

# 自适应特征融合的核相关滤波目标跟踪算法研究

董春燕, 刘 怀, 梁秦嘉, 梁 磊

(南京师范大学电气与自动化工程学院, 江苏 南京 210023)

[摘要] 在核相关滤波目标跟踪算法中,为了克服采用单一特征导致的特征表达不足,以及采用线性插值模型更新策略造成模型漂移的问题,提出了一种自适应特征融合和模型更新的核相关滤波目标跟踪算法. 首先使用主成分分析法对方向梯度直方图特征和颜色名特征进行降维,以提高算法的运行速度;其次计算两种特征的响应图,用所得响应图的峰值与平均峰值相关能量值的乘积来计算响应图权重,实现响应图的加权融合,从而获得目标位置;最后根据两帧间颜色名特征的相似度调整模型更新速率. 在 OTB-50 数据集上的实验结果分析表明,该算法跟踪性能优于其他算法,能够提高处理速度.

[关键词] 目标跟踪,核相关滤波,特征融合,模型更新

[中图分类号] TP391 [文献标志码] A [文章编号] 1672-1292(2020)03-0050-07

## Kernelized Correlation Filter Tracking Algorithm Based on Adaptive Feature Fusion

Dong Chunyan, Liu Huai, Liang Qinjia, Liang Lei

(School of Electrical and Automation Engineering, Nanjing Normal University, Nanjing 210023, China)

**Abstract:** In the kernelized correlation filter object tracking algorithm, the use of mere histograms of oriented gradients (HOG) feature can easily cause insufficient feature expression. In addition, the linear interpolation model updating strategy used in this algorithm can easily cause model drift. To solve these problems, an improved kernelized correlation filter tracking algorithm based on adaptive feature fusion and model updating is proposed in this paper. Firstly, PCA is applied to reduce the dimension of HOG feature and color name (CN) feature to improve the speed of the algorithm. Secondly, the response maps of the two dimensionality reduction features are calculated independently. After that, the product of the peak value and the average peak-to-correlation energy (APCE) of two response maps are used to obtain their weights so that we can use weights to obtain the fused response map. Finally, the model updating rate is determined according to the similarity of CN feature between the two frames. Qualitative and quantitative analysis of experimental results on the OTB-50 dataset show that the tracking performance of the proposed algorithm is superior to that of other tracking algorithms and it can ensure the real-time performance.

**Key words:** object tracking, kernelized correlation filter, feature fusion, model update

目标跟踪是计算机视觉领域的一个重要研究内容,在视频监控、自动驾驶和人机交互等领域有广泛的应用<sup>[1]</sup>. 在运动过程中,目标可能会发生形变、尺度变化以及相互遮挡等干扰情况,造成目标丢失或跟踪精确度降低. 在干扰存在的情况下实现鲁棒跟踪是目标跟踪领域的难点问题. 早期的目标跟踪算法大多为生成类算法<sup>[2-3]</sup>,如光流跟踪、均值漂移跟踪、粒子滤波跟踪等. 近年来目标跟踪算法的研究逐渐转向判别类算法<sup>[4-6]</sup>,如 TLD 跟踪、Struck 跟踪、相关滤波类目标跟踪等. 此外,有学者设计深度学习的算法来进行目标跟踪,如 Chi 等<sup>[7]</sup>提出的 DNT(dual deep network for visual tracking)算法、Gordon 等<sup>[8]</sup>提出的 Re3(real-time recurrent regression networks)算法、Wang 等<sup>[9]</sup>提出的 SiamMask 算法等. 目前基于深度学习的跟踪算法普遍存在实时性较差的问题.

收稿日期:2019-05-21.

基金项目:国家自然科学基金项目(61603194).

通讯作者:刘怀,博士,副教授,研究方向:数字图像处理、实时控制系统. E-mail:liuhuai@njjnu.edu.cn

相关滤波跟踪算法由于精度高、速度快,吸引了许多学者对其进行研究. Bolme 等<sup>[10]</sup>将目标跟踪转化为求两个信号的相关问题,通过目标特征和训练出的滤波模型在频域计算得到目标位置,跟踪速度明显提高,但由于训练样本有限,跟踪精度较低. Henriques 等<sup>[11]</sup>提出 CSK(circulant structure with kernels)算法,通过目标样本的循环移位获得大量训练样本,利用循环结构的性质实现在频域的快速计算,既增加了训练样本数目又不影响训练速度. 随后 Henriques 对 CSK 算法进行完善,在 KCF(kernel correlation filter)算法<sup>[12]</sup>中使用 HOG 特征代替 CSK 跟踪算法的单通道灰度特征,提升了跟踪性能. 同时, Danelljan 等<sup>[13]</sup>使用 CN 特征代替灰度特征,提高了目标跟踪在彩色视频中的准确性.

以上方法仅采用单一特征对目标建模,当目标外观变化时容易累积模型误差,会导致目标丢失或跟踪精确度降低. 很多学者从多特征融合入手,通过提取多种互补特征提高目标跟踪精度. Bertinetto 等<sup>[14]</sup>提取颜色直方图和 HOG 特征分别训练并对响应图加权融合,跟踪准确性较高. 茅正冲等<sup>[15]</sup>提取 CN 特征、HOG 特征和灰度特征并串联,丰富了特征表达.

此外,现有的相关滤波跟踪算法使用固定学习率更新模型,易发生跟踪漂移. 为此, Asha 等<sup>[16]</sup>根据目标前后两帧中的位置变化量来调整学习率,实现了学习率的动态适应. 陈智等<sup>[17]</sup>设置了响应图峰值阈值,当峰值大于阈值时更新模型. Wang 等<sup>[18]</sup>对响应图进行计算分析,虽能判断目标漂移,但当目标发生形变时,响应图也会出现多个峰值,造成模型更新不准确.

尽管上述多特征融合算法在一定程度上提高了目标跟踪的准确性,但融合方法仍存在缺陷,且现有的模型更新策略也存在不足. 为此,本文在 KCF 算法的基础上,提出一种自适应特征融合和模型更新的跟踪算法,依据降维后的 HOG 特征和 CN 特征计算响应图,用所得响应图的峰值与平均峰值相关能量值的乘积自适应调整响应图权重,实现响应图的加权融合,并根据两帧之间 CN 特征相似度改变模型更新速率.

## 1 KCF 跟踪算法基本原理

滤波器训练以目标位置为中心,截取宽为  $M$ 、高为  $N$  的图像块为目标样本  $X$ ,对其循环移位得到  $M \times N$  个图像样本  $X_i(i \in \{0, 1, \dots, M \times N - 1\})$  作为训练样本,提取对应的训练样本特征  $x_i$ ,样本标签  $y_i$  采用二维高斯函数. 训练的目标是找到一个  $\omega$  使得在样本特征  $x_i$  及其标签  $y_i$  给定的情况下误差函数最小,即:

$$\min_{\omega} \sum_i [\omega^T x_i - y_i]^2 + \lambda \|\omega\|^2, \quad (1)$$

式中,  $\lambda$  为正则化参数,可避免分类器过拟合.

将  $\omega$  转换成样本特征  $x_i$  的高维矩阵  $\varphi(x_i)$  的线性加权:

$$\omega = \sum_i \alpha_i \varphi(x_i), \quad (2)$$

同时引入核函数  $\kappa(x, x') = \varphi^T(x) \varphi(x')$ . 这样,求解  $\omega$  就转化为求解滤波器系数  $\alpha$ :

$$\hat{\alpha} = \frac{\hat{y}}{\hat{k}^{xx} + \lambda}, \quad (3)$$

式中,符号  $\hat{\cdot}$  表示变量的傅里叶变换;  $\alpha$  为滤波器系数;  $y$  为标签  $y_i$  构成的标签向量;  $k^{xx} = \kappa(x, x)$  为样本特征  $x$  的核自相关向量.

在新的一帧中,以上一帧目标位置为中心,采用上一帧计算出的检测区域宽和高的值截取检测样本,提取检测样本特征  $z$ ,得到输出响应为:

$$\hat{f}(z) = \hat{k}^{xz} \odot \hat{\alpha}, \quad (4)$$

式中,  $k^{xz}$  为目标样本特征  $x$  和检测样本特征  $z$  的核互相关向量;  $\odot$  表示点乘.

输出响应中最大值的位置即为当前帧目标的中心位置. 为了适应目标的变化,使用线性插值更新目标样本特征  $\hat{x}$  和滤波器系数  $\hat{\alpha}_t$  为:

$$\begin{cases} \hat{x}_t = \eta \hat{x}_t + (1 - \eta) \hat{x}_{t-1}, \\ \hat{\alpha}_t = \eta \hat{\alpha}_t + (1 - \eta) \hat{\alpha}_{t-1}, \end{cases} \quad (5)$$

式中,  $\eta$  表示学习率;  $\hat{x}_{t-1}$  为第  $t-1$  帧的目标样本特征;  $\hat{x}_t$  为第  $t$  帧的目标样本特征.

## 2 自适应特征融合的核相关滤波跟踪算法

### 2.1 自适应特征融合

传统的 KCF 跟踪算法只使用 HOG 特征对目标建模, HOG 特征反映了目标的局部形状和边缘, 对颜色变化和光照变化鲁棒<sup>[19]</sup>, 但当目标发生快速形变时, 不能准确判断目标位置. CN 特征将图像的 RGB 颜色空间映射至 11 种预先定义的颜色构成的颜色空间, 能够更好地描述目标颜色, 对目标形变鲁棒, 但当目标发生连续变色时, 不能准确判断目标位置.

HOG 特征和 CN 特征分别描述了目标的形状和颜色, 具有一定的互补性. 若采用特征层直接串联的融合方式, 当某一特征跟踪精确度降低时, 会影响整体的跟踪性能, 鲁棒性较差. 本文通过计算特征权重实现响应图的融合:

$$f_{\text{mix},t} = g_{\text{HOG},t} \times f_{\text{HOG},t} + g_{\text{CN},t} \times f_{\text{CN},t}, \quad (6)$$

式中,  $f_{\text{mix},t}$ ,  $f_{\text{HOG},t}$  和  $f_{\text{CN},t}$  分别为第  $t$  帧融合响应图、HOG 特征响应图和 CN 特征响应图;  $g_{\text{HOG},t}$  和  $g_{\text{CN},t}$  分别为第  $t$  帧 HOG 特征和 CN 特征的权重.

但是, 特征的增多不可避免地增加了算法计算量, 会丧失 KCF 跟踪算法最突出的速度优势. 为了在提升速度的同时又不影响跟踪精度, 受文献[20]的启发, 本文使用主成分分析(PCA)法分别对 HOG 特征和 CN 特征进行降维. 首先, 将原始特征按行排列成特征矩阵, 并令该特征矩阵每一行数据均值为零, 得到去平均值后的特征矩阵  $\mathbf{X}_{m \times n}$ ; 其次, 对特征的自相关矩阵  $\mathbf{X}\mathbf{X}^T$  进行分解, 将特征值从大到小排序并选择前  $d$  个特征值对应的特征向量, 按顺序排列成左投影矩阵  $\mathbf{U}_{d \times m}$ , 其中  $d \leq m$ ; 最后, 将去平均值后的原始特征矩阵  $\mathbf{X}_{m \times n}$  左乘这个投影矩阵  $\mathbf{U}_{d \times m}$  即可得降维后的特征矩阵:

$$\mathbf{X}'_{d \times n} = \mathbf{U}_{d \times m} \mathbf{X}_{m \times n}, \quad (7)$$

式中,  $\mathbf{X}'_{d \times n}$  为降维后的特征矩阵;  $d$  为降维维数.

分别计算降维后的 CN 特征和 HOG 特征响应图, 选取响应图的峰值  $f_{\text{max}}$  和平均峰值相关能量<sup>[18]</sup> (APCE) 的乘积作为特征权重的置信度, 其中:

$$\begin{cases} f_{\text{max},t} = \max f_t, \\ \text{APCE}_t = \frac{|f_{\text{max},t} - f_{\text{min},t}|^2}{\text{mean}\left(\sum_{w,h} (f_{w,h,t} - f_{\text{min},t})^2\right)}, \end{cases} \quad (8)$$

式中,  $f_t$  表示第  $t$  帧的特征响应图;  $f_{\text{max},t}$  表示第  $t$  帧响应图的峰值;  $f_{\text{min},t}$  表示第  $t$  帧响应图的最小值;  $f_{w,h,t}$  表示第  $t$  帧响应图中坐标为  $(w, h)$  位置处的值.

则第  $t$  帧特征权重的计算公式为:

$$\begin{cases} g_{\text{HOG},t} = \frac{f_{\text{max\_HOG},t} \times \text{APCE}_{\text{HOG},t}}{f_{\text{max\_HOG},t} \times \text{APCE}_{\text{HOG},t} + f_{\text{max\_CN},t} \times \text{APCE}_{\text{CN},t}}, \\ g_{\text{CN},t} = \frac{f_{\text{max\_CN},t} \times \text{APCE}_{\text{CN},t}}{f_{\text{max\_HOG},t} \times \text{APCE}_{\text{HOG},t} + f_{\text{max\_CN},t} \times \text{APCE}_{\text{CN},t}}, \end{cases} \quad (9)$$

式中,  $g_{\text{HOG},t}$  和  $g_{\text{CN},t}$  分别为第  $t$  帧 HOG 特征和 CN 特征权重;  $f_{\text{max\_HOG},t}$  和  $f_{\text{max\_CN},t}$  分别为第  $t$  帧 HOG 特征和 CN 特征响应图的峰值;  $\text{APCE}_{\text{HOG},t}$  和  $\text{APCE}_{\text{CN},t}$  分别为第  $t$  帧 HOG 特征和 CN 特征的平均峰值相关能量值.

为了抑制权值漂移, 对式(9)得到的特征权重进行线性插值更新:

$$\begin{cases} g_{\text{HOG},t} = \lambda g_{\text{HOG},t} + (1-\lambda) g_{\text{HOG},t-1}, \\ g_{\text{CN},t} = \lambda g_{\text{CN},t} + (1-\lambda) g_{\text{CN},t-1}. \end{cases} \quad (10)$$

为了验证本文特征权重的有效性, 使用本文特征融合算法在 Basketball 视频序列上跟踪得到的特征权重变化图如图 1 所示. 可以看出, 第 88、484 帧时目标发生较大变形, HOG 特征的权重显著下降, CN 特征权重显著增加; 而在第 226、694 帧时目标的形变较小, 背景光照对目标绿色衣服产生了影响, HOG 特征权重显著增加, CN 特征权重减小. 可见本文特征融合算法能够根据两个特征的跟踪效果来分配权重, 达到特征权重的自适应改变.

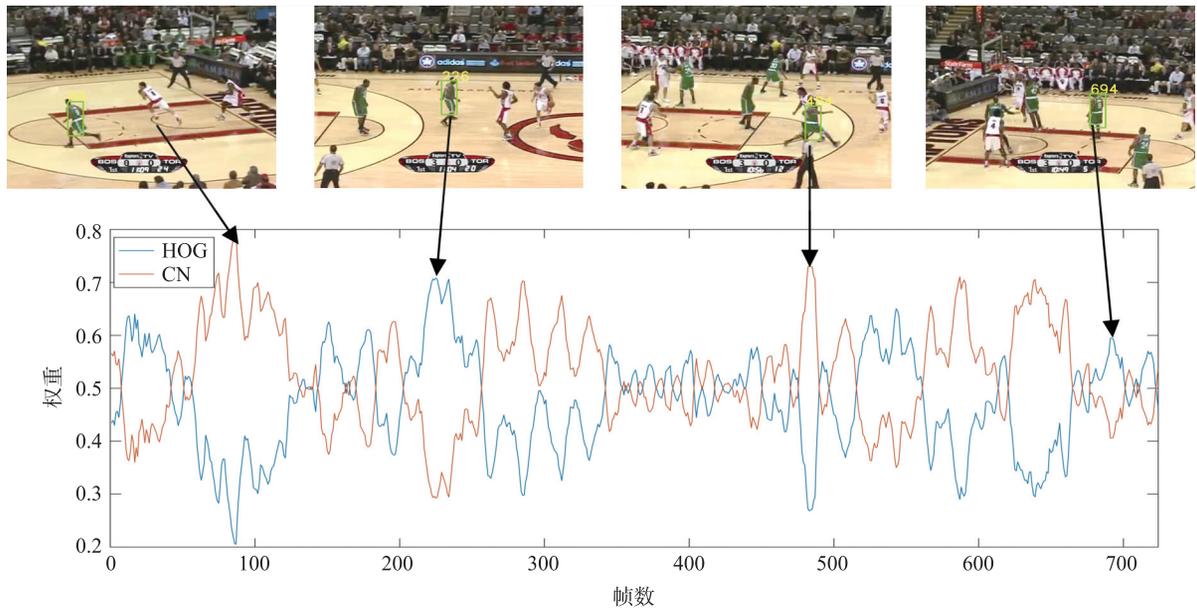


图1 Basketball 视频序列特征权重变化图

Fig. 1 Feature weight variation diagram of Basketball sequence

## 2.2 改进的模型更新策略

传统的 KCF 跟踪算法采用式(5)的固定学习率更新模型,未对跟踪结果的可靠性进行判断,当跟踪不准确时,模型中会引入错误的目标信息.为此,本文提出根据前后两帧的特征相似度自适应调整模型更新速率.图2为在不同视频序列上运行得到的前后两帧特征的相似度.相似度值计算公式为:

$$T_t(v_{t-1}, v_t) = \frac{\langle v_{t-1}, v_t \rangle}{\|v_{t-1}\|^2 + \|v_t\|^2 - \langle v_{t-1}, v_t \rangle}, \quad (11)$$

式中,  $T_t$  表示特征相似度值;  $v_{t-1}$  和  $v_t$  分别为第  $t-1$  帧和第  $t$  帧目标区域的特征;  $\langle \cdot, \cdot \rangle$  表示内积.

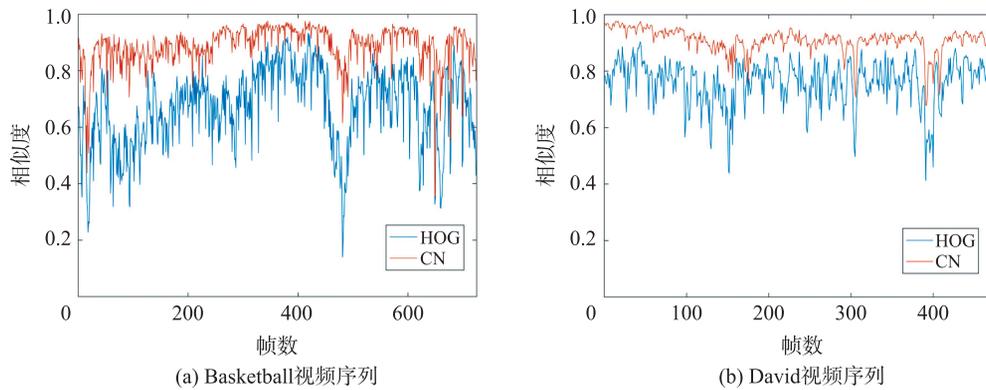


图2 不同视频序列的特征相似度对比图

Fig. 2 Similarity comparison diagram of different sequence

从图2可以看出,采用 HOG 特征计算的相似度波动程度较大,在不同视频序列中的变化范围有着很大差异;采用 CN 特征计算的相似度波动程度较小,在不同视频序列中变化范围相似.因此, CN 特征的相似度比较稳定,具有一定的普适性,故本文采用 CN 特征的相似度计算模型更新率.

通过选取不同的更新率进行测试,可以得出以下结论:过小的更新率、过多强调之前的目标信息,在目标发生快速变化时会因更新不及时导致跟踪失败;过大的更新率、过多强调当前的目标信息,在跟踪不准确时会快速引入错误的目标信息,导致跟踪失败;更新率在 0.012 到 0.02 之间跟踪结果较精确.为了在特征相似度较高时获得较低的更新率,而在特征相似度较低时更新率较高,同时在相似度过低时令更新率为固定值,避免因更新率过高导致模型更新不准确,因此,第  $t$  帧模型更新率的计算公式为:

$$\eta = \begin{cases} a-bT_t, & T_t > \text{threshold}; \\ 0.02, & \text{else.} \end{cases} \quad (12)$$

式中,  $a$ 、 $b$  和  $\text{threshold}$  为经验值.

综上,本文算法流程图如图 3 所示. 首先,提取目标区域的 HOG 特征和 CN 特征并进行降维;然后,分别训练,得到 HOG 特征和 CN 特征的响应图,根据 HOG 特征和 CN 特征响应图的置信度,自适应调整特征权重,并根据特征权重得到融合后的响应图,预测目标位置;最后,计算前后两帧目标区域 CN 特征的相似度自适应调整模型更新速率.

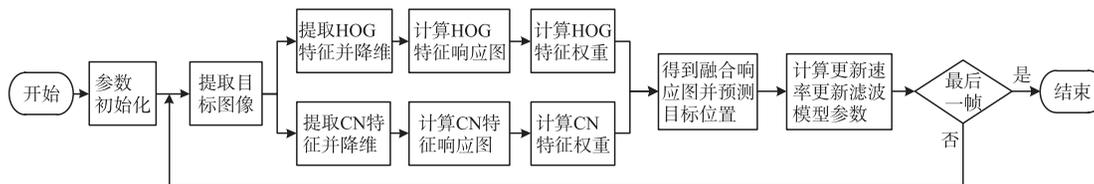


图 3 本文算法流程图

Fig. 3 Flow chart of the proposed algorithm

### 3 实验结果及分析

本文实验基于 VS2010 开发平台,使用 Opencv2.4.9 的库编程实现,PC 机配置为 Intel(R) Core(TM) i5-3337U CPU,主频 1.80 GHz,6 GB 内存. 为了评估本文算法的跟踪性能,采用文献[21]中提出的精确度 (distance precision, DP) 和成功率 (success rate, SR) 两个评价指标对跟踪性能进行分析.

DP 是指中心位置误差 (center location error, CLE) 小于阈值的帧数占整个视频序列帧数的百分比. CLE 的计算公式为:

$$CLE = \sqrt{(x_T - x_C)^2 + (y_T - y_C)^2}, \quad (13)$$

式中,  $(x_C, y_C)$  是真实的目标中心位置坐标;  $(x_T, y_T)$  是跟踪到的目标中心位置坐标.

SR 是指重叠精度 (overlap precision, OP) 小于阈值的帧数占整个视频序列帧数的百分比. OP 的计算公式为:

$$OP = \frac{|r_T \cap r_C|}{|r_T \cup r_C|}, \quad (14)$$

式中,  $r_T$  为跟踪到的目标区域面积;  $r_C$  为目标真实区域面积.

算法的参数设置为: HOG 特征的降维维度  $d_{HOG} = 5$ , CN 特征的降维维度  $d_{CN} = 3$ , 特征权重更新率  $\lambda = 0.02$ ; 模型更新率中的参数  $a = 0.032$ ,  $b = 0.02$ ,  $\text{threshold} = 0.6$ ; 其他参数设置与文献[12]相同. 在整个实验过程中,参数保持不变.

算法实验分析选取整个 OTB-50 数据集的 49 组视频序列进行了两组实验. 实验 1: 在 KCF 算法的框架中且不改变模型更新率的前提下,将本文特征融合算法和采用单一 HOG 特征、单一 CN 特征以及特征直接串联的线性叠加融合方法进行对比,验证本文特征融合方法的有效性. 实验 2: 加入模型更新率自适应调整,将本文算法与 MS\_TLD 算法<sup>[6]</sup>、KCF 算法<sup>[12]</sup>、CNT 算法<sup>[13]</sup>、ASMS 算法<sup>[2]</sup>、TLD 算法<sup>[4]</sup> 和 CSK 算法<sup>[11]</sup> 进行对比分析,评估跟踪算法的性能.

图 4 为实验 1 在 KCF 算法的框架下采用不同特征跟踪得到的精确度与成功率曲线. 可以看出,使用多个特征跟踪比使用单一特征跟踪的效果更好,但不同的融合方法得到的跟踪结果不同. 本文特征融合方法通过对响应图的计算分析来调节两个响应图的权重,使跟踪结果整体上比直接串联的线性融合方法更好.

图 5 为实验 2 本文算法与其他 6 种算法的精确度与成功率曲线,本文算法在曲线图中的标记为 Proposed. 可以看出,本文算法比其他算法具有更高的算法精度. 在速度方面,由于本文算法在每次迭代时加入了对响应图的计算分析来调节响应图权重,且计算前后两帧 CN 特征的相似度来调节模型更新速率,增加了算法的运算耗时,但本文算法使用主成分分析法对特征进行降维,将原本的 41 维特征降低至 8 维,在显著提升速度的同时又不影响精度.

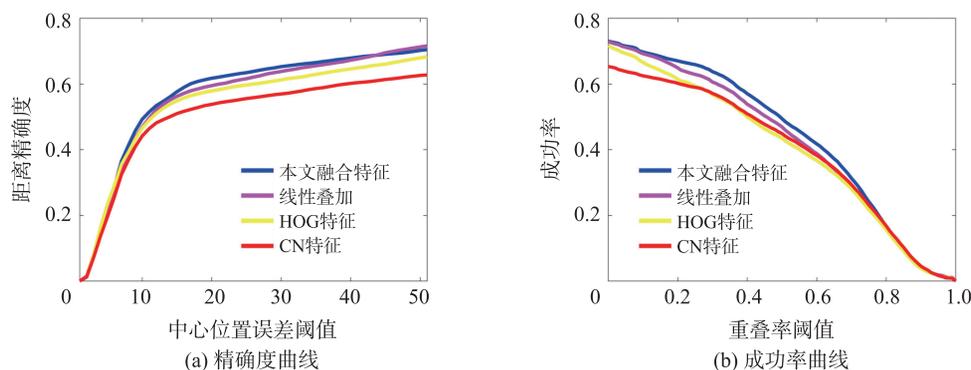


图 4 OTB-50 数据集上不同特征跟踪的精确度与成功率曲线

Fig. 4 The accuracy curve and success rate curve of different feature tracking in OTB-50 dataset

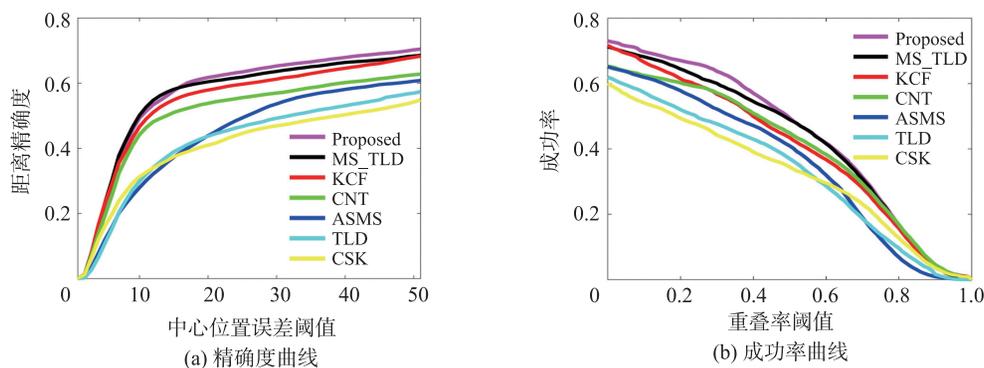


图 5 OTB-50 数据集上 7 种算法的精确度与成功率曲线

Fig. 5 The accuracy curve and success rate curve of 7 algorithms in OTB-50 dataset

## 4 结论

本文在核相关滤波跟踪算法的框架下,提出了一种自适应特征融合和模型更新的核相关滤波跟踪算法.该算法从特征自适应融合和更新率自适应调整两方面进行了改进,克服了传统核相关滤波跟踪算法特征表达不足以及采用线性插值模型更新策略造成模型漂移的问题.

本文算法首先使用主成分分析法对 HOG 特征和 CN 特征进行降维,以提高算法的运行速度;其次分别计算降维后的 HOG 特征和 CN 特征响应图,用得到的响应图的峰值与平均峰值相关能量值的乘积自适应调整响应图权重,进行响应图的加权融合,增加了目标的特征表达,且不影响速度;最后通过计算前后两帧的 CN 特征相似度来调整模型更新率,提高了模型更新的准确性.

为了验证本文算法的有效性,在 OTB-50 数据集上进行了对比实验,结果表明,本文算法跟踪性能优于其他算法,能够提高处理速度.

## [参考文献] (References)

- [1] 卢湖川,李佩霞,王栋. 目标跟踪算法综述[J]. 模式识别与人工智能,2018,31(1):61-76.
- [2] VOJIR T,NOSKOVA J,MATAS J. Robust scale-adaptive mean-shift for tracking[J]. Pattern Recognition Letters,2014,49:250-258.
- [3] ZHANG T Z,XU C S,YANG M H. Learning multi-task correlation particle filters for visual tracking[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence,2019,41(2):365-378.
- [4] KALAL Z,MIKOLAJCZYK K,MATAS J. Tracking-learning-detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence,2012,34(7):1409-1422.
- [5] HARE S,GOLODETZ S,SAFFARI A,et al. Struck:structured output tracking with kernels[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence,2016,38(10):2096-2109.

- [6] 张惊雷,时鹏,温显斌. 基于尺度自适应均值偏移优化的 TLD 跟踪算法[J]. 控制与决策,2019,34(1):144-150.
- [7] CHI Z,LI H,LU H,et al. Dual deep network for visual tracking[J]. IEEE Transactions on Image Processing,2017,26(4):2005-2015.
- [8] GORDON D,FARHADI A,FOX D. Re3:real-time recurrent regression networks for visual tracking of generic objects[J]. IEEE Robotics and Automation Letters,2018,3(2):788-795.
- [9] WANG Q,ZHANG L,BERTINETTO L,et al. Fast online object tracking and segmentation:a unifying approach[C]//IEEE Conference on Computer Vision and Pattern Recognition. Los Angeles:IEEE,2019:1328-1338.
- [10] 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. San Francisco:IEEE,2010:2544-2550.
- [11] 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. Singapore:IEEE,2012:702-715.
- [12] 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.
- [13] 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. Columbus:IEEE,2014:1090-1097.
- [14] BERTINETTO L,VALMADRE J,GOLODETZ S,et al. Staple:complementary learners for real-time tracking[C]//IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas:IEEE,2016:1401-1409.
- [15] 茅正冲,陈海东. 基于核相关滤波的长期目标跟踪算法[J]. 激光与光电子学进展,2019,56(1):94-101.
- [16] ASHA C S,NARASIMHADHAN A V. Adaptive learning rate for visual tracking using correlation filters[J]. Procedia Computer Science,2016,89:614-622.
- [17] 陈智,柳培忠,骆炎民,等. 自适应特征融合的多尺度相关滤波目标跟踪算法[J]. 计算机辅助设计与图形学学报,2018,30(11):2063-2073.
- [18] WANG M,LIU Y,HUANG Z. Large margin object tracking with circulant feature maps[C]//IEEE Conference on Computer Vision and Pattern Recognition. Honolulu:IEEE,2017:4800-4808.
- [19] SINGH G,CHHABRA I. Effective and fast face recognition system using complementary OC-LBP and HOG feature descriptors with SVM classifier[J]. Journal of Information Technology Research,2018,11(1):91-110.
- [20] DANELLJAN M,HÄGER G,KHAN F S,et al. Discriminative scale space tracking[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence,2016,38(8):1561-1575.
- [21] WU Y,LIM J,YANG M H. Object tracking benchmark[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence,2015,37(9):1834-1848.

[责任编辑:严海琳]