

特征权值与尺度自适应的核相关跟踪算法

朱宏基*, 于凤芹

江南大学物联网工程学院, 江苏 无锡 214122

摘要 提出了一种特征权值与尺度自适应的核相关跟踪算法。提取目标搜索区域的方向梯度直方图(HOG)特征和颜色名(CN)特征进行自适应权值融合,通过融合特征的相关滤波响应图的峰值找到目标位置;利用权值较大特征的相关滤波响应图的峰值和峰值旁瓣比的乘积作为尺度评估依据,对目标尺度进行粗略估计和精确估计,从而得到目标的最佳尺度。通过在目标跟踪标准(OTB-2013)数据集上的仿真实验,结果表明相比核相关滤波跟踪算法以及其他 5 种跟踪算法,所提算法在跟踪精度和成功率方面都有明显提高,跟踪精度为 0.799,成功率为 0.723,能较好地适应目标尺度的变化。

关键词 机器视觉; 目标跟踪; 核相关滤波; 特征融合; 尺度自适应

中图分类号 TP391 **文献标识码** A

doi: 10.3788/LOP56.101501

Feature-Weight and Scale Adaptive Algorithm for Kernel Correlation Tracking

Zhu Hongji*, Yu Fengqin

School of Internet of Things, Jiangnan University, Wuxi, Jiangsu 214122, China

Abstract A kernel correlation tracking algorithm exhibiting feature-weight and scale adaptation is proposed. The histogram of oriented gradient (HOG) and the color name (CN) features of the target search area are extracted for performing adaptive weight fusion, and the target position is estimated using the peak value of the correlation filter response map of the fusion feature. Further, using the product of the peak value of the correlation filter response map and the peak sidelobe ratio of the large weighted feature as the basis for scale estimation, the rough and accurate estimations of the target scale are performed and utilized to obtain the optimal scale of the target. The results of the simulation experiments performed using the object tracking benchmark (OTB-2013) dataset show that the proposed algorithm exhibits obvious improvements in terms of tracking precision and success rate compared with other five tracking algorithms. The tracking precision and success rate obtained using the proposed algorithm are 0.799 and 0.723, respectively. Furthermore, the proposed algorithm can well adapt to the change of target scale.

Key words machine vision; target tracking; kernel correlation filtering; feature fusion; scale adaptation

OCIS codes 150.1135; 100.4999; 070.4550

1 引言

目标跟踪是计算机视觉的一个十分热门且重要的课题,在视频监控、人机交互以及智能交通等领域都有十分广泛的应用^[1-2]。但受复杂场景及目标外观剧烈变化等因素影响,目标跟踪仍是一个极具挑战的问题^[3]。

目标跟踪算法可分为生成类方法^[4-5]和判别类

方法^[6-8]两大类。由于后者同时考虑了背景与目标信息,在目标跟踪算法中具有明显优势。近年来,基于相关滤波的判别类方法被广泛用于目标跟踪算法的研究。Henriques 等^[9]提出一种 CSK (Circulant structure of tracking-by-detection with kernels)算法,该算法通过样本的循环移位获取大量训练样本,算法的准确性较高,但由于 CSK 采用的是灰度特征,易受目标复杂背景、相似颜色的干扰。Danelljan

收稿日期: 2018-11-13; 修回日期: 2018-12-10; 录用日期: 2018-12-20

基金项目: 国家自然科学基金(61573168)、中央高校基本科研业务费专项资金(JUSRP51733B)

* E-mail: zhu_hongji_purpose@163.com

等^[10]将颜色名(CN)特征引入到CSK中,提出CN跟踪算法,进一步提高了跟踪准确性。Henriques等^[11]提出核相关滤波(KCF)算法,采用多通道的梯度直方图(HOG)特征,显著提升了跟踪性能。然而这些算法都不能很好地适应目标尺度的变化,且均采用单一特征表示目标。

针对这些问题,潘振福等^[12]在KCF算法基础上采用尺度滤波器估计目标尺度,提高了算法适应目标尺度变化的能力。Li等^[13]提出的尺度自适应的多特征滤波器(SAMF)跟踪算法,采用灰度、CN和HOG特征串联的方式训练滤波器,并加入尺度估计策略,虽然提高了算法的跟踪精度,但不能满足实时性要求。李聪等^[14]融合Lab颜色特征与HOG特征,建立目标的尺度模型,得到了较好的跟踪效果。Montero等^[15]利用特征点检测跟踪作为尺度估计策略融入KCF算法中,得到了不错的跟踪效果。Akin等^[16]采用分块模型的方法提出一种可变形分块的相关滤波跟踪算法,有效地解决了目标尺度的变化。本文在KCF算法框架上,提出特征权值与尺度自适应的核相关跟踪算法。通过自适应权值的方式融合HOG特征和CN特征,利用融合特征的相关滤波响应图的峰值求出目标位置,并借鉴文献^[13]的尺度估计思路,提高尺度估计的有效性和速度。本文采用权值较大特征的相关滤波响应图峰值和峰值旁瓣比(PSR)的乘积评判尺度得分,并将尺度估计分为粗略估计和精确估计两步来提高尺度估计速度。

2 KCF跟踪器

在KCF^[11]中,利用前一帧的目标位置与尺度扩大的搜索区域作为样本 \mathbf{x} ,通过循环移位得到大量训练样本 \mathbf{x}_i ,其中 i 为样本序号。训练的目的是使回归函数 $f(\mathbf{x}_i) = \mathbf{w}^T \boldsymbol{\varphi}(\mathbf{x}_i)$ 的回归误差最小化得到分类器,即

$$\min_{\mathbf{w}} \sum_i [\mathbf{w}^T \boldsymbol{\varphi}(\mathbf{x}_i) - \mathbf{y}_i]^2 + \lambda \|\mathbf{w}\|^2, \quad (1)$$

式中: T 表示转置; λ 为正则化系数; \mathbf{w} 为分类器参数; $\boldsymbol{\varphi}(\mathbf{x}_i)$ 表示样本 \mathbf{x}_i 的非线性变换; \mathbf{y}_i 是样本标签,由高斯函数得到。

引入核策略以后, \mathbf{w} 可由 $\boldsymbol{\varphi}(\mathbf{x}_i)$ 的线性组合表示, $\mathbf{w} = \sum_i \alpha_i \boldsymbol{\varphi}(\mathbf{x}_i)$,其中 α 是滤波器学习系数。令核函数 $\kappa(\mathbf{x}, \mathbf{x}') = \langle \boldsymbol{\varphi}(\mathbf{x}), \boldsymbol{\varphi}(\mathbf{x}') \rangle$,其中 \mathbf{x} 和 \mathbf{x}' 表示两个不同的训练样本, $\langle \cdot \rangle$ 表示内积,这样回归函数就变为 $f(\mathbf{x}) = \sum_i \alpha_i \kappa(\mathbf{x}_i, \mathbf{x})$ 。将(1)式的回归函数和 \mathbf{w} 替换后, \mathbf{w} 的优化问题就转变为对 α 的求解,

利用循环矩阵的性质求解可得到

$$\hat{\boldsymbol{\alpha}} = \frac{\hat{\mathbf{y}}}{\hat{\mathbf{k}}^{xx'} + \lambda}, \quad (2)$$

式中: $\hat{\boldsymbol{\alpha}}$ 是 $\boldsymbol{\alpha}$ 的离散傅里叶变换; $\hat{\mathbf{y}}$ 为样本标签 \mathbf{y} 的离散傅里叶变换; $\hat{\mathbf{k}}^{xx'}$ 表示 $\kappa(\mathbf{x}, \mathbf{x}')$ 中的元素。KCF算法中采用高斯核函数表示

$$\hat{\mathbf{k}}^{xx'} = \exp\left\{-\frac{1}{\sigma^2} [\|\mathbf{x}\|^2 + \|\mathbf{x}'\|^2 - 2\mathcal{F}^{-1}(\hat{\mathbf{x}}^* \odot \hat{\mathbf{x}}')]\right\}, \quad (3)$$

式中: σ 为核函数参数; $*$ 表示复共轭; \odot 表示元素的点积; \mathcal{F}^{-1} 表示离散傅里叶逆变换。

利用训练好的分类器对当前帧的目标搜索区域 \mathbf{z} 进行检测,得到相关滤波响应图。

$$f(\mathbf{z}) = \mathcal{F}^{-1}(\hat{\mathbf{k}}^{xz} \odot \hat{\boldsymbol{\alpha}}), \quad (4)$$

式中: \mathbf{x} 为目标外观模型,通过寻找相关滤波响应图的峰值位置得到当前帧目标位置。

3 特征权值与尺度自适应的核相关跟踪算法

3.1 自适应权值特征融合

KCF算法中采用HOG特征表示目标,利用目标搜索区域的HOG特征作为(3)式高斯核函数的输入。但研究发现,HOG特征虽然对目标的颜色变化、背景光照变化具有很强的稳健性,但对目标形变的稳健性较差。CN特征则对目标形变具有很好的稳健性,但对光照变化的稳健性较差。为了提高特征的表示能力,本文采用一种自适应权值的方式将具有互补特性的HOG特征和CN特征进行融合。考虑到在跟踪系统中峰值旁瓣比(PSR)可以量化相关峰值的锐度,PSR值越高意味着跟踪的置信度越高,当前帧和前一帧之间的匹配分数越高。而相关滤波响应图的峰值越大,是目标位置的可能性也越大。因此,根据两种特征的相关滤波响应图的峰值和峰值旁瓣比计算特征融合权值。

峰值旁瓣比的定义为

$$P_{\text{PSR}} = \frac{\max[f_t(\mathbf{z})] - \mu_t}{\sigma_t}, \quad (5)$$

式中: $\max[f_t(\mathbf{z})]$ 为相关滤波响应图第 t 帧的峰值; μ_t 和 σ_t 分别为除峰值区域以外旁瓣的均值和标准差。

特征融合自适应权值的计算方式为

$$g_{\text{HOG}} = \frac{\max(f_{\text{HOG},t}) \times P_{\text{PSR, HOG},t}}{\max(f_{\text{HOG},t}) \times P_{\text{PSR, HOG},t} + \max(f_{\text{CN},t}) \times P_{\text{PSR, CN},t}}, \quad (6)$$

式中： g_{HOG} 为第 t 帧时 HOG 特征的融合权值比例； $P_{\text{PSR, HOG},t}$ 和 $P_{\text{PSR, CN},t}$ 分别为 HOG 特征和 CN 特征第 t 帧的 PSR 值。为了防止权值漂移，采用线性插值的方式更新权值，即

$$g_{\text{HOG},t} = (1 - \theta) \times g_{\text{HOG},t-1} + \theta \times g_{\text{HOG}}, \quad (7)$$

式中： θ 为融合权值的学习系数； $g_{\text{HOG},t}$ 为第 t 帧是 HOG 特征的融合权值。

利用两种特征的融合权值计算融合特征的相关滤波响应图

$$f_t(z) = g_{\text{HOG},t} \times f_{\text{HOG},t}(z) + (1 - g_{\text{HOG},t}) \times f_{\text{CN},t}(z), \quad (8)$$

式中： $f_{\text{HOG},t}$ 和 $f_{\text{CN},t}$ 分别为 HOG 和 CN 特征第 t 帧时相关滤波响应图。进而根据 $f_t(z)$ 的峰值位置得到目标位置。

3.2 快速尺度估计

KCF 跟踪算法采用固定的目标搜索区域，伴随着目标尺度的变化，背景信息对模型的干扰加大，容易产生模型漂移。为了保证跟踪的准确性，对目标的尺度变化进行估计。目前尺度估计算法的一种常见思路是采用多个尺度目标搜索区域分别进行训练，将相关滤波响应图峰值最大的尺度，作为目标的最佳尺度。这种作法虽然可以得到较好的估计结果，但容易造成尺度冗余且影响算法的速度。

为加强相关滤波响应图的峰值判断目标尺度变化的可靠性，采用可以评判跟踪的置信度的峰值旁瓣比来进一步验证峰值的有效性。利用当前帧中权值较大的特征相关滤波响应图的峰值和峰值旁瓣比乘积来评估不同尺度目标搜索区域的得分，得分采用 S_{core} 表示，表达式为

$$S_{\text{core}} = \max(f_t) \times P_{\text{PSR},t}, \quad (9)$$

式中： $P_{\text{PSR},t}$ 和 $\max(f_t)$ 分别表示第 t 帧目标搜索区域的峰值旁瓣比和相关滤波响应图的峰值。

为了提高尺度估计的速度，将尺度估计分为粗略估计和精确估计两步。粗略估计只采用三个尺度目标搜索区域 $\{s_0, a_i s_0, a_j s_0\}$ ，其中 s_0 表示原始目标搜索区域， a_i 和 a_j 分别表示尺度因子， $a_i s_0$ 和 $a_j s_0$ 分别表示缩小和扩大的目标搜索区域。利用(9)式的得分对目标尺度变化进行粗略估计，确定目标的尺度变化方向。

精确估计中，若 s_0 的 S_{core} 值最大，说明目标尺度没有发生改变，保持原有尺寸；若 $a_i s_0$ 的 S_{core} 值最大，说明尺度往减小方向发展，则采用等差方式不断减小尺度因子 a_i ，找到最大 S_{core} 值的尺度因子，得到最佳目标尺度；若 $a_j s_0$ 的 S_{core} 值最大，说明尺度往增大方向发展，则采用等差方式不断增大尺度因子 a_j ，找到最大 S_{core} 值的尺度因子，得到最佳目标尺度。本文仿真实验中设置初始尺度因子 $a_i = 0.99$ ， $a_j = 1.01$ ，公差 $d = 0.01$ ，初始尺度因子与公差均为经验值。

3.3 算法实现步骤

提出的特征权值与尺度自适应的核相关跟踪算法可分为目标位置检测和尺度估计两部分，具体步骤如下。

1) 位置检测部分

①第 t 帧时，利用目标尺度 S_{t-1} 和位置 P_{t-1} 分别提取目标的 HOG 特征和 CN 特征，利用(6)式得到特征的融合权值比例，并通过(7)式更新得到特征的融合权值。

②通过(8)式得到融合特征的相关滤波响应图，由响应图峰值的位置找到第 t 帧的目标位置 P_t 。

2) 尺度估计部分

①第 t 帧时，利用目标位置检测部分得到目标位置 P_t ，在目标位置上采集三个不同尺度的目标搜索区域，利用(9)式计算不同尺度的目标搜索区域的得分，粗略估计尺度的变化方向。

②在尺度变化方向上，等差方式采集不同尺度的目标搜索区域，利用(9)式比较不同搜索区域的尺度得分，通过得分最高的目标搜索区域得到最佳目标尺度 S_t ，并将 P_t 和 S_t 输出给下一帧。

4 仿真实验结果与分析

4.1 实验环境与参数设置

为了测试所提算法的准确率以及适应目标尺度变化的能力，将所提算法与当前 6 种主流算法 Struck^[7] (Structured output tracking with kernels, Struck)、TLD^[8] (Tracking learning detection, TLD)、CSK^[9]、CN^[10]、KCF^[11]、SAMP^[13] 在目标跟踪标准(OTB-2013)测试平台上利用 51 个测试视频序列进行对比实验。性能评估方法采用 Wu 等^[17]

提出的一次通过评估(OPE),分别得到跟踪的精度曲线(Precision plot)和成功率曲线(Success plot)。

本文所有实验硬件环境均为配置 Intel Core i5-4200M CPU,2.50 GHz 主频,4G 内存的联想 G510 笔记本,算法开发平台为 Matlab R2016a。所提算法中参数设置:相关滤波器学习参数为 0.015,HOG 特征的正则化参数为 10^{-3} ,CN 特征的正则化参数为 10^{-2} ,HOG 特征和 CN 特征的初始化权值都是 0.5,权值学习参数为 0.2,其余参数都和 KCF 算法相同。

4.2 定性分析

图 1 为不同算法在 7 个视频序列中的跟踪结果,用来定性分析算法在不同情形下的有效性。




图 1 7 种场景下,不同算法的跟踪结果。(a) Doll; (b) Skating 1; (c) Singer 2; (d) Jogging-2; (e) David 3; (f) Basketball; (g) Bolt

Fig. 1 Tracking results obtained using different algorithms in 7 scenarios with different attributes. (a) Doll; (b) Skating 1; (c) Singer 2; (d) Jogging-2; (e) David 3; (f) Basketball; (g) Bolt

1) 尺度变化分析:以视频序列 Doll 和 Skating 1 为例,Doll 序列中玩具和 Skating 1 序列中滑冰者,在运动过程一直发生着尺度变化,所提算法和 SAMF 算法能够一直保持很高的准确度来跟踪目

标,且始终能够较好地适应目标尺度的变化。KCF 算法、CN 算法虽然还能跟上目标,但不能适应目标尺度变化,而且对于背景环境相对复杂的 Skating 1 序列,Struck 算法与 TLD 算法均出现了目标丢失的现象。

2) 光照变化分析:以视频序列 Singer 2 为例,歌手在演唱过程中背景灯光不断变化,在第 41 帧时其周围发生了较为强烈的光照变化,所提算法和 KCF 算法能够准确跟踪目标,其他几种算法已经不能跟踪上目标。

3) 抗遮挡分析:以视频序列 Jogging-2 和 David 3 为例,当目标未发生遮挡时,7 种算法都能准确跟踪目标。而在 Jogging-2 的第 57 帧和 David 3 的第 86 帧目标发生部分遮挡时,所提算法、SAMF 算法和加入了重检测机制的 TLD 算法均能够较为准确地跟踪目标,其他算法则都出现了不同程度的目标丢失现象。

4) 目标形变分析:以视频序列 Basketball 和 Bolt 为例,篮球运动员和赛跑运动员在运动过程中不断地发生形变,且有时还会存在部分遮挡。所提算法和 KCF 算法、SAMF 算法能一直准确跟踪目标,CSK 算法、Struck 算法以及 TLD 算法则已经丢失了目标。

4.3 定量分析

为了综合评估所提算法的准确性和适应目标尺度变化的能力,对 OTB-2013 的 51 个视频序列和包含目标尺度变化的 28 个视频序列进行了一次性通过评估。图 2 和图 3 中方括号内的数值分别表示跟踪精度和跟踪成功率,它们分别指跟踪目标中心位置误差小于 20 pixel 和跟踪目标的重叠率大于 0.5 时,算法跟踪成功帧数占视频总帧数的比值。图 2 是所提算法和其他 6 种对比算法在 51 个视频序列的距离精度曲线图和成功率曲线图。从图 2 可以看出,所提算法的跟踪精度为 0.799,成功率为 0.723,相比 SAMF 算法精度提高了 2.5%,相比 KCF 算法精度提高了 5.9%,成功率提高了 10.0%。

图 3 是所提算法和其他 6 种对比算法在具有尺度变化的视频序列的测试结果。从图 3 可以看出,所提算法跟踪精度比 SAMF 算法提高了 3.0%,比 KCF 算法提高了 5.4%,跟踪成功率比 KCF 算法提高了 13.4%,且和第一名的 SAMF 算法相近。这说明所提算法具有较好的适应目标尺度变化的能力。

为更好地分析所提算法的优缺点,表 1 和表 2 列出了 7 种算法在包含 11 种不同属性场景的 51 个

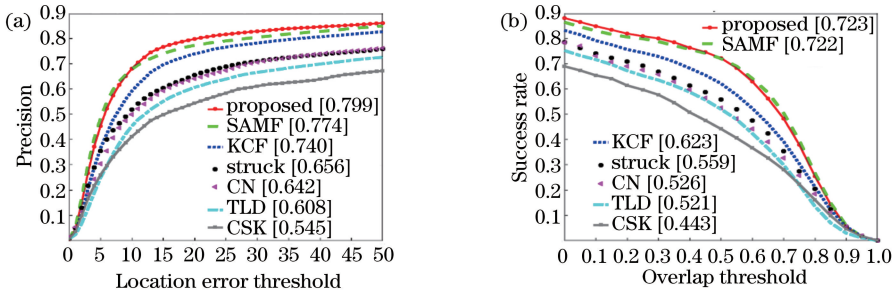


图 2 51 个视频序列的结果。(a)精度图;(b)成功率图

Fig. 2 Results of 51 video sequences. (a) Precision plot; (b) success rate plot

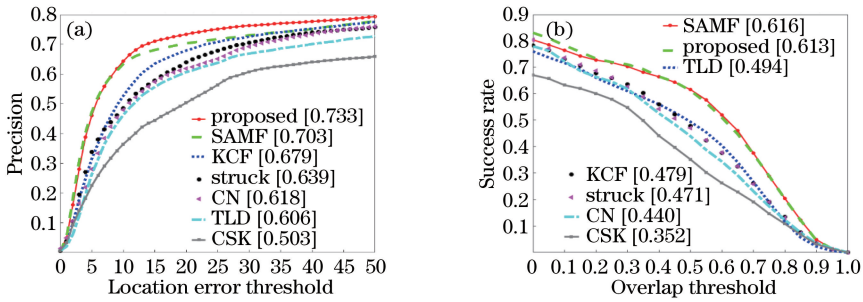


图 3 28 个尺度变化视频序列的测试结果。(a)精度图;(b)成功率图

Fig. 3 Test results of 28 video sequences with scale variation. (a) Precision plot; (b) success rate plot

视频序列上实验,得到的 11 种属性下算法的跟踪精度和成功率。表格的第 1 列为测试算法,第 1 行为有不同属性名称的缩写,括号内数字表示该种属性的视频序列个数。11 种属性包括:光照变化(IV)、尺度变化(SV)、遮挡(OCC)、目标形变(DEF)、快速运动

(FM)、移动模糊(MB)、出视野(OV)、背景杂乱(BC)、低分辨率(LR)、面内旋转(IPR)、面外旋转(OPR)。从表 1 和表 2 可以看出,除了包含快速移动、移动模糊以及出视野的视频序列以外,所提算法的跟踪精度和成功率都处于最优或者次优位置。

表 1 7 种算法在 11 种不同属性场景下的跟踪精度

Table 1 Tracking precision of 7 algorithms in 11 scenarios with different attributes

Algorithm	IV (25)	SV (28)	OCC (29)	DEF (19)	FM (17)	MB (12)	OV (6)	BC (21)	LR (4)	IPR (31)	OPR (39)
Proposed	0.748	0.733	0.834	0.814	0.561	0.548	0.617	0.733	0.584	0.764	0.796
SAMF	0.682	0.703	0.820	0.810	0.608	0.564	0.636	0.676	0.385	0.714	0.767
KCF	0.728	0.679	0.749	0.740	0.602	0.650	0.650	0.753	0.381	0.725	0.729
Struck	0.558	0.639	0.564	0.521	0.604	0.551	0.539	0.585	0.545	0.617	0.597
CN	0.603	0.618	0.642	0.637	0.530	0.604	0.499	0.612	0.490	0.677	0.661
TLD	0.537	0.606	0.563	0.512	0.551	0.518	0.576	0.428	0.349	0.584	0.596
CSK	0.481	0.503	0.500	0.476	0.381	0.342	0.379	0.585	0.411	0.547	0.540

表 2 7 种算法在 11 种不同属性场景下的跟踪成功率

Table 2 Tracking success rates of 7 algorithms in 11 different attribute scenarios

Algorithm	IV (25)	SV (28)	OCC (29)	DEF (19)	FM (17)	MB (12)	OV (6)	BC (21)	LR (4)	IPR (31)	OPR (39)
Proposed	0.678	0.613	0.750	0.785	0.558	0.553	0.633	0.681	0.524	0.690	0.702
SAMF	0.641	0.616	0.765	0.804	0.593	0.561	0.646	0.655	0.370	0.653	0.699
KCF	0.581	0.479	0.618	0.671	0.557	0.595	0.650	0.672	0.357	0.615	0.608
Struck	0.491	0.471	0.493	0.473	0.567	0.518	0.550	0.545	0.410	0.528	0.506
CN	0.484	0.440	0.509	0.553	0.501	0.557	0.496	0.536	0.447	0.555	0.524
TLD	0.460	0.494	0.468	0.456	0.473	0.482	0.516	0.491	0.327	0.476	0.497
CSK	0.388	0.352	0.404	0.370	0.380	0.336	0.410	0.388	0.397	0.457	0.439

在同一实验环境下对 51 个视频序列进行跟踪实验可知,所提算法在 51 个视频序列上的跟踪速度为 $9.08 \sim 69.42 \text{ frame} \cdot \text{s}^{-1}$, 平均跟踪速度为 $21.71 \text{ frame} \cdot \text{s}^{-1}$, KCF 算法的平均跟踪速度为 $129.38 \text{ frame} \cdot \text{s}^{-1}$ 。所提算法融合了 HOG 特征和 CN 特征,且加入了尺度估计策略,速度相比 KCF 算法慢了许多,但仍能够保持较好的时效性。

5 结 论

在 KCF 算法的基础上,提出了一种特征权值与尺度自适应的核相关跟踪算法。将 CN 特征通过自适应权值策略和 HOG 特征进行融合,提高了算法特征的表示能力,并加入尺度估计策略,可快速估计出目标的最佳尺度,从而适应目标在运动过程中的尺度变化。仿真实验表明:本文算法在跟踪准确性上有较大提高,且在不同属性的视频场景中均具有较好的适应性。但该算法对目标被严重或者长时遮挡,以及出视野等情形不能很好地处理,容易产生模型漂移,无法准确地跟踪目标。针对这一问题,如何进行目标的重检测,将作为是下一步研究的重点。

参 考 文 献

- [1] Smeulders A W M, Chu D M, Cucchiara R, *et al.* Visual tracking: an experimental survey [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2014, 36(7): 1442-1468.
- [2] Lu H C, Li P X, Wang D. Visual object tracking: a survey [J]. Pattern Recognition and Artificial Intelligence, 2018, 31(1): 61-76.
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.
- [3] Ge B Y, Zuo X Z, Hu Y J. Review of visual object tracking technology [J]. Journal of Image and Graphics, 2018, 23(8): 1091-1107.
葛宝义, 左宪章, 胡永江. 视觉目标跟踪方法研究综述[J]. 中国图象图形学报, 2018, 23(8): 1091-1107.
- [4] Ross D A, Lim J, Lin R S, *et al.* Incremental learning for robust visual tracking[J]. International Journal of Computer Vision, 2008, 77(1/2/3): 125-141.
- [5] Kwon J, Lee K M. Visual tracking decomposition [C] // 2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, June 13-18, 2010, San Francisco, CA, USA. New York: IEEE, 2010: 1269-1276.

- [6] Liao X F, Hou Z Q, Yu W S, *et al.* A scale adapted tracking algorithm based on kernelized correlation [J]. Acta Optica Sinica, 2018, 38(7): 0715002.
廖秀峰, 侯志强, 余旺盛, 等. 基于核相关的尺度自适应视觉跟踪 [J]. 光学学报, 2018, 38(7): 0715002.
- [7] Hare S, Saffari A, Torr P H S. Struck: Structured output tracking with kernels[C] // 2011 International Conference on Computer Vision, November 6-13, 2011, Barcelona, Spain. New York: IEEE, 2011: 263-270.
- [8] Kalal Z, Mikolajczyk K, Matas J. Tracking-learning-detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2012, 34(7): 1409-1422.
- [9] Henriques J F, Caseiro R, Martins P, *et al.* Exploiting the circulant structure of tracking-by-detection with kernels[M] // Henriques J F, Caseiro R, Martins P, *et al.* Computer Vision-ECCV 2012. Berlin, Heidelberg: Springer-Verlag, 2012: 702-715.
- [10] 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, June 23-28, 2014, Columbus, OH, USA. New York: 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 and Machine Intelligence, 2015, 37(3): 583-596.
- [12] Pan Z F, Zhu Y L. Kernelized correlation filters object tracking method with multi-scale estimation [J]. Laser & Optoelectronics Progress, 2016, 53(10): 101501.
潘振福, 朱永利. 多尺度估计的核相关滤波器目标跟踪方法 [J]. 激光与光电子学进展, 2016, 53(10): 101501.
- [13] Li Y, Zhu J K. A Scale adaptive kernel correlation filter tracker with feature integration[M] // Li Y, Zhu J K. Computer Vision-ECCV 2014 Workshops. Cham: Springer International Publishing, 2015: 254-265.
- [14] Li C, Lu C Y, Zhao X, *et al.* Scale adaptive correlation filtering tracking 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.

- [15] Montero A S, Lang J, Laganière R. Scalable kernel correlation filter with sparse feature integration[C]// 2015 IEEE International Conference on Computer Vision Workshop (ICCVW), December 7-13, 2015, Santiago, Chile. New York: IEEE, 2015: 587-594.
- [16] 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.
- [17] Wu Y, Lim J, Yang M H. Online object tracking: A benchmark[C]//2013 IEEE Conference on Computer Vision and Pattern Recognition, June 23-28, 2013, Portland, OR, USA. New York: IEEE, 2013: 2411-2418.