

doi: 10.7690/bgzdh.2021.06.009

## 基于相关滤波跟踪算法的测试与分析

王承贊<sup>1</sup>, 张龙杰<sup>1</sup>, 浦跃兵<sup>2</sup>, 李彦宽<sup>3</sup>, 张龙云<sup>4</sup>

(1. 海军航空大学岸防兵学院, 山东 烟台 264001; 2. 中国人民解放军 92555 部队, 上海 201900;  
3. 烟台北方星空自控科技有限公司, 山东 烟台 264003; 4. 山东大学后勤保障部, 济南 250000)

**摘要:** 基于相关滤波的跟踪算法具有跟踪速度快以及在线学习并同步更新的特点, 对其进行测试与分析。详细介绍几种经典的相关滤波跟踪模型, 根据诸多算法在 OTB-2013(object tracking benchmark)上的测试运行结果, 对比分析各种算法的总体跟踪性能和在跟踪难点问题上的跟踪鲁棒性能, 横向分析相关滤波算法在应对各种跟踪难点问题时所做的一系列改进, 并对未来的发展给出几点看法。结果表明, 该分析可对相关研究提供参考借鉴。

**关键词:** 相关滤波算法; 目标跟踪基准平台; 目标跟踪难点问题; 测试结果分析; 发展展望

中图分类号: TP181 文献标志码: A

## Test and Analysis of Tracking Algorithm Based on Correlation Filter

Wang Chengyun<sup>1</sup>, Zhang Longjie<sup>1</sup>, Pu Yuebing<sup>2</sup>, Li Yankuan<sup>3</sup>, Zhang Longyun<sup>4</sup>

(1. School of Coastal Defense, Navy Aviation University, Yantai 264001, China;

2. No. 92555 Unit of PLA, Shanghai 201900, China;

3. Yantai Beifang Xingkong Auto-control Technology Co., Ltd., Yantai 264003, China;

4. Department of Logistics Support, Shandong University, Ji'nan 250000, China)

**Abstract:** The tracking algorithm based on correlation filter has the characteristics of fast tracking speed, online learning and synchronous updating, and it is tested and analyzed. Several classical correlation filter tracking models are introduced in detail, according to testing results of many algorithms in the OTB-2013(object tracking benchmark), overall tracking performance and tracking robustness of various algorithms are compared and analyzed. A series of improvements of correlation filter algorithms in dealing with various tracking difficulties are analyzed laterally, and some views on the development of the future are given. The results show that this analysis can provide reference for related research.

**Keywords:** correlation filters algorithms; object tracking benchmark platform; tracking difficulty problems; analysis of test results; development prospect

## 0 引言

目标跟踪是根据已知目标在图像中的位置来预测后续视频序列中目标位置变化, 达到持续目标跟踪的目的。研究目标跟踪技术, 使跟踪系统具有更好的精度和速度, 且使算法对复杂环境和不易跟踪的目标算法仍具有很好的跟踪鲁棒性, 在军事作战上对目标的全天候侦察和精确制导打击具有十分重要的意义。

与传统的目标跟踪算法相比, 相关滤波跟踪算法具有很多优势, 受到了研究人员的重点关注。它巧妙地利用循环矩阵对角化的性质<sup>[1]</sup>, 将时域卷积运算转换到傅里叶域元素点乘, 结合快速傅里叶变换<sup>[2]</sup>, 大大简化了计算量, 提高了跟踪速度。在采样过程中, 只需将原始样本生成循环矩阵, 就可得到类似于使用真正的循环移位对样本采样的大量样本的集合, 大量样本对模型更新可以很好地增强模

型从背景中对目标的判别能力。此外, 图像的灰度特征又增加了方向梯度直方图(histogram of oriented gradients, HOG)特征、颜色(colornames, CN)特征, 甚至从卷积神经网络(convolutional neural network, CNN)中提取的深度特征<sup>[3]</sup>, 将这些特征融合来训练模型参数, 使目标的外观模型表达更充分, 模型判别目标的能力更精确。实验结果表明, 丰富的特征表达是提高跟踪效果极为重要的因素。这些都是核相关滤波(kernelized correlation filter, KCF)算法的优势, 使其具备很大的研究和应用价值。

## 1 经典相关滤波跟踪模型介绍

### 1.1 KCF 算法

KCF 算法是相关滤波跟踪算法的基础和基石<sup>[4]</sup>。KCF 算法的工作原理如图 1 所示。在首帧图

收稿日期: 2021-02-14; 修回日期: 2021-03-28

基金项目: 国家自然科学基金(51809156); 中国博士后科学基金(2016M600537)

作者简介: 王承贊(1992—), 男, 山东人, 硕士, 从事兵器科学与技术研究。E-mail: 2275339722@qq.com。

像中人工标注目标跟踪框，跟踪框初值为 $[x_0, y_0, w_0, h_0]$ ，其中 $x_0$ 和 $y_0$ 为跟踪框左上角的行列坐标、 $w_0$ 和 $h_0$ 为跟踪框的宽和高。建立相关滤波器判别模型，在每帧图像搜索区域，搜索区域以跟踪框中点为中心，长宽与跟踪框的长宽等比例，大小通常是跟踪框面积的2.5倍的搜索区域上采样训练样

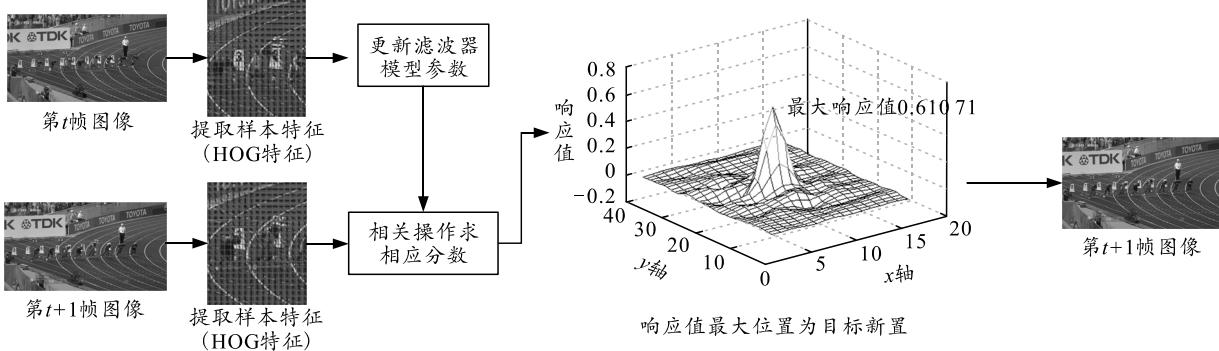


图1 KCF算法的工作原理

KCF 算法的优点有：

- 1) 采用图像的 HOG 特征，把目标的特征向量从 1 维扩展到多维<sup>[6]</sup>，HOG 特征能很好地描述目标的纹理特征和轮廓形状，且对颜色变化不敏感，在色彩复杂的背景下目标也能被较为准确的定位。
- 2) 用岭回归的方法对目标样本拟合效果更好。
- 3) 利用循环移位的方法密集采样，增强核相关滤波器对目标的判别能力，简化了算法的复杂度，跟踪速度很快。
- 4) 引入高斯核函数，将低维空间中线性不可分的样本特征映射入高维空间中变得可以分类。
- 5) 采样时使用余弦窗减轻图像边缘的负样本影响，样本结合高斯标签，使得样本并非传统意义上的非正即负，高斯加权的方式在实际采样中的效果更好。
- 6) 模型更新时采用线性加权，避免了更新的剧烈程度。

但是 KCF 算法仍然存在一些不足，如不能解决目标的变尺度问题、对模型的更新策略不可靠、使用特征单一、循环移位会产生边界效应问题以及在跟踪失败后没有目标重检测的能力等，当在目标出现尺度变化、自身形变、快速运动、受到外界物体的遮挡时，KCF 算法对目标的跟踪很容易失败。

## 1.2 DSST 算法

判别尺度空间跟踪 (discriminative scale space tracker, DSST) 算法以 KCF 算法为基础，也采用图像 HOG 特征。算法的突出贡献是又定义了一个尺

本并对模型在线更新，通过新一帧图像在相同位置的搜索区域上采样的测试样本与模型参数相关操作，得到测试样本响应分数图，取最大响应值的位置作为目标的新位置，并且以新位置为中心采样更新模型。接下来对每一帧图像重复操作，对目标进行跟踪<sup>[5]</sup>。

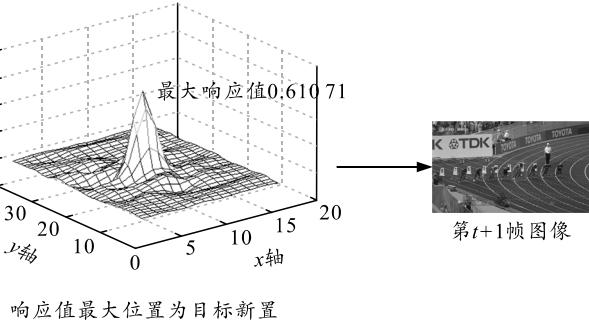


图2 DSST算法的工作原理

度滤波器，将跟踪分成位置跟踪和尺度跟踪<sup>[7]</sup>。如图 2 所示，2 维位置滤波器与 1 维尺度滤波器彼此独立工作，分别估计跟踪框的平移和缩放。

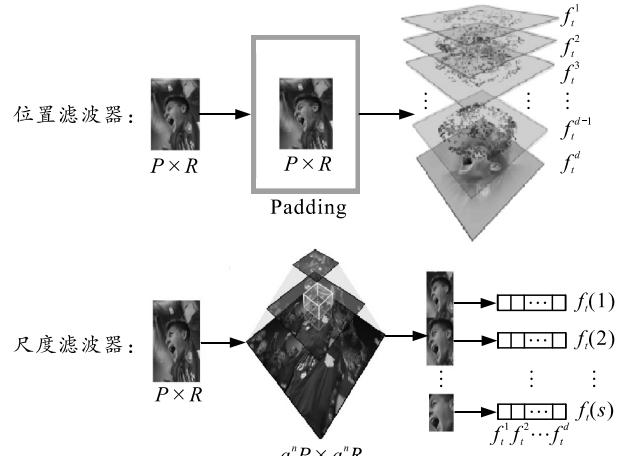


图2 DSST算法的工作原理

尺度跟踪的思路与位置跟踪大体相似，首先由位置滤波器估计出新一帧图像中目标的位置，然后以目标位置为中心，在采样窗口大小分别是跟踪框大小的 $a^n$ 倍获取目标在共 $N$ 个尺度上的测试样本特征 $\{Z_i | i \in a^n P \times a^n R\}$ 。其中， $i$  表示不同大小的测试样本， $a$  是尺度步长， $P$  和  $R$  分别是跟踪框的宽和高， $n$  是尺度取值范围， $n \in \{-(N-1)/2, -(N-3)/2, \dots, (N-1)/2\}$ 。

尺度滤波器对获取的 $N$ 个测试样本缩放，并统一为固定的大小 $J$ ，计算得到 $N$ 个尺度对应的响应分数，取最大响应值对应的尺度作为此时跟踪框变化的尺度大小。

尺度滤波器在目标的位置中心由内而外地采样，采集的样本尺寸是非线性的指数缩放，与上一帧跟踪框的尺寸越接近，采样就越精细；尺寸越偏离，采样就越粗略。使跟踪的尺度可随目标大小变化而自适应调整。本文中尺度步长  $a$  取 1.02，采集  $N$  个 ( $N=33$ ) 尺度的样本。

DSST 算法在 KCF 算法的基础上，可以尺度自适应地应对跟踪过程中目标大小变化的问题；由于 DSST 算法额外增加了一个尺度滤波器，且采样了 33 种尺度的样本特征分别进行测试，高数目的尺度搜索要每帧训练近 1 000 个滤波器参数，极大影响了 DSST 算法的速度。

### 1.3 STAPLE 算法

特征融合目标跟踪 (complementary learners for real-time tracking, STAPLE) 算法，可以看作 DSST 算法与 DAT (double array trie) 算法结合<sup>[5]</sup>。其将 HOG 特征和颜色直方图特征融合作为目标的特征表达，颜色特征能很好解决目标形变和运动模糊的问题，但其对于色彩变化很敏感，在光照变化背景下跟踪效果很差。HOG 特征可以帮助解决，两者取长补短，2 种特征融合能解决跟踪过程中所遇到的大部分问题<sup>[8]</sup>，比只使用灰度特征的跟踪算法在精度上提升超过 20%，跟踪速度却并未受到很大影响。STAPLE 算法用到了粗略的尺度搜索策略，将搜索区域限制在较小部分，用 pca 降维对特征进行压缩和对尺度滤波器加速。

STAPLE 算法的核心思想为：

$$f(x)=\alpha f_{\text{tmp}}(x)+(1-\alpha)f_{\text{hist}}(x) \quad (1)$$

式中： $\alpha$  为融合系数，实验中取 0.7； $f$  为响应分数； $f_{\text{tmp}}$  为相关滤波器使用 HOG 特征跟踪目标得到的响应值； $f_{\text{hist}}$  为用颜色直方图得到的响应值，二者彼此独立。STAPLE 算法将 2 个响应分数加权求和，得到最终的响应值。

### 1.4 SRDCF 算法

相关滤波算法利用循环矩阵生成大量训练样本，但也产生了一个缺陷，即循环矩阵会将目标的图像信号循环拼接，拼接处这些信号并不连续或者不真实，更新模型时就会引入负样本中错误的目标信息，影响目标跟踪<sup>[9]</sup>。空间正则化相关滤波 (spatially regularized correlation filters, SRDCF) 算法将图像的候选区域尽量扩大 (采样区域是跟踪框大小的 16 倍)，保留更多的正样本信息，更关键的

是增加一个惩罚项  $w$ 。对离目标中心越远的样本  $w$  越大，使得该样本对模型更新的影响越小<sup>[10]</sup>。对离目标中心越近的样本， $w$  越大，使得该样本对模型更新的影响越大。

SRDCF 算法的核心公式是：

$$E_t(f)=\sum_{k=1}^t \alpha_k \left\| \sum_{l=1}^d x_k^l * f^l - y_k \right\|^2 + \sum_{l=1}^d \| w * f^l \|_2^2. \quad (2)$$

式中： $k$  为某一帧图像； $l$  为第 1 维到第  $d$  维的样本特征通道； $\alpha_k$  为每一帧图像的权重； $x_k$  和  $f$  为样本集和相关滤波器的模型参数； $y_k$  为高斯标签集；惩罚项  $w$  为一个中间小、周围大的倒置高斯函数，惩罚图像的边界效应。

SRDCF 算法能很好地解决循环矩阵带来的图像边界效应，并且算法采用 Gauss-Seidel 迭代法在损失函数中求解模型参数，优化计算；但是，SRDCF 算法因为加入了惩罚项使得模型参数不能通过非线性核映射入高维空间，损失函数只能线性计算求解滤波器参数，计算量很大。SRDCF 算法速度极慢只有 5 fps 左右。

### 1.5 C-COT 算法

单分辨率特征受复杂环境影响大，跟踪精度受限。连续卷积算子 (continuous convolution operators, C-COT) 算法，既用到传统特征如灰度特征、HOG 特征、CN 特征，又增加了 VGG 神经网络 2 个卷积层-底层和高层，底层卷积层的图像分辨率高，有利于目标定位。高层卷积层语义信息丰富，有利于目标搜索<sup>[11]</sup>；因此，C-COT 算法利用 3 个传统特征和 2 个卷积层提取的 CNN 特征，多特征分辨率使算法精度很高<sup>[12]</sup>。

C-COT 算法的搜索区域很大，在跟踪框 25 倍大小的空间中采样 400 多个样本，算法用一个内插模型将样本特征从离散域扩展到了近似的连续域，用这些连续域特征所训练的连续卷积滤波器，可以在亚像素的程度上判别目标和背景。

C-COT 算法尽管精度很高，但用到了 VGG 网络的卷积层，用来训练的模型参数高达 80 万个。模型参数使用每帧图像来更新，大量的图像历史特征被保留下。上述 2 点容易造成训练样本的过拟合，且庞大的特征意味着计算量的成倍增加，C-COT 算法跟踪速度只有不到 1 fps。

### 1.6 ECO 算法

针对 C-COT 算法速度慢的问题，高效卷积算子

的相关滤波跟踪 (efficient convolution operators for tracking, ECO) 算法在以下 3 方面进行了改进<sup>[13]</sup>:

1) ECO 算法用到卷积算子因式分解的方法, 选择 C-COT 中能量比较大的连续卷积滤波器模型组成一组滤波器集合。实验中 ECO 算法将滤波器的个数从原来的 512 个减少到了 64 个。

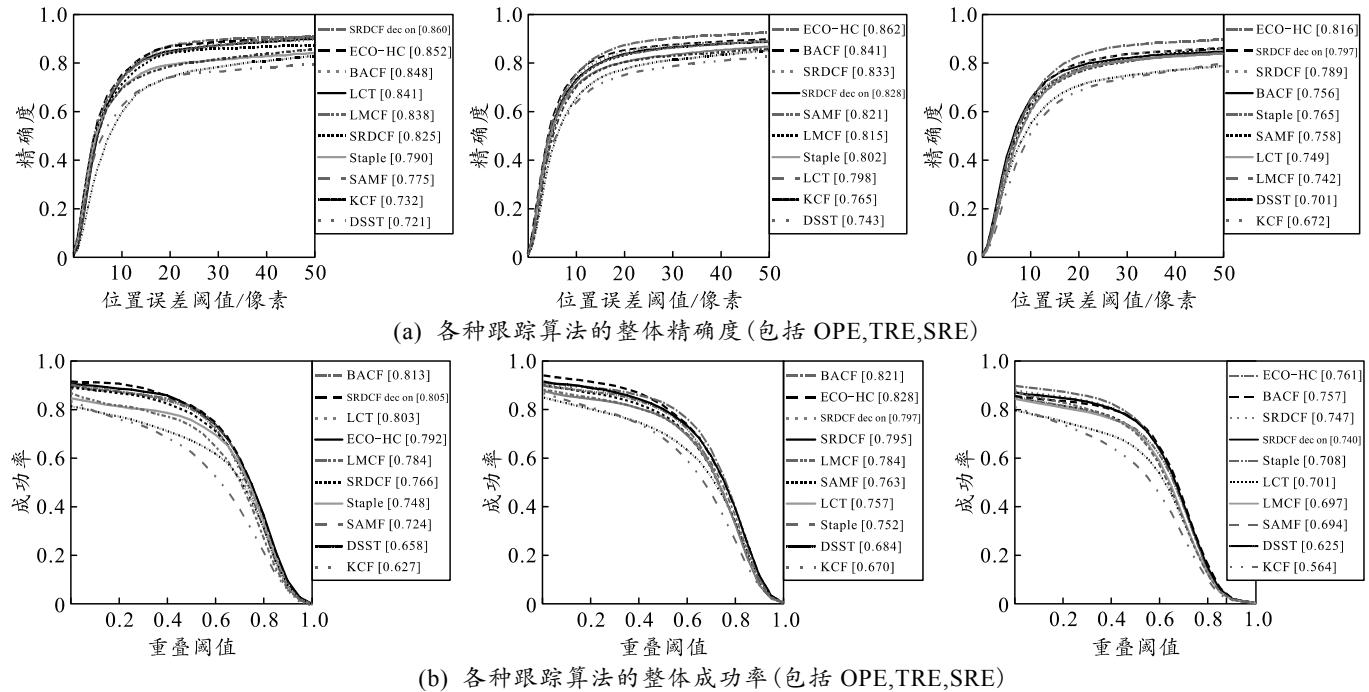
2) ECO 算法采用 GMM 高斯混合模型, 将样本分组表示。同一组样本特征相似, 不同组样本的特征差异很大。算法通过求解每个样本分组的均值, 对于权重小的样本分组, 将其与均值相近的样本分组合并, 并将新样本分组的权重和均值进行更新。对于权重大的样本分组, 将作为一个独立的分组, 这样能减少训练样本冗余产生的过拟合问题。

3) ECO 算法采用每隔 6 帧的间隔来更新滤波器集合的模型参数, 而不是像 KCF 算法那样对模型每帧图像都采样更新, 在一定程度上避免了采样到低质量的样本对模型更新造成的污染问题; 但是 ECO 算法对样本特征还是每帧都要更新。

ECO 算法简化了 C-COT 算法的复杂度, 跟踪速度提升明显, 采用 HOG+CN+CNN 特征的 ECO 算法速度能达到 8 fps。如果把 CNN 特征去除, 算法仅采用 HOG+CN 的特征, 简化的 ECO-HC 算法速度可超过 60 fps, 但精度会有所下降。

## 2 OBT-2013 测试结果对比和分析

实验中电脑硬件配置环境是 Intel Core i5-8033H 4 核 CPU 处理器。带有 CNN 特征的算法



速度过慢, 达不到跟踪实时性要求, 所以实验不会测试 CNN 特征。将 KCF、DSST、STAPLE、SRDCF、SRDCFdecon、ECO-HC、LCT、BACF、LMCF、SAMF 等 10 种算法在 OTB-50 平台上运行测试, 比较各种算法的精度、成功率和运行速度, 分析了算法的综合性能以及在复杂环境中应对各种问题的鲁棒性。

### 2.1 object tracking benchmark 介绍

采用 object tracking benchmark (OTB-50) 测试算法的成功率和精确度来评估算法基准平台<sup>[14-15]</sup>。统一了各类算法的输入输出格式, 建立了 50 个人工标注好的视频序列。50 个视频代表不同的属性, 主要分为光照变化、尺度变化和遮挡等 11 个属性, 每个视频兼有不同的属性。

### 2.2 测试结果对比及分析

上述 10 种算法在 OTB-50 上测试, 图 3 的前两行图表示跟踪算法的一次性评估 (one-pass evaluation, OPE)、时间鲁棒性评估 (temporal robustness evaluation, TRE)、空间鲁棒性评估 (spatial robustness evaluation, SRE) 的精度图和成功率图; 后两行图表表示算法进行鲁棒性跟踪的精确度图, 包括遮挡、目标变尺度、目标形变、低分辨率、光照和运动模糊的问题。表 1 记录了经典相关滤波跟踪模型的 5 种算法在 OTB-50 上测试的平均帧率、准确度、成功率以及采用的特征表达。

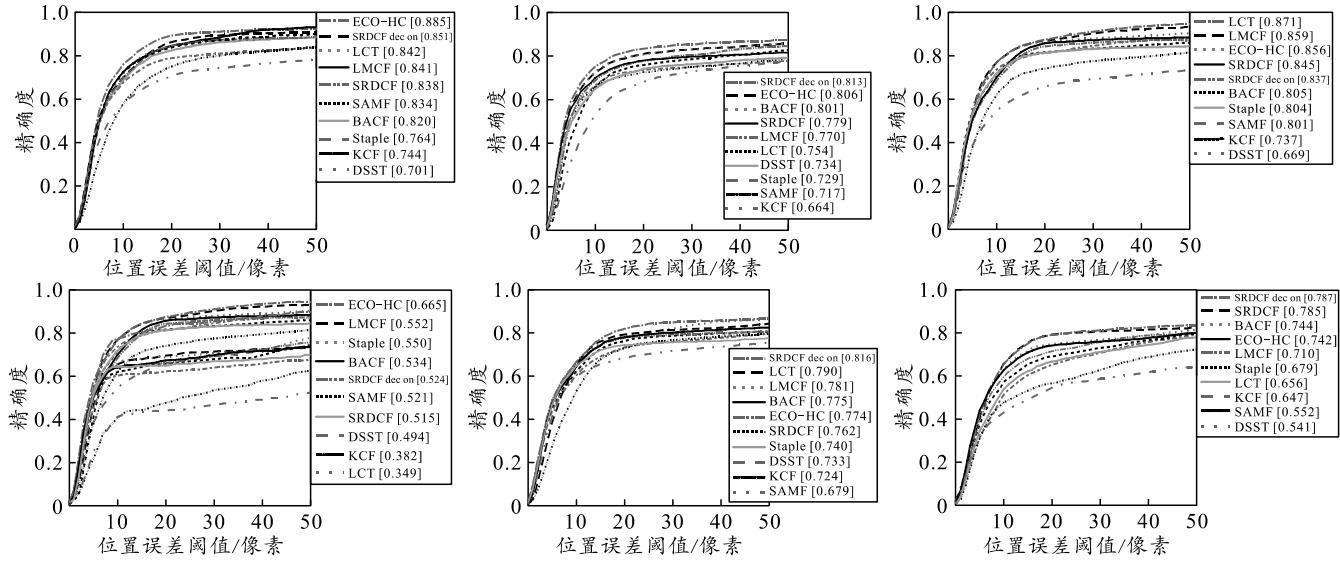


图 3 算法的精确度和成功率

表 1 跟踪算法的指标

相关滤波算法	算法特征	平均帧率/fps	精确度	成功率
ECO-HC	HOG+CN	43.4	0.852	0.813
SRDCF	HOG+CN	2.7	0.825	0.838
Staple	HOG+颜色直方图	53.6	0.748	0.764
DSST	HOG	20.2	0.721	0.658
KCF	HOG	148.0	0.732	0.627

从图 3 和表 1 可以看出:KCF 算法只采用 HOG 特征, 并未采取更多的特征表达和目标搜索策略, 在整体性能上效果较差, 也不能处理复杂问题; DSST 算法以牺牲跟踪速度为代价, 在目标尺度变化的问题上做出改进, 但处理其他问题时精度较差, 整体性能上与 KCF 算法接近; STAPLE 算法在 DSST 算法的基础上, 将图像的 HOG 特征与颜色直方图特征进行融合, 算法的成功率得到了很大提高。得出结论: 在处理复杂问题上采用特征融合可以很好地提升目标跟踪的鲁棒性; SRDCF 算法通过在损失函数中加入惩罚项, 有效地解决了相关滤波算法的边界效应问题, 使 SRDCF 算法的跟踪精度和成功率提高了一个层次, 但速度极差; ECO-HC 算法通过内插模型和高斯混合模型分别提高了样本特征分辨率以及减少了样本的过拟合, 跟踪精度在测试中位居前列, 而且从多个方面优化了目标搜索策略, 减少了算法的复杂度, 未采用深度特征的 ECO-HC 算法的跟踪速度能够保证跟踪实时性的要求, 具有巨大的应用前景。

### 3 算法在跟踪难点问题上的改进

#### 3.1 遮挡问题

目标受到短时的遮挡问题, ECO 算法每间隔 6

帧更新模型, 短时错误的样本不会对跟踪产生影响; LMCF 算法<sup>[16]</sup>将结构化 SVM 加入相关滤波框架中, 通过多峰值检测避免了相似物体的干扰, 引入响应值 APCE 指标, 目标受到遮挡时 APCE 低于阈值, 模型就不会更新, 无遮挡时 APCE 值会高于阈值, 正常更新模型。

如果目标发生部分遮挡, 通常会采用分块策略, 对目标未被遮挡的部分分块提取有效的样本特征, 对遮挡部分进行判别, 将信息忽略。RPAC 算法<sup>[17]</sup>将目标中心分成一个块, 同时上下左右划分为 4 个块, 给 5 个块建立相互独立的滤波器模型, 将每个滤波器的响应值利用贝叶斯后验概率推导出整体的联合响应值, 并且利用峰值旁瓣比的方法判别每个块是否存在遮挡来确定是否停止更新某个模型; PKCF 算法给每个块建立独立的 KCF 滤波器, 通过粒子滤波的方式来分块训练各自的模型, 并自适应赋给每个滤波器不同的权值。

目标被完全遮挡导致滤波器丢失目标, 有些算法加入了重检测模块使目标可以被重新跟踪。LCT 算法<sup>[18]</sup>在 DSST 算法的基础上, 构建一个随机森林分类器, 通过训练具有长期记忆能力的滤波器判断目标是否跟丢。分类器设定 2 个阈值, 如果响应值大于最大阈值, 说明跟踪可靠; 如果响应值小于最小阈值, 说明目标丢失, 要重新检测目标; ILCT 算法<sup>[19]</sup>将 SVM 取代随机森林分类器作为重检测模块; MUSEer 算法<sup>[20]</sup>利用认知心理学的一种启发式思路来作为目标特征的表达, 以短时记忆和长时记忆来处理目标特征。

### 3.2 尺度变化问题

通常采用尺度池方法来解决目标大小变化。DSST 算法在平移滤波器的基础上加入一个尺度滤波器, 可以计算 33 种尺度大小变化得到的响应值; SAMF 算法<sup>[21]</sup>采用全局最优策略、7 个尺度的搜索可同时估计跟踪框的位置和尺度, 提升速度; fDSST 算法<sup>[22]</sup>是对 DSST 算法的加速, 利用 PCA 降维和 QR 分解来简化计算; RAJSSC 算法<sup>[23]</sup>将目标从笛卡尔坐标系转换到对数坐标系, 保证目标在旋转时仍能估计出位移和尺度变化。

分块方法也能很好地应对目标大小的变化。RPAC 算法设定阈值, 通过计算位于中心的块和其他 4 个方向的块中心点的距离, 判断某个距离是否大于阈值, 如果比阈值大就调整相应块的距离, 可以自适应的估计目标尺度变化。

特征点跟踪比尺度池和分块方法对尺度变化更敏感, 而且具有通用性。常用的特征点包括 SIFT、SURF、BRIEF、FAST 等。SKCF 算法在图像中设置不同特征点, 对离目标中心越近的特征点, 算法赋值权重越大; 对离目标中心越远的特征点, 算法赋值的权重越小。然后匹配特征点, 比较特征点位置的移动来估计目标尺度的变化。

### 3.3 目标形变问题

可形变组件利用目标整体特征和局部特征的相互关系解决目标形变。DPCF 算法<sup>[24]</sup>建立一个整体和多个局部的滤波器, 通过滤波器的耦合关系来协同处理目标形变; DPT 算法将目标函数约束为一个凸代价函数, 把局部滤波器用于精确定位, 把整体滤波器用于粗略估计; SSPA-KCF 算法通过 KCF 的方法对组件建立最小化外观函数和最小化形变代价, 采用最小生成树和动态规划相结合的思路求解各组件的响应值, 综合响应值来预测目标的位置。

### 3.4 边界效应问题

为解决相关滤波的边界效应, 最初采用尽可能大的搜索区域, 但会引入不必要的背景信息, 而且增加了计算量。后来对目标函数加入正则化约束成为一种更好的方法。SRDCF 算法只是采用固定的正则项来抑制边界; 由于遮挡或者背景等干扰, 训练样本有时会被污染, SRDCFdecon 算法提出一种目标外观模型和训练样本质量权重联合学习的统一公式, 算法通过公式来最小化单一损失, 达到“去污”的目的; STRCF 算法<sup>[25]</sup>将时间正则化加入 SRDCF

架构中, 时空正则化策略在目标出现遮挡和大幅形变的情况下比 SRDCF 算法有更好的鲁棒性能; BACF 算法通过“裁剪”图像中有用区域来提高训练样本的质量, 同时扩大采样区域, 使用真实移位产生的负样本, 提高了样本数量。训练样本的质量和数量都能提高, 且很好地提高了跟踪的可靠性。

## 4 结束语

目标跟踪技术在军事上得到广泛应用, 相关滤波算法仍需进一步发展和完善, 通过分析, 可从如下方面进行研究:

### 1) 在 2 维与 3 维的转换下结合运动学滤波。

将相关滤波算法与运动学滤波相结合, 通过世界坐标系-相机坐标系-图像坐标系-像素坐标系的坐标转换, 在像素坐标系下用相关滤波算法推导出跟踪框中心点的 2 维坐标, 加上对目标的测距和相机旋转的姿态角和偏移量, 可以转换到世界坐标系下真实目标的 3 维位置, 根据假设的目标运动模型, 滤波得到目标状态量的最优估计, 再通过坐标系转换为算法跟踪框 2 维坐标的修正量, 代入相关滤波算法对下一帧的目标进行跟踪。这样既可以发挥相关滤波算法在线学习、同步更新和跟踪速度快的优势, 又能够通过运动学滤波来预测目标的运动状态。

### 2) 特征融合。

强大的特征是可靠跟踪的关键因素。相关滤波算法最初采用图像的手工特征(灰度、HOG、颜色特征及其组合), HCF 算法<sup>[26]</sup>将卷积神经网络应用到相关滤波中, 从不同卷积层提取的深度特征具有不同的特点, 跟踪精度很高; ECO+算法<sup>[27]</sup>将网络替换为 RESNET-50, 总结了手工特征更侧重精度而深度特征更侧重鲁棒性能的特点, 将 2 种特征分而治之, 得到的响应值自适应融合; SiamFC 算法<sup>[28]</sup>将神经网络不限于特征提取, 而是用于构建分类器。SiamFC 算法是基于全卷积孪生网络, 利用孪生结构来进行相似性学习。RPN 算法<sup>[29]</sup>结合了 SiamFC 和 Faster R-CNN 2 种算法, 在保证较高跟踪精度的同时, 加快了图像的提取速度。SiamMask 算法<sup>[30]</sup>基于 SiamFC 算法, 提出了一个简单的模型, 同时实现视频目标跟踪和视频目标分割 2 项任务, 实时地给出目标的像素级标注。SiamMask 模型通过在用于目标跟踪的全卷积孪生神经网络上增加 mask 分支来实现目标的分割。一旦网络训练好后, SiamMask 仅依赖于初始的一个目标框就可实现类别无关的目

标实时跟踪及分割。如何满足跟踪实时性要求，是下一步研究的重中之重。

### 3) 红外目标跟踪。

红外视频比可见光视频有其独有的优势：可见光在光线不足的情况下无法获得有效的图像，红外视频利用物体辐射的红外能量成像，可全天候跟踪目标。红外图像缺乏目标纹理信息且目标的形状和大小容易受到环境干扰，红外视频含有大量的噪声和模糊，目标在红外视频的跟踪比在可见光里要难得多。在跟踪目标前对图像进行一系列预处理工作，使目标特征变得“清晰”，这是红外跟踪能够被广泛运用的关键。

## 参考文献：

- [1] HENRIQUES J F, CASEIRO R, MARTINS P, et al. Exploiting the Circulant Structure of Tracking-by-Detection with Kernels[C]//Proceedings of the 12th European conference on Computer Vision-Volume Part IV. Springer, Berlin, Heidelberg, 2012.
- [2] PATNAIK R, CASASENT D. Fast FFT-based distortion-invariant kernel filters for general object recognition[J]. Proceedings of Spie the International Society for Optical Engineering, 2009.
- [3] MA C, HUANG J B, YANG X, et al. Hierarchical Convolutional Features for Visual Tracking[C]//IEEE International Conference on Computer Vision. IEEE Computer Society, 2016.
- [4] HENRIQUES J F, CASEIRO R, MARTINS P, et al. High-Speed Tracking with Kernelized Correlation Filters[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2015, 37(3): 583–596.
- [5] BERTINETTO L, VALMADRE J, GOLODETZ S, et al. Staple: Complementary Learners for Real-Time Tracking[C]// Computer Vision & Pattern Recognition. IEEE, 2016.
- [6] GALOOGAHI H K, SIM T, LUCEY S. Multi-channel Correlation Filters[C]//Proceedings of the 2013 IEEE International Conference on Computer Vision. IEEE, 2014.
- [7] DANELLJAN M, HAGER G, KHAN F S, et al. Discriminative Scale Space Tracking[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016(99): 1.
- [8] WANG N, SHI J, YEUNG D Y, et al. Understanding and Diagnosing Visual Tracking Systems[C]//IEEE International Conference on Computer Vision. IEEE Computer Society, 2016.
- [9] GALOOGAHI H K, SIM T, LUCEY S. Correlation Filters with Limited Boundaries[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2015.
- [10] DANELLJAN M, HGER G, KHAN F S, et al. Learning Spatially Reularized Correlation Filters for Visual Tracking[C]// 2015 IEEE International Conference on Computer Vision (ICCV). IEEE, 2016.
- [11] BERTINETTO L, VALMADRE J, HENRIQUES J, et al. Fully-Convolutional Siamese Networks for Object Tracking[J]. 2016.
- [12] DANELLJAN M, ROBINSON A, KHAN F S, et al. Beyond Correlation Filters: Learning Continuous Convolution Operators for Visual Tracking[C]//European Conference on Computer Vision. Springer, Cham, 2016.
- [13] DANELLJAN M, BHAT G, KHAN F S, et al. ECO: Efficient Convolution Operators for Tracking[C]//IEEE Conference on Computer Vision & Pattern Recognition. IEEE, 2017.
- [14] WU Y, LIM J, YANG M H. Online Object Tracking: A Benchmark[C]//Computer Vision & Pattern Recognition. IEEE, 2013.
- [15] WU Y, LIM J, YANG M H. Object Tracking Benchmark[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2015, 37(9): 1834–1848.
- [16] WANG M, LIU Y, HUANG Z. Large Margin Object Tracking with Circulant Feature Maps[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2017.
- [17] LIU T, WANG G, YANG Q. Real-time part-based visual tracking via adaptive correlation filters[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2015.
- [18] MA C, YANG X, ZHANG C, et al. Long-term correlation tracking[C]//Computer Vision & Pattern Recognition. IEEE, 2015.
- [19] MA C, YANG X, ZHANG C, et al. Adaptive correlation filters with long-term and short-term memory for object tracking[J]. International Journal of Computer Vision, 2018, 126(8): 771–796.
- [20] HONG Z B, ZHE C, WANG C, et al. MUSTer: a Cognitive Psychology Inspired Approach to Object Tracking[C]//IEEE Conference on Computer Vision & Pattern Recognition. IEEE, 2015.
- [21] LI Y, ZHU J. A Scale Adaptive Kernel Correlation Filter Tracker with Feature Integration[C]//European Conference on Computer Vision. 2015.
- [22] FAN H, LING H. Parallel Tracking and Verifying: A Framework for Real-Time and High Accuracy Visual Tracking[C]//2017 IEEE International Conference on Computer Vision (ICCV). IEEE, 2017.
- [23] ZHANG M, XING J, GAO J, et al. Joint Scale-Spatial Correlation Tracking with Adaptive Rotation Estimation[C]// IEEE International Conference on Computer Vision Workshop. IEEE, 2015.
- [24] AKIN O, ERDEM E, ERDEM A, et al. Deformable part-based tracking by coupled global and local correlation filters[J]. Journal of Visual Communication and Image Representation, 2016, 38: 763–774.
- [25] LI F, TIAN C, ZUO W, et al. Learning Spatial-Temporal Regularized Correlation Filters for Visual Tracking[C]// 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2018.

(下转第 53 页)