lambda}, \quad (8)$$

$\mathbf{K} = C(\mathbf{k})$ ,  $\mathbf{k}$  的元素  $k_i = \kappa(\mathbf{x}, \mathbf{x}_i)$ 。

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

$$\mathbf{K}^z = C(\mathbf{k}^{xz}), \quad (9)$$

式中  $\mathbf{k}^{xz}$  是前面定义的  $\mathbf{x}$  与  $\mathbf{z}$  的核相关运算。可以把回归函数表示成

$$\mathbf{f}(\mathbf{z}) = \begin{bmatrix} \sum_i^n \alpha_i \kappa(\mathbf{x}_i, \mathbf{z}_1) \\ \sum_i^n \alpha_i \kappa(\mathbf{x}_i, \mathbf{z}_2) \\ \sum_i^n \alpha_i \kappa(\mathbf{x}_i, \mathbf{z}_3) \\ \dots \\ \sum_i^n \alpha_i \kappa(\mathbf{x}_i, \mathbf{z}_m) \end{bmatrix} = (\mathbf{K}^{xz})^T \boldsymbol{\alpha}, \quad (10)$$

式中  $\mathbf{x}$  为训练样本,  $\mathbf{x}_i$  为样本  $\mathbf{x}$  的第  $i$  次循环移位向量,  $\mathbf{z}$  为测试样本,  $\mathbf{z}_j$  为样本  $\mathbf{z}$  的第  $j$  次循环移位向量,  $m$  为  $\mathbf{z}$  的元素个数。

注意到  $\mathbf{f}(\mathbf{z})$  是一个矩阵,为其元素  $\mathbf{z}$  向量的所有移位变换形式的输出响应,为了更有效率地计算(10)式,得到对角化后的等式

$$\hat{\mathbf{f}}(\mathbf{z}) = \hat{\mathbf{k}}^{xz} \cdot \hat{\boldsymbol{\alpha}}, \quad (11)$$

式中  $\cdot$  为矩阵点乘运算,  $\mathbf{z}$  是预测包含目标的搜索窗口图像块,从中检测目标的位置,  $\mathbf{x}$  为从以前帧中学习获得的目标模型。对(11)式进行 DFT 逆运算,就得出检测样本  $\mathbf{z}$  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  $\hat{\boldsymbol{\alpha}}$  和  $\hat{\mathbf{x}}$  为

$$\hat{\boldsymbol{\alpha}}_t = (1 - \eta) \hat{\boldsymbol{\alpha}}_{t-1} + \eta \hat{\boldsymbol{\alpha}}, \quad (12)$$

$$\hat{\mathbf{x}}_t = (1 - \eta) \hat{\mathbf{x}}_{t-1} + \eta \hat{\mathbf{x}}, \quad (13)$$

式中  $\eta$  为学习因子;  $\hat{\boldsymbol{\alpha}}_t$ 、 $\hat{\boldsymbol{\alpha}}_{t-1}$  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  $\hat{\boldsymbol{\alpha}}$ ;  $\hat{\mathbf{x}}_t$ 、 $\hat{\mathbf{x}}_{t-1}$  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  $\hat{\mathbf{x}}$ 。

## 3 KCF 跟踪方法多尺度改进

传统的 KCF 跟踪方法始终用固定尺度的矩形框去搜寻下一帧中的目标,即(13)式中的目标匹配模型  $\mathbf{x}$  是一个固定尺寸的矩阵,不能很好地适应目标尺度发生变化的目标跟踪情况。而且将尺度估计纳入一个跟踪器中是需要很高的计算代价的,会明显降低算法的运算效率。而在理想情况下,一个精确的尺度估算方法应该是健壮的,而且具有较高的计算效率。为实现这一目标,提出一个在线学习且独立于位置的滤波器,实现快速尺度估算的方法。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。

### 3.1 特征金字塔

在传统的 KCF 跟踪方法已估算出目标位置的框架下,在该位置上面提取样本的  $s$  层主成分分析 (PCA)-HOG 特征金字塔。用  $P \times R$  表示当前帧中的目标大小,  $s$  表示尺度大小。对每个  $n$  提取以目标为中心大小为  $a^n P \times a^n R$  的图像块  $J_n$ ,  $a$  表示各个特征层之间的尺度因子,  $n$  的取值为

$$n \in \left\{ \left[ -\frac{s-1}{2} \right], \dots, \left[ \frac{s-1}{2} \right] \right\}. \quad (14)$$

### 3.2 一维分类相关滤波器

DSST 尺度估计的尺度金字塔相关滤波方法,能够解决尺度匹配的问题,但是 DSST 方法直接把尺度图像金字塔作为核岭回归相关滤波器的输入,运算效率不高。在文献[11]中 Henriques 等提出 KCF 算法的同时证明了建立循环数据结构后,再采用核岭回归分类相关滤波器,运算速度可以得到明显提升。估算目标尺度,需要采用一维尺度相关滤波器。

在三维数据的灰度图像尺度金字塔输出一个坐标值(第  $n$  层),不能像位置相关滤波器那样直接从一维滤波器扩展到二维灰度图像那么简单,相关运算响应输出就是坐标信息。如图 1 所示,建立  $s$  层尺度图像金字塔,再采用一维的特征映射表示尺度图像金字塔信号,如图 2 所示。




图 1  $s$  层尺度金字塔

Fig. 1 Scale pyramid of  $s$  layers

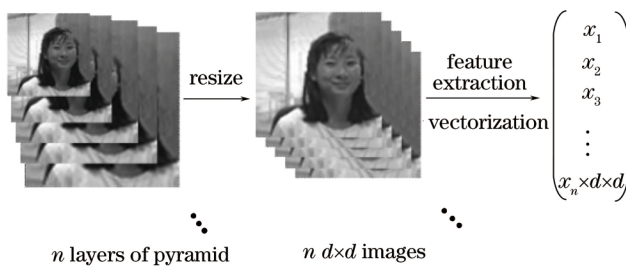


图 2 一维特征映射表示尺度金字塔图像

Fig. 2 Scale pyramid images expressed by one dimensional feature mapping

使用双线性内插值法对灰度图像金字塔进行缩放,调整到同样尺寸,再进行 PCA-HOG 特征提取,构建成一个三维矩阵,然后展开成一个一维向量  $\mathbf{X}$ ,作为一维尺度相关滤波器的输入向量。使用一维高斯函数作为相应所需的相关输出  $g$ ,然后利用(9)式计算该特征金字塔相关响应向量  $\mathbf{Y}$ ,在向量  $\mathbf{Y}$  得到最高相关响应值  $y_{\max}$  与  $y_{\max}$  在向量  $\mathbf{Y}$  中的索引  $i$ 。估算出的最佳目标尺度索引为

$$q = \left[ \frac{i}{d \times d} \right], \quad (15)$$

式中  $q$  取一个整数,对应于(14)式集合中  $n$  的索引值,从而估算出目标尺度  $n$ 。同样地,采用(12)式在线更新尺度相关滤波器,采用(13)式在线学习匹配模板。

## 4 性能评估方法

定量地分析所提算法的精度和成功率。此外,从时间稳健性和空间稳健性两个方面评估本跟踪算法的稳健性<sup>[14]</sup>。精度: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。然后用对所有的帧序列平均中心位置误差来总结算法对该序列的整体性能。然而,当追踪失去目标,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<sup>[15]</sup>。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。一般采用阈值为 20 pixel。

成功率:另一个评估指标是边界框重叠率,即对跟踪边界框  $r_t$  和人工标注真实边界框  $r_a$ ,成功率定义为  $S = \frac{|r_t \cap r_a|}{|r_t \cup r_a|}$ ,式中  $\cap$ 、 $\cup$  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  $S$ ,如果  $S$  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。

稳健性评估:追踪器传统的评估方法是运行从人工标注初始化的第一帧开始测试序列以及测量其平均精度或成功率,称为一遍过评估(OPE)。然而一个追踪算法可能对初始化很敏感,不同的开始帧可能使得算法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稳健性,通过扰动初始化时间(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稳健评估(TRE)和空间稳健性评估(SRE)。

时间稳健性评估:从不同的帧数位置作为初始化第一帧,追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评估数据统计,总体统计数据评估算法稳健性。

空间稳健性评估: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。使用 8 空间变化,包括 4 个中心移位和 4 个角移位,和 4 个尺度变化。空间变化目标边框移位 10%,尺度变化因子为 0.8、0.9、1.1 和 1.2。因此,每个图像序列进行 12 组测试,统计数据评估跟踪方法的性能。

## 5 实验与分析

为了验证本算法的有效性,对 benchmark 数据集中富有挑战性的 50 组视频图像序列在时间稳健性与空间稳健性评估方法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,比如 DSST[在视觉目标追踪(VOT2014)挑战结果位列第一]KCF、自适应结构局部稀疏外观模型跟踪器(ASLA)<sup>[16]</sup>、CSK 跟踪算法进行了对比。

### 5.1 实验环境及参数

实验平台为 Matlab R2014b,所有的实验均在 Intel Core i3 M390 CPU、主频 2.67 GHz、4 GB 内存配置的电脑上完成。在实验中,传统的 KCF 算法的参数保持不变。高斯核的标准差  $\sigma$  为 0.5,学习因子  $\eta$  为 0.02,正则化参数  $\lambda$  为 0.0001,取 HOG 特征,尺度因子  $\gamma$  取 1.5。

以下所有图像在实验中均应用相同的参数。

### 5.2 实验结果与分析

一遍过精度评估中,所提算法与先进算法比较结果如图 3(a)所示,横坐标为跟踪位置中心与事实标注的目标中心的误差阈值,单位为像素,纵坐标为精度值,矩形框里去阈值为 20 像素的精度作为评估标准。本算法在 OPE 精度评估中与 KCF 持平,比 DSST 高出 1.496%,比 CSK 高出 36.6%,以及比 ASLA 高出 39.7%。空间稳健性精度评估结果如图 3(b)所示。本算法比 KCF 高出 1.3%,比 ALSA 高出 21.3%,以及比 CSK 高出 32.88%。时间稳健性精度评估结果如图 3(c)所示。本算法比 KCF 高出 0.12%,比 DSST 高出 4.02%,比 ASLA 高出 25.8%,以及比 CSK 高出 26.6%。

一遍过成功率评估中本算法与先进算法比较结果如图 3(d)所示,横坐标为跟踪结果与事实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。本算法比 DSST 高出 2.4%,比 KCF 高出 8.5%,比 ALSA 高出 32.9%,以及比 CSK 高出 53.6%。空间稳健性成功率比较结果如图 3(e)所示。本算法比 KCF 高出 9.7%,比 ALSA 高出 19.7%,以及比 CSK 高出 50.0%。时间稳健性成功率比较结果如图 3(f)所示。本算法比 DSST 高出 2.8%,比 KCF 算法高出 5.1%,比 ALSA 高出 25.7%,以及比 CSK 高出 37.6%。

### 5.3 质量与效率评估

使用 benchmark 数据集进行了跟踪质量的对比实验,本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 4 所示,图中细实线方框为本算法跟踪结果,虚线方框为 DSST 跟踪结果,点线为 ALSA 跟踪结

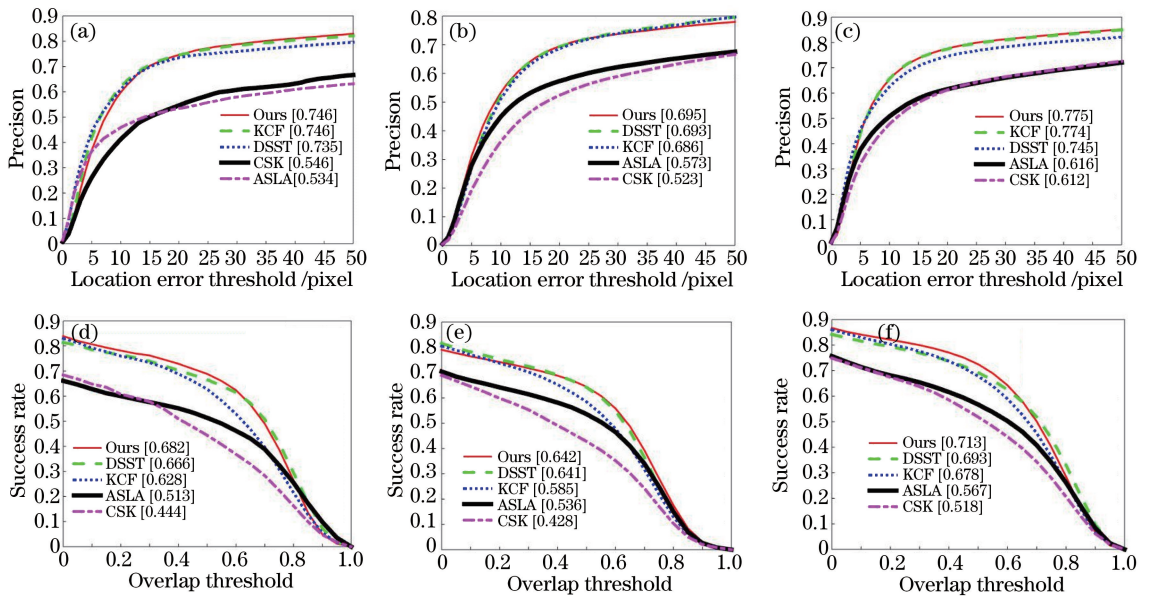


图3 算法性能评估与比较结果。(a) OPE精确度评估；(b) SRE精确度评估；(c) TRE精确度评估；  
(d) OPE成功率评估；(e) SRE成功率评估；(f) TRE成功率评估

Fig. 3 Algorithm performance evaluation and comparison results. (a) OPE precision assessment; (b) SRE precision assessment; (c) TRE precision assessment; (d) OPE success rate assessment; (e) SRE success rate assessment; (f) TRE success rate assessment

果,粗实线为CSK跟踪结果。由图中所列4组图像序列的跟踪结果可以看出,某些算法对某些图像序列未能进行有效跟踪,而本算法对4组图像序列均能做到有效跟踪。本研究对benchmark数据集的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中得到体现,表明本算法具有很强的稳定性与适应性。

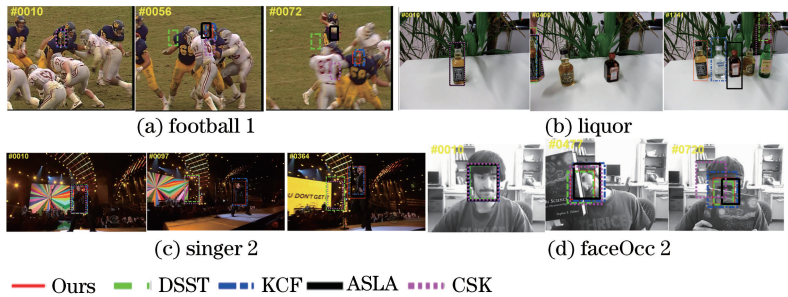


图4 本算法与目前先进算法跟踪质量比较结果

Fig. 4 Tracking quality comparison results of the proposed algorithm and advanced algorithms

所提跟踪算法与目前已有先进算法的运行速度结果对照如表1所示。表中显示本算法跟踪速度可达89.276 frame/s,是DSST算法的4.5倍,具有很高的时效性,可以胜任实时任务。

表1 跟踪算法平均运行速度对照表

Table 1 Table of average efficiency speed of tracking method

Tracking method	Ours	DSST	KCF	ASLA	CSK
Speed /(frame/s)	89.276	19.646	127.877	1.381	207.65

## 6 结 论

针对传统的KCF跟踪方法在尺度变化显著的视频图像序列运行效果很差的问题,提出了一种多尺度估计的改进方法,使得算法对尺度变化的运动目标具有更强的适应能力。借鉴了DSST跟踪的尺度金字塔方法,把灰度图像金字塔的HOG特征映射到一维向量中,作为尺度相关滤波器的输入,获得最高响应值,然后

估算目标尺度。通过与目前已有先进的跟踪方法的比较对照实验,验证了所提算法的高效性,且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,本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 A, Javed O, Shah M. Object tracking: A survey[J]. *Acm Computing Surveys*, 2006, 38(4): 81-93.
- 2 Kristan M, Matas J, Leonardis A, *et al.* The visual object tracking VOT2015 challenge results [C]. 2015 IEEE International Conference on Computer Vision Workshop, 2015: 564-586.
- 3 Casasent D. Unified synthetic discriminant function computational formulation[J]. *Applied Optics*, 1984, 23(10): 1620-1627.
- 4 Kristan M, Pflugfelder R, Leonardis A, *et al.* The visual object tracking VOT2014 challenge results [M]. *Computer Visio-ECCV 2014 Workshops, Switzerland: Springer International Publishing*, 2014, 8926: 191-217.
- 5 Qiu Chunchun, Li Qingwu, Wang Tian, *et al.* An improved IVT algorithm for object tracking [J]. *Laser & Optoelectronics Progress*, 2016, 53(1): 011002.  
仇春春, 李庆武, 王 恬, 等. 一种改进的 IVT 目标跟踪算法[J]. *激光与光电子学进展*, 2016, 53(1): 011002.
- 6 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, 2010: 2544-2550.
- 7 Danelljan M, Khan F S, Felsberg M, *et al.* Adaptive color attributes for real-time visual tracking [C]. 2014 IEEE Conference on Computer Vision and Pattern Recognition, 2014: 1090-1097.
- 8 Henriques J F, Caseiro R, Martins P, *et al.* Exploiting the circulant structure of tracking-by-detection with kernels[M]. *Computer Vision-ECCV 2012, Berlin: Springer Berlin Heidelberg*, 2012, 7575: 702-715.
- 9 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): 583-596.
- 10 Danelljan M, Häger G, Khan F, *et al.* Accurate scale estimation for robust visual tracking [C]. Nottingham: British Machine Vision Conference, 2014.
- 11 Schölkopf B, Smola A J. Learning with kernels: support vector machines, regularization, optimization, and beyond[J]. *IEEE Transactions on Neural Networks*, 2005, 16(3): 781-781.
- 12 Rifkin R, Yeo G W, Poggio T A. Regularized least-squares classification[J]. *Acta Electronica Sinica*, 2003, 190(1): 131-154.
- 13 Gray R M. Toeplitz and circulant matrices: a review[J]. *Foundations & Trends@in Communications & Information Theory*, 2001, 2(3): 155-239.
- 14 Wu Y, Lim J, Yang M H. Online object tracking: A benchmark[C]. 2013 IEEE Conference on Computer Vision and Pattern Recognition, 2013: 2411-2418.
- 15 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.
- 16 Jia X, Lu H C, Yang M H. Visual tracking via adaptive structural local sparse appearance model[C]. *IEEE Conference on Computer Vision & Pattern Recognition*, 2012: 1822-1829.