

响应置信度的多特征融合核相关滤波跟踪算法

顾明琨, 钟小勇

(江西理工大学 理学院, 江西 赣州 341000)

摘要: 针对传统核相关滤波(KCF)在跟踪彩色视频序列不能有效利用颜色特征,并且处理目标遮挡和形变能力低等问题,提出一种响应置信度的多特征融合核相关滤波跟踪算法;该算法首先提取目标图像的方向直方图特征和颜色直方图特征,通过计算高响应值点在响应图上层的占比,来判断目标的跟踪情况,进而调整学习率的大小;然后用两种特征的平均峰相关能量(APCE)和最大响应峰值的乘积来加权融合目标位置;实验对比表明,提出的跟踪算法在精度和成功率上相对于KCF算法分别提升了12.8%和22.6%,在目标发生遮挡、快速移动、旋转等复杂情况下仍然具有较强的鲁棒性。

关键词: 目标跟踪;核相关滤波;响应置信度;多特征融合;鲁棒性;目标遮挡

Multi-feature Fusion Kernel Correlation Filtering Tracking Algorithm Based on Response Confidence

GU Mingkun, ZHONG Xiaoyong

(School of Science, Jiangxi University of Science and Technology, Ganzhou 341000, China)

Abstract: Aiming at the problems that traditional kernel correlation filtering (KCF) cannot effectively utilize color features in tracking color video sequences, and the abilities of processing target occlusion and deformation become low, a filtering tracking algorithm for multi-feature fusion kernel correlation with response confidence was proposed. the orientation and color histogram features of target image is first extracted to determine the target tracking by calculating the percentage of high response value points in the upper layer of response map, and the size of the learning rate is adjusted; then the product of average peak correlation energy (APCE) and the maximum response peak of two features are used to weigh the fusion target positions. The experimental comparison shows that the proposed tracking algorithm improves by 12.8% of accuracy and 22.6% of success rate respectively compared with the KCF algorithm, and still has strong robustness under the complex situations of target occlusion, fast motion and rotation.

Keywords: object tracking; kernel correlation filter; response confidence; multi-feature fusion; robustness; object occlusion

0 引言

近年来,目标跟踪技术发展迅速,在视频监控、人机交互、智能交通等领域有着广泛的应用^[1-3]。但由于跟踪时存在着遮挡、形变、光照变化等因素影响,如何在复杂场景中准确跟踪目标仍是目标跟踪领域的难点问题。

目标跟踪方法按照处理方式的不同,可以分为两类,一类是生成类模型类,另一类是判别类模型类^[4]。早期的目标跟踪算法大多是生成类模型,生成模型类是对跟踪的目标建立模型并识别,在下一帧图像中搜索与当前模型中最为相似的区域作为预测区域。比较经典的算法有卡尔曼滤波^[5]与粒子滤波^[6]等。这种通过单一数学模型描述待跟踪目标的方法,不能全面利用图像的背景信息,当受到光照变化,运动模糊等干扰时,会对模型建立产生较大影响。

判别模型类是将目标模型和背景信息同时考虑在内,将目标跟踪看作是一个目标前景和背景的二分类问题,通过提取图像的特征,利用两者的差异进行在线学习来对分类器做相应的训练,该方法可以较好的提高跟踪精度。伴随着数字信号处理技术的发展,基于各种滤波方法的判别类模型由于其优异的性能和前景而受到学者们的青睐^[7-8]。相关滤波最初用于通信领域,用来描述信号之间的相关程度。在目标跟踪中则是将输入图像通过滤波器模板进行相关操作,得到一个尽可能理想的响应图,根据响应图最高峰的位置来确定目标的中心点。Bolme等学者在2010年提出的最小平方误差输出和跟踪算法(MOSSE, minimum output sum of squared error filter)^[9]首次把相关滤波的方法引入到目标跟踪中,并使用灰度特征进行学习,使得跟踪速度大幅提高,相关滤波器跟踪算法也因此备受关注。针对

收稿日期:2021-11-16; 修回日期:2022-01-04。

基金项目:国家自然科学基金(51665019);江西省研究生创新专项资金项目(YC2020-S479)。

作者简介:顾明琨(1996-),男,山东济宁人,硕士研究生,主要从事计算机视觉跟踪、智能信息处理方向的研究。

钟小勇(1964-),男,江西遂川人,高级工程师,硕士生导师,主要从事嵌入式系统、计算机视觉方向的研究。

引用格式:顾明琨,钟小勇.响应置信度的多特征融合核相关滤波跟踪算法[J].计算机测量与控制,2022,30(5):191-196,202.

MOSSE 算法中训练样本不足的问题, Henriques 等人对其进行改进, 提出循环结构的目标跟踪算法 (CSK, exploiting the circulant structure of tracking-by-detection with kernels)^[10], 利用循环矩阵的特性对样本密集采样, 生成训练样本集, 同时引入核函数, 提高在高维特征空间中分类样本的速度。随后 Henriques 等人又在原 CSK 算法的基础上进行改进, 使用方向梯度直方图 (HOG, histogram of oriented gradient)^[11]多通道特征替换 CSK 中的单通道灰度特征, 设计出了核相关滤波算法 (KCF, kernel correlation filter)^[12]。该算法结合了 CSK 速度快的优点, 使用了循环矩阵和快速傅里叶变换 (FFT, fast fourier transform), 并且在精确度和成功率上也有所提升, 但是无法进行尺度估计。之后, Danelljan 等人提出了判别式尺度空间目标跟踪算法 (DSST, discriminative scale space tracking)^[13], DSST 算法仍使用主流的 HOG 特征, 通过二维的位置滤波器确定跟踪目标的位置信息, 然后用一维的尺度滤波器对跟踪的目标进行尺度检测, 两个滤波器工作相互独立, 分别进行目标定位与尺度缩放。该尺度估计的方法可以很方便的移植到其他目标跟踪器中, 但对位置滤波器的精度要求较高。

以上算法的跟踪性能虽然一直在不断完善, 但均使用单一特征对目标进行跟踪, 使得目标出现形变、遮挡等因素时容易丢失目标。Li 等在 KCF 算法的基础上将颜色特征 (CN, color naming)^[14]和 HOG 特征进行通道融合, 提出了多特征尺度自适应目标跟踪算法 (SAMF, scale adaptive with multiple features tracker)^[15]。该算法对目标进行七个尺度的缩放, 然后使用一个滤波器同时进行尺度和位置的检测, 对不同尺度分别进行相关滤波操作得到对应的响应值, 比较选取响应值最大的一个作为最佳的目标尺度和位置。虽然该方法可以相互促进提高跟踪精度, 但是检测时每个尺度都要进行一次特征提取和 FFT 操作, 导致跟踪速度较慢, 无法满足实时性的要求。

针对上述问题, 本文以 KCF 滤波器为基础模型, 在使用多特征目标跟踪的基础上引入了预测位置加权融合机制。通过计算每种特征的平均峰相关能量 (APCE, average peak-to-correlation energy)^[16]所占权重和响应置信度以实现更精准的目标定位, 并提高算法了在形变、旋转、遮挡等场景下的鲁棒性。

1 核相关滤波跟踪算法

核相关滤波算法在跟踪过程中包含训练、检测和更新 3 个阶段^[17]。首先在帧图像中用矩形框框选出目标位置, 采集矩形框中的图像特征。然后进行循环移位构建出目标位于不同位置的训练样本集, 根据目标质心距离矩形框中心的远近赋予不同的标签。通过得到的训练样本集和其对应的标签训练出一个分类器, 之后将下一帧图像的特征输入给分类器, 计算最大响应位置来预测下一帧目标所在区域, 最后使用检测结果来更新训练集和分类器。

1.1 训练阶段

相关滤波算法将目标跟踪问题转化为求解最小平方误差下的岭回归问题。可以写为:

$$\min_{\omega} \sum_i (f(x_i) - y_i)^2 + \lambda \|\omega\|^2 \quad (1)$$

其中: x 是样本数据, y 是回归目标, λ 是正则项系数, 以防止过拟合, ω 表示分类器参数。求解岭回归的问题是为了找到一个使得样本 x_i 和回归目标 y_i 之间平方误差最小的决策函数 $f(x) = \omega^T x$, 使平方误差达到最小值。

将式 (1) 求偏导之后可以得到:

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

其中: \mathbf{I} 是单位矩阵, \mathbf{X} 是由基样本 $x = [x_1, x_2, \dots, x_n]^T$ 构造出的一个 $n \times n$ 循环矩阵。而所有的循环矩阵 $C(x)$ 都可以傅里叶域实现对角化, 因此有:

$$\mathbf{X} = C(x) = \mathbf{F} \text{diag}(\hat{x}) \mathbf{F}^H \quad (3)$$

符号 “ \cdot ” 是变量在傅里叶域中的表示, \mathbf{F}^H 为 \mathbf{F} 的共轭转置, diag 表示对角化。将式代入中可以得到:

$$\omega = \mathbf{F} \text{diag} \left(\frac{\hat{x}^*}{\hat{x}^* \odot \hat{x} + \lambda} \right) \mathbf{F}^H y \quad (4)$$

其中: 符号 “ \odot ” 表示元素对位相乘, 符号 “ $*$ ” 表示复共轭。将上述结果转换到傅里叶域中, 并将简化为:

$$\hat{\omega} = \frac{\hat{x} \odot \hat{y}}{\hat{x}^* \odot \hat{x} + \lambda} \quad (5)$$

以上的推导都是在线性回归的情况下, 实际应用中绝大多数都是非线性回归的情况。对于非线性问题, KCF 使用核函数对数据进行非线性映射, 将低维空间的非线性问题转变为高维空间的线性问题。拓展到核空间后, 样本空间中的 ω 可表示为对偶空间的线性组合:

$$\omega = \sum_i \alpha_i \varphi(x_i) = \alpha^T \varphi(x) \quad (6)$$

其中: $\varphi(x)$ 是一个非线性映射函数, 映射后的样本线性可分。此时求解 ω 的问题就变成了求解 α 。给定核函数 $\kappa(x, x') = [\varphi(x), \varphi(x')]$, $[\cdot, \cdot]$ 表示数学中的内积操作。分类器 $f(z) = \omega^T z$ 可以写为:

$$f(z) = \omega^T z = \sum_i \alpha_i \kappa(x_i, z) \quad (7)$$

根据对偶空间的回归问题求解得到^[18]:

$$\alpha = (\mathbf{K} + \lambda \mathbf{I})^{-1} y \quad (8)$$

其中: \mathbf{K} 表示核相关矩阵, α 是 α_i 组成的分类器系数矩阵。当核矩阵 \mathbf{K} 为循环矩阵时:

$$\hat{\alpha} = \left(\frac{1}{\hat{k}^{xx} + \lambda} \right)^* \odot \hat{y} \quad (9)$$

分类器为:

$$\hat{f}(z) = \hat{k}^{xz} \odot \hat{\alpha} = \left(\frac{1}{\hat{k}^{xx} + \lambda} \right)^* \odot \hat{y} \odot \hat{k}^{xz} \quad (10)$$

\hat{k}^{xz} 表示样本特征 x 在傅里叶域的核自相关矩阵, \hat{k}^{xz} 是训练样本 x 与检测区域 z 在傅里叶域的核互相关矩阵。

1.2 检测阶段

在检测过程中, 使用已训练好的分类器对框选出的区域进行滤波计算, 得到输出响应图, 如果两个信号越相似,

那么之间的相关性就越高, 输出的响应值就越大。检测过程中的输出响应方程为:

$$\hat{f}(z) = \hat{k}^* \odot \hat{\alpha} \quad (11)$$

将 $\hat{f}(z)$ 转换回空间域, 最大响应位置即为预测目标的中心位置。

1.3 更新阶段

在目标跟踪过程中, 目标对象经常因为背景干扰或者自身发生变化而导致算法性能受到影响, 因此需要及时对目标样本特征 x 和滤波器系数 α 进行更新, 通常采用线性内插法来更新模板参数, 公式如 (12) 所示:

$$\begin{cases} \hat{\alpha}_i = (1 - \eta)\hat{\alpha}_{i-1} + \eta\hat{x} \\ \hat{x}_i = (1 - \eta)\hat{x}_{i-1} + \eta\hat{x} \end{cases} \quad (12)$$

式中, η 为学习因子, $\hat{\alpha}_i$ 和 $\hat{\alpha}_{i-1}$ 为当前帧与前一帧的分类器系数向量的傅里叶变换, \hat{x}_i 和 \hat{x}_{i-1} 为当前帧和前一帧目标样本特征的傅里叶变换。

2 响应置信度的多特征融合 KCF 跟踪算法

传统的 KCF 跟踪算法只使用 HOG 特征, HOG 特征是一种视觉特征描述符, 它通过计算和统计目标区域像素点的梯度方向直方图来获取目标轮廓或形态上的统计信息, 由于其对光照变化和位置偏移不敏感, 具有较强的鲁棒性, 所以在检测行人、车辆、动物等物体上具有较好的效果。但由于 HOG 特征主要是反映目标局部形状和边缘, 所以在遇到遮挡和快速形变时, 经常会跟踪失败。而仅使用 CN 颜色特征跟踪的效果也并不好, CN 特征是将 RGB 彩色图像细化为黑、蓝、棕、灰、绿、橙、粉、紫、红、白和黄 11 种预先定义的颜色, 形成离散的 11 维颜色表示^[19], 其对旋转、形变等干扰有较强的抵抗能力, 但是当目标出现严重的光照变化或快速变色时, 仅使用 CN 特征就容易出现目标漂移现象。由此可见只使用单一特征往往会由于其自身的局限性, 无法应对跟踪场景中出现的各种困难。

2.1 多特征融合机制

选择多特征互补在理论上可以弥补各自的缺点, 提升跟踪效果。而在选择特征类型和融合方式是应当思考与细究的问题。

从特性来看, HOG 和 CN 两种特征相互融合可以实现互补, 但如果只是用简单的特征层相加方式进行融合, 不进行权重分配, 就会出现某一特征跟踪精度下降时, 整体的跟踪性能下降的情况。因此本文首先使用主成分分析 (PCA, primary component analysis) 法^[20]对 CN 特征降维, 提高运算速度, 然后利用平均峰相关能量 (APCE) 和输出的响应峰值作为跟踪置信度, 进行权重分配。

假设跟踪区域的大小为 $M \times N$ 像素, 则该区域第 t 帧图像的 APCE 值 P_t 计算如下:

$$P_t = \frac{|g_{\max,t} - g_{\min,t}|^2}{\left\{ \frac{1}{MN} \sum_{m,n} (g_{m,n,t} - g_{\min,t})^2 \right\}} \quad (13)$$

其中: $g_{\max,t}$, $g_{\min,t}$ 和 $g_{m,n,t}$ 分别是第 t 帧图像在跟踪区域内的最大响应值、最小响应值和位置 (m, n) 处的响应值。

我们可以将第 t 帧的特征权重公式写为:

$$\begin{cases} \omega_t = P_{cn} \times g_{cn_max,t} + P_{hog} \times g_{hog_max,t} \\ \omega_{cn,t} = P_{cn} \times g_{cn_max,t} / \omega_t \\ \omega_{hog,t} = P_{hog} \times g_{hog_max,t} / \omega_t \end{cases} \quad (14)$$

式中, $\omega_{cn,t}$ 和 $\omega_{hog,t}$ 分别为 CN 特征和 HOG 特征在第 t 帧的权重。

为确认该权重分配方法的有效性, 采用 OTB-2013 数据集^[21]中的 Basketball 视频序列进行验证。

从图 1 可以看到在 572 帧到 624 帧之间, 目标主要是在进行平移操作, 形变较小, 得到的特征权重变化图中 HOG 的特征权重高于 CN。而之后目标产生形变和旋转, HOG 特征权重显著下降。这表明该融合算法在不同的条件下能够实现自适应改变。

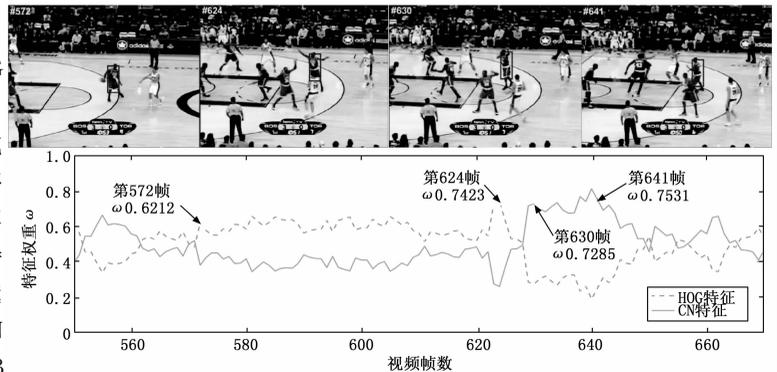


图 1 Basketball 部分视频序列的特征权重变化

2.2 基于响应置信度的分段更新策略

KCF 算法在每一帧学习中都使用相同的学习率来更新模型。而在实际的应用场景中, 由于背景杂乱、形变、遮挡等原因, 使用相同的学习率更新容易将不可靠的跟踪结果引入到模型当中。模型误差的累计将导致跟踪失败, 因此在跟踪质量较差的情况下应适当减小学习率。

响应图的峰值和波动可以一定程度上反应跟踪的质量, 当跟踪结果较为理想时, 响应图是只有一个尖峰, 其他区域平滑的图像, 而且响应峰值越高, 周边区域越平滑, 跟踪效果越好, 如图 2。而当跟踪过程出现了运动模糊等复杂情况时, 响应图的峰值就会变低, 顶部变宽, 产生多峰现象, 如图 3。

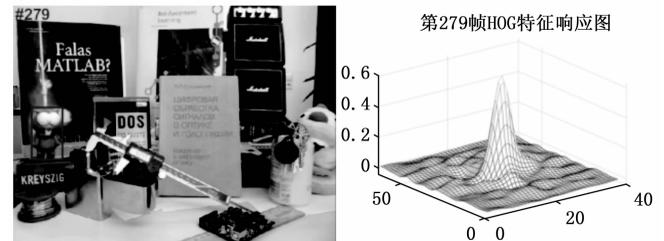


图 2 目标跟踪正常及三维响应图

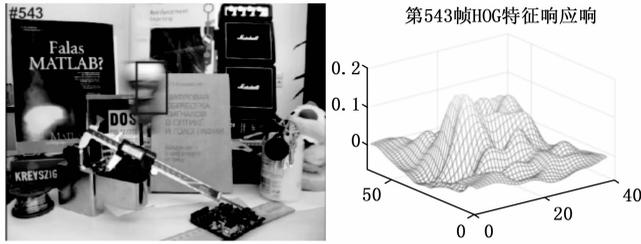


图 3 目标快速移动及三维响应图

为了避免模型更新而导致错误, 本文根据响应图变化的结果, 提出一种响应置信度判别方式: 计算大于 0.5 倍峰值的响应值个数 F_{med} 与大于 0.28 倍峰值的响应值个数 F_{major} , 设响应置信度 $F = F_{med}/F_{major}$ 。当干扰比较少时, 图像峰值高, 高响应值点比较集中且占比小, 没有多峰现象, 所以 F 的值较小。当受到干扰时, 响应图峰值变低, 产生多峰现象, 高响应值的点占比增加, F 的值增大。

由此就可以根据响应置信度 F 的大小来使用不同的学习率分段更新模型。经过对响应置信度范围的实验验证, 得出第 t 帧的分段更新模型策略为:

$$\eta_{CN,t} = \begin{cases} \eta_{CN} & F_{CN} < 0.35 \\ 0.95\eta_{CN} & 0.35 \leq F_{CN} < 0.52 \\ 0 & F_{CN} \geq 0.52 \end{cases} \quad (15)$$

$$\eta_{HOG,t} = \begin{cases} \eta_{HOG} & F_{HOG} < 0.30 \\ 0.95\eta_{HOG} & 0.30 \leq F_{HOG} < 0.55 \\ 0 & F_{HOG} \geq 0.55 \end{cases} \quad (16)$$

其中: η_{CN} 与 η_{HOG} 分别代表 CN 特征的学习率和 HOG 特征的学习率。 F 较小时认为图像接近理想响应图, 使用正常或较低学习率, 当 F 过大时, 认为干扰强烈, 不再继续更新模型。

利用这种方法, 不仅可以提高算法的鲁棒性, 还可以用来解决某一特征跟踪失效的问题。

2.3 特征失效下的模型跟踪判别

2.1 章节中的多特征融合机制虽然可以自适应的进行权重分配, 提高跟踪精确度, 但是如果出现某一特征跟踪失效, 产生相反的预测位置时, 再使用加权的更新方式就会引入额外的误差, 如图 4 所示。

由于图像在第 549 帧时产生运动模糊, HOG 特征的跟踪精度下降。可以看到物体原本向左运动, CN 特征得到的响应最高峰在左侧, 但 HOG 特征由于受到干扰, 得到的响应最高峰却在右侧。此时两种特征得出的预测位置截然相反, 不适合使用位置融合机制, 而应根据响应置信度 F 来进行单一特征的位置更新。

2.4 算法整体流程

本算法的伪代码如下:

```
Input: 当前帧图像  $I_t$ , 目标初始位置  $P_1$ 
Output: 检测到的目标位置  $P_t$ 
fort = 1 to N
if t = 1 then
```



第549帧CN特征响应图

第549帧HOG特征响应图

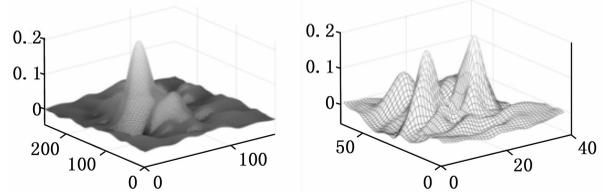


图 4 运动模糊时的 CN 特征与 HOG 特征响应图

1. 在初始帧中选取目标图像块 *Patch*
2. 提取 *Patch* 中的 HOG 特征和 CN 特征, 并对 CN 特征降维。由式(8)初始化分类器。
- else $t \geq 2$
3. 提取并计算出两种特征的响应峰值 g_{max} 、预测目标位置、响应置信度 F 以及 APCE 的值
4. if 两种特征预测的目标位置差异过大 then
使用 F 值较小的特征进行位置更新
else
通过权重 ω_{CN} 、 ω_{HOG} 得到的融合位置进行更新
end if
5. 根据响应置信度 F 计算更新速率, 更新滤波器模型的参数。
end if
end

3 实验结果分析

3.1 实验环境及参数设置

实验硬件环境条件为: Windows10 64 位操作系统, 处理器是 Intel (R) Core (TM) i5-8400CPU@2.80 GHz, 内存 16 GB, 开发软件为 Matlab R2020a。本文算法中, HOG 特征的维度为 31, 降维后的 CN 特征维度为 3, 模型学习率 η_{HOG} 、 η_{CN} 等其余参数设置与原 KCF 算法和 CN 算法相同, 分别为 0.02 和 0.075。响应置信度 F 按照式 (15~16) 中来取, 尺度变换部分使用了 DSST 算法的尺度滤波器。用于对比的算法参数均原用作者设定的默认参数。

3.2 定量分析

为了评估本文算法 (OURS) 的有效性, 在 OTB-2013 数据集上选取了具有代表性的 30 组视频序列来与 SAMF、DSST、KCF、CN 算法进行对比。所选视频的主要属性包括以下 11 种:

- 1) 14 组光照变化 (IV, illumination variation);
- 2) 23 组平面外旋转 (OPR, out-of-plane rotation);
- 3) 13 组尺度变换尺度变化 (SV, scale variation);

- 4) 19 组遮挡 (OCC, occlusion);
- 5) 11 组变形 (DEF, deformation);
- 6) 7 组运动模糊 (MB, motion blur);
- 7) 8 组快速移动 (FM, fast motion);
- 8) 20 组平面内旋转 (IPR, in-plane rotation);
- 9) 3 组离开视野 (OV, out of view);
- 10) 10 组背景复杂 (BC, background clutters);
- 11) 2 组低分辨率 (LR, low resolution)。

评估方法采用 OTB-2013 数据集中提出的距离精确度 (DP, distance precision)、成功率 (SR, success rate) 及跟踪速度 (FPS, frames per second) 作为评价标准。

单帧图像的跟踪评价指标主要有中心位置误差 (CLE, center location error) 和覆盖域 (OR, overlap region) 两种^[22]。

中心位置误差 CLE 是指跟踪目标位置 (x_T, y_T) 与真实位置 (x_G, y_G) 间的距离, 计算公式如下:

$$GLE = \sqrt{(x_T - x_G)^2 + (y_T - y_G)^2} \quad (17)$$

中心位置误差的值越小, 算法的跟踪精度就越高。但是中心位置误差只考虑了中心点的准确度, 没有考虑目标外观的变化, 不能反映算法在目标发生旋转、尺度变化时的跟踪精度。

覆盖域 OR 是根据人工标注的实际目标框和跟踪算法得到的跟踪框之间的重叠面积之比, 来衡量算法的跟踪性能。

$$OR = \left| \frac{r_t \cap r_g}{r_t \cup r_g} \right| \quad (18)$$

其中: $|\cdot|$ 代表区域中的像素数目, r_t 、 r_g 分别表示跟踪算法得到的预测区域和实际的目标区域, OR 的取值范围为 0 到 1, 算法对目标的跟踪越精确, 目标框的大小越接近于实际目标区域时, 重叠率越接近 1。所以旋转、尺度变化等干扰对算法的影响可以在覆盖域上得到体现。

距离精确度 DP 是通过统计中心位置误差 CLE 小于某一设定阈值 ϵ 的帧数 N_{num} 占视频序列总长度 N_{all} 的比值, 绘制出精确度曲线。通常采用阈值为 20 个像素点对应的数值作为精确度评价指标, 其计算公式如 (19) 所示:

$$DP = \frac{\sum_{CLE < \epsilon} N_{num}}{N_{all}} \quad (19)$$

成功率 SR 是通过统计覆盖域 OR 大于某一设定阈值 θ 的帧数 N_{num} 占所有测试视频序列总长度 N_{all} 的比值, 绘制出阈值从 0 到 1 变化的成功率曲线。通常以特定阈值为 0.5 时对应的值作为跟踪器的成功率, 其计算公式如 (20) 所示:

$$SR = \frac{\sum_{OR > \theta} N_{num}}{N_{all}} \quad (20)$$

具体本文算法 (OURS), SAMF 算法, DSST 算法, KCF 算法, CN 算法在 11 种主要属性下的精确度 DP 和成功率 SR 结果如表 1、表 2 所示, 每组的最优结果用加粗显示。

从表 1 和表 2 中可以看到, 对比主流的相关滤波跟踪算法, 本文算法的精确度 DP 和成功率 SR 在大多数属性下要优于其他算法。

表 1 5 种算法在 11 种属性下的精确度 DP

	OURS	SAMF	DSST	KCF	CN
IV	0.788	0.669	0.783	0.725	0.649
OPR	0.855	0.807	0.787	0.747	0.684
SV	0.757	0.723	0.791	0.690	0.664
OCC	0.862	0.903	0.742	0.777	0.656
DEF	0.936	0.858	0.664	0.777	0.589
MB	0.680	0.654	0.681	0.708	0.699
FM	0.691	0.683	0.639	0.661	0.602
IPR	0.796	0.731	0.837	0.764	0.722
OV	0.821	0.812	0.568	0.610	0.490
BC	0.804	0.618	0.718	0.755	0.690
LR	0.537	0.465	0.419	0.433	0.524

表 2 5 种算法在 11 种属性下的成功率 SR

	OURS	SAMF	DSST	KCF	CN
IV	0.755	0.647	0.729	0.607	0.532
OPR	0.798	0.738	0.665	0.626	0.550
SV	0.641	0.613	0.607	0.455	0.434
OCC	0.798	0.867	0.643	0.667	0.527
DEF	0.854	0.847	0.693	0.642	0.479
MB	0.647	0.643	0.639	0.601	0.574
FM	0.653	0.666	0.572	0.593	0.520
IPR	0.745	0.716	0.657	0.631	0.583
OV	0.775	0.810	0.517	0.597	0.489
BC	0.800	0.610	0.668	0.684	0.612
LR	0.548	0.483	0.428	0.448	0.537

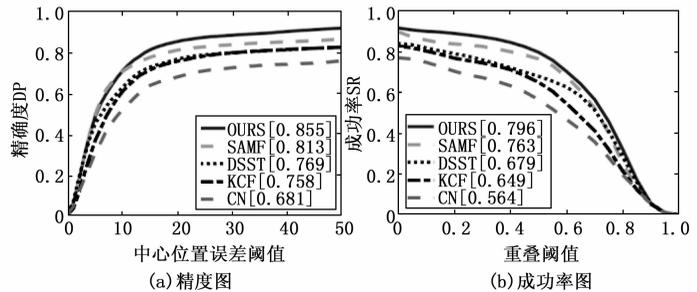


图 5 综合评价曲线图

图 5 为算法执行一次的整体精度图和成功率图。该图显示出本文算法相比于原 KCF 算法, 在精确度 DP 和成功率 SR 上分别提高了 12.8% 和 22.6%, 同时也高于其他主流算法。将本文算法中所有视频的总 FPS 数除以视频序列总数, 可得到本文算法的平均 FPS 值为 93.1。在保证较高跟踪精度的情况下, 平均速度依然可以满足实时性的要求。

3.3 定性分析

为了更直观的验证算法性能, 我们选取了 Deer、Singer2、Jogging2、Girl、Freeman1 这 5 个视频序列进行定性分析。其中本文算法 (OURS) 使用红色实线框, 绿色虚线框为 SAMF 算法, 蓝色虚点框为 DSST 算法, 黑色点横线

框为 KCF 算法，粉色实线框为 CN 算法。

3.3.1 Deer 序列测试

图 6 中，因为目标的快速跃起，在第 24 帧后开始产生运动模糊，导致仅用 HOG 特征的 DSST 和 KCF 算法丢失目标，使用 HOG 和 CN 通道融合的 SAMF 算法也因 HOG 特征的误差导致精度下降。而仅使用颜色通道的 CN 算法和使用了加权特征融合方式的 OURS 算法跟踪效果良好。

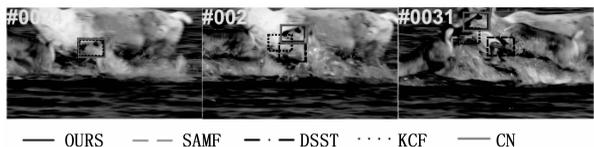


图 6 在 Deer 序列上的跟踪对比情况

3.3.2 Singer2 序列测试

图 7 中，由于目标在光照的影响下产生了颜色变化，导致 CN 算法丢失目标，SAMF 算法也因为 CN 颜色通道的误差导致跟踪失败。而只使用 HOG 特征的 DSST、KCF 与加权特征融合的 OURS 算法跟踪效果良好。



图 7 在 Singer2 序列上的跟踪对比情况

3.3.3 Jogging2 序列测试

图 8 中，目标在经过信号灯等之前缓慢运动，所有算法的跟踪情况都较好。但在 58 帧左右时，目标经过信号灯被完全遮挡，之后 CN、KCF 和 DSST 算法产生了漂移现象，丢失了目标。只有 SAMF 算法和本文算法在遮挡后依然能成功跟踪目标。



图 8 在 Jogging2 序列上的跟踪对比情况

3.3.4 Girl 序列测试

图 9 中，从 127 帧可以看到，DSST 算法由于位置滤波器预测的中心位置误差较大，导致尺度滤波器预测的尺度框大小也出现问题，而使用相同尺度滤波器的 OURS 算法因为预测位置更加精确，所以得到的尺度框大小正常。之后目标在 437 帧左右时出现相似物体遮挡的情况，使得 DSST、KCF 和 CN 算法出现漂移，最终跟踪失败。SAMF 算法和本文算法在受到遮挡后都能继续跟踪到目标，且本文算法预测的中心位置更加精确。

3.3.5 Freeman1 序列测试

图 10 中，目标由远至近运动，在第 114 帧时摘下眼镜，



图 9 在 Girl 序列上的跟踪对比情况

并在之后产生旋转。从 153 帧中可以看到，使用单一特征的 DSST、KCF、CN 算法都丢失了目标，SAMF 算法则因为目标摘眼镜动作的干扰，导致模板更新后，跟踪位置漂移到了手上。而本文算法基于响应置信度，采用了分段更新策略，减少了模型受到的污染，最终可以成功跟踪到正确目标。

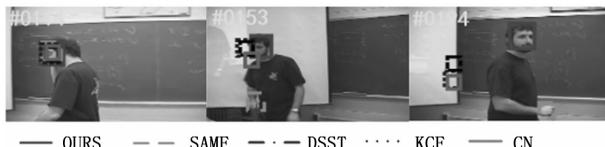


图 10 在 Freeman1 序列上的跟踪对比情况

4 结束语

本文以核相关滤波跟踪算法为基本框架，利用特征响应图的峰值与平均峰值相关能量值的乘积，对 HOG 特征和 CN 特征得出的预测位置进行自适应融合，并提出了一种新的置信度判断方法。通过对模型的跟踪情况和特征的有效性检测，采用分段式更新策略，避免了模型污染，提高了位置融合的可靠性和复杂环境中跟踪的鲁棒性。实验结果表明该算法相对于原 KCF 算法，在跟踪精度和成功率上分别提高了 12.8% 和 22.6%，且整体的性能优于其他常用的跟踪算法，并在抗遮挡、旋转、快速运动等方面也有较为明显的优势。同时本文算法的跟踪速度可达到 93.1FPS，满足实时性的要求，有一定的应用价值。

参考文献：

- [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] 马 森, 李始斌, 武宪青, 等. 视频中多特征融合人体姿态跟踪 [J]. 中国图象图形学报, 2020, 25 (7): 1459-1472.
- [3] 王 林, 胥中南. 改进的 KCF 算法在车辆跟踪中的应用 [J]. 计算机测量与控制, 2019, 27 (7): 195-199.
- [4] 孟晓燕, 段建民. 基于相关滤波的目标跟踪算法研究综述 [J]. 北京工业大学学报, 2020, 46 (12): 1393-1416.
- [5] 赵广辉, 卓 松, 徐晓龙. 基于卡尔曼滤波的多目标跟踪方法 [J]. 计算机科学, 2018, 45 (8): 253-257, 276.
- [6] 咎孟恩, 周 航, 韩 丹, 等. 粒子滤波目标跟踪算法综述 [J]. 计算机工程与应用, 2019, 55 (5): 8-17, 59.
- [7] 孟 球, 杨 旭. 目标跟踪算法综述 [J]. 自动化学报, 2019, 45 (7): 1244-1260.
- [8] 姜 珊, 张 超, 韩 成, 等. 基于相关滤波的目标重检测跟踪 [J]. 红外与激光工程, 2021, 50 (2): 224-235.

(下转第 202 页)

[2] 唐 榜, 吴 珏, 杨福军, 等. 基于高斯混合模型的 Web 代理服务缓存替换策略 [J]. 计算机测量与控制, 2021, 29 (2): 166 - 170, 175.

[3] 石 敏, 刘建勋, 周 栋, 等. 基于多重关系主题模型的 Web 服务聚类方法 [J]. 计算机学报, 2019, 42 (4): 820 - 836.

[4] SEGHIR K A, SEMCHEDINE F. An interval-based multi-objective artificial bee colony algorithm for solving the web service composition under uncertain QoS [J]. The Journal of Supercomputing, 2019, 75 (1): 5622 - 5666.

[5] 任 刚, 狄文辉, 郜广兰, 等. 基于 MapReduce 大数据计算模型的遗传算子前置并行遗传算法 [J]. 河南工学院学报, 2020, 28 (5): 7 - 9

[6] 韩 敏, 孙国庆, 郑丹晨, 等. 一种基于时变 Petri 网的服务组合质量检验方法 [J]. 软件学报, 2019, 30 (8): 2453 - 2469.

[7] CHIBANI S S, TARI A. Multi-Objective and discrete elephants herding optimization algorithm for QoS aware web service composition [J]. RAIRO-Operations Research, 2017, 53 (2): 445 - 459.

[8] 范国栋, 祝 铭, 李 静, 等. 基于 FAHP 与规划图融合的 Web 服务组合方法 [J]. 计算机科学, 2020, 47 (1): 270 - 275.

[9] GHOBAEI A M, SOURI A. LP-WSC: a linear programming approach for web service composition in geographically distributed cloud environments [J]. Journal of supercomputing, 2019, 75 (5): 2603 - 2628.

[10] BHUSHAN S B, REDDY P C H. A Hybrid Meta-Heuristic Approach for QoS-Aware Cloud Service Composition [J]. International Journal of Web Services Research, 2018, 15 (2): 1 - 20.

[9] BOLME D S, BEVERIDGE J R, DRAPER B A, et al. Visual object tracking using adaptive correlation filters [C] // 2010 IEEE computer society conference on computer vision and pattern recognition. IEEE, 2010: 2544 - 2550.

[10] 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.

[11] ZHOU W, GAO S, ZHANG L. Histogram of oriented gradients feature extraction from raw Bayer pattern images [J]. IEEE Transactions on Circuits and Systems II: Express Briefs, 2020, 67 (5): 946 - 950.

[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, 3 (37): 583 - 596.

[13] DANELLJAN M, HAGER G, KHAN F S, et al. M. Discriminative scale space tracking [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 39 (8): 1561 - 1575.

[14] LOU J, WANG H, CHEN L, et al. Exploiting color name

[11] LUCA M, PATRICK K, MATTHIAS K. Semantic composition of optimal process service plans in manufacturing with ODERU [J]. International Journal of Web Information Systems, 2018, 14 (4): 495 - 523.

[12] RAJAVEL R, IYER K, MAHESWAR R, et al. Adaptive neuro-fuzzy behavioral learning strategy for effective decision making in the fuzzy-based cloud service negotiation framework [J]. Journal of Intelligent & Fuzzy Systems, 2019, 36 (3): 2311 - 2322.

[13] LI K, ROLLINS J, YAN E. Web of Science use in published research and review papers 1997 - 2017: a selective, dynamic, cross-domain, content-based analysis [J]. Scientometrics, 2018, 115 (1): 1 - 20.

[14] 张梦洋, 田国会, 龚 京, 等. 基于强化学习的服务规划生成方法 [J]. 华中科技大学学报 (自然科学版), 2018, 46 (9): 59 - 63.

[15] 尚博祥, 刘 晨. 移动云环境中基于节点自适应配置的可靠服务架构 [J]. 计算机测量与控制, 2018, 26 (3): 250 - 253.

[16] FORERO-ROMERO J E, CONTRERAS S, PADILLA N, et al. Cosmic web alignments with the shape, angular momentum and peculiar velocities of dark matter haloes [J]. Monthly Notices of the Royal Astronomical Society, 2018, 443 (2): 1090 - 1102.

[17] 彭 军, 王成龙, 蒋 富, 等. 一种车载服务的快速深度 Q 学习网络边云迁移策略 [J]. 电子与信息学报, 2020, 42 (1): 58 - 64.

[18] 张苑蕾, 邵 清, 李刘静, 等. 融合遗传聚类的可靠 Web 服务组合优化方法 [J]. 小型微型计算机系统, 2020, 41 (5): 1030 - 1035.

[15] 余汉蓉, 林 彬, 俞增林. 结合 SAMF 和视觉显著性的目标跟踪算法 [J]. 电光与控制, 2021, 28 (1): 15 - 18, 32.

[16] 常 敏, 沈 凯, 张学典, 等. 自适应特征融合和模型更新的相关滤波跟踪 [J]. 光学学报, 2019, 39 (9): 228 - 236.

[17] 胡世达. 复杂场景下基于相关滤波的目标跟踪算法研究 [D]. 成都: 电子科技大学, 2020.

[18] GAN H, SHE Q, MA Y, et al. Generalization improvement for regularized least squares classification [J]. Neural Computing and Applications, 2019, 31 (2): 1045 - 1051.

[19] DANELLJAN M, SHAHBAZ KHAN F, FELSBERG M, et al. Adaptive color attributes for real-time visual tracking [C] // Proceedings of the IEEE conference on computer vision and pattern recognition, 2014: 1090 - 1097.

[20] 岳晨晨, 侯志强, 余旺盛, 等. 基于鲁棒 PCA 的视觉跟踪算法 [J]. 光电工程, 2020, 47 (7): 20 - 29.

[21] 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.

[22] 刘海峰, 孙 成, 梁星亮. 自适应特征融合与抗遮挡的相关滤波跟踪算法 [J]. 激光与光电子学进展, 2020, 57 (14): 139 - 151.

(上接第 196 页)