

迁移学习融合双 HOG 特征的目标跟踪

黄戌霞¹, 林淑彬²

(1. 宁德职业技术学院信息技术与工程学院, 福建 宁德 355000)

(2. 闽南师范大学计算机学院, 福建 漳州 363000)

[摘要] 目标跟踪是计算机视觉的关键技术之一, 应用于模式识别、自动控制等领域. 深度学习的跟踪算法具有良好的性能, 但在快速运动情况下, 低层 HOG 特征易受影响, 跟踪性能较弱. 提出一种结合线下训练深度特征的鲁棒跟踪方法. 通过线下训练 VGG 模型, 线上构造双 HOG 特征并进行最优选择, 将线下训练提取的特征迁移到线上, 与最优 HOG 特征响应融合. 首先, 线下逐层训练 VGG 网络, 卷积层负责提取卷积特征. 然后, 在线提取当前帧目标区域的 HOG 特征, 并分解为 HOG1 和 HOG2, 对其进行滤波处理, 选择最优特征. 最后, 融合卷积特征响应和 HOG 最优特征响应得到特征响应图, 预测目标的新位置. 在 OTB-2013、OTB-2015 基准数据集上与其他 6 个算法对比. 结果表明, 该方法在处理快速运动、背景混乱、形变等跟踪方面具有良好的性能.

[关键词] 计算机视觉, 目标跟踪, VGG 网络, HOG 特征, 迁移学习

[中图分类号] TP391.4 **[文献标志码]** A **[文章编号]** 1672-1292(2022)04-0029-07

Object Tracking Based on Transfer Learning Fusion of Dual HOG Feature

Huang Xuxia¹, Lin Shubin²

(1. College of Information Technology and Engineering, Ningde Vocational and Technology College, Ningde 355000, China)

(2. College of Computer Science, Minnan Normal University, Zhangzhou 363000, China)

Abstract: Object tracking is one of the key technologies in computer vision, which is applied in image processing, pattern recognition, automatic control and other fields. Deep learning tracking algorithm has good performance. However, in the case of fast motion, the low-level HOG feature is easily affected and the tracking performance is weak. This paper proposes a robust tracking method based on offline training depth feature. Through offline training of VGG model, constructing double HOG features online and making optimal selection, the features extracted from offline training to online are transferred and integrated with the optimal HOG feature response. Firstly, the VGG network is trained layer by layer offline, and the convolution layer is responsible for extracting convolution features. Then, the HOG feature of the current frame in the object area is extracted and decomposed into HOG1 and HOG2. The optimal feature is selected for the two HOG features processed by filtering. Finally, the feature response graph is calculated by integrating convolution feature response and HOG feature response, that is, the predicted new object position. Comparing OTB-2013 and OTB-2015 benchmark data sets with other six algorithms, experimental results show that this method has good performance in dealing with fast motion, background clutter, deformation and other tracking aspects.

Key words: computer vision, object tracking, VGG network, HOG features, transfer learning

视觉目标跟踪是计算机视觉中的热点问题, 在军事科学、安全监控、无人驾驶、航空航天等方面有广泛应用^[1]. 由于目标自身的变化因素(如外观变化、尺寸变化、运动模糊)和背景因素^[2](如遮挡与消失、光照变化和相似背景干扰等)的影响, 视觉目标跟踪技术仍面临着诸多挑战. 近年来, 相继提出了许多跟踪方法来对目标运动状态进行预测并定位, 其中基于相关滤波(correlation filter, CF)^[3]和基于深度学习^[4]的跟踪方法尤其引人注目.

自 Bolme 等^[5]首次将相关滤波应用到视觉目标跟踪, 提出最小平方误差输出和滤波(minimum output sum of squared error, MOSSE)算法后, 一系列改进算法相继出现并得到应用. 判别式相关滤波

收稿日期: 2022-03-16.

基金项目: 福建省中青年教师教育科研项目(JAT220752).

通讯作者: 林淑彬, 硕士, 实验师, 研究方向: 计算机视觉和模式识别. E-mail: greenkure@163.com

(discriminative correlation filter, DCF)^[6] 利用图像块在多个通道特征上学习一个相关滤波器,被广泛应用于视频跟踪领域. Wei 等^[7] 利用循环矩阵,先后提出一种基于核循环结构的目标跟踪方法(circulant structure kernels, CSK)和一种植核相关滤波器的跟踪方法(kernel correlation filter, KCF). SRDCF 跟踪器^[8] 在保留目标更多真实信息的基础上,通过对相关滤波系数来惩罚离目标中心比较远的样本. DSST 算法^[9] 基于尺度金字塔描述来学习判别相关滤波,性能提升显著,并能够方便的融入到其他没有尺度估计的跟踪算法中. Martin 等^[10] 提出 SRDCFdecon 跟踪器,是一种跟踪模型与训练样本权值联合学习的新方式,以减轻在跟踪检测框架中训练样本损坏的问题. Bertinetto 等^[11] 提出在 tracking-by-detection 框架下的目标尺度估计跟踪算法. Staple 算法^[11] 综合局部特征 HOG 和全局特征颜色直方图用于目标跟踪,速度达到 80 fps,并且跟踪效果很好. DCFNet 跟踪算法^[12] 同时完成卷积特征提取过程和在线协同滤波跟踪. 在孪生网络中,将判别协同滤波器看作特殊的协同滤波器层, Wang 等^[12] 给出在傅里叶空间中进行反向传播的跟踪方法,使 DCFNet 保留了良好的跟踪时效性. MCCTH 跟踪算法^[13-14] 使用多个独立的基于判别相关滤波器的专家进行跟踪,在每一帧中选择当前最优的专家,将其结果作为当前帧的跟踪结果. 多个跟踪器的决策层得出的融合结果可以有效地提高鲁棒性.

近年来,将卷积神经网络(convolutional neural network, CNN)^[15] 应用于目标跟踪成为热点. VGG (visual geometry group) 网络^[16] 模型通过卷积层数的加深来增加感受野,提升深层特征通道的语义信息,从而更好地进行目标识别. Nam 等^[17] 提出的 MDNet 网络巧妙利用了 CNN 特征,把它分为共性特征和个性特征,对应设计出的神经网络也反映了跟踪任务的特点,在线更新模型,减少累积误差,可以适应场景变化,使得跟踪结果更加精确. Chao 等^[18] 提出 HCF 算法,在低级特征上构造多个 DCF,用于捕获空间细节和语义的中级和高级特性,使用从粗到细的多级别 DCF 响应映射来预测目标位置.

为了让跟踪器获得更好的性能,满足更多挑战性场景,本文融合跟踪器的多种特征,基于 DCF 算法和 CNN,提出一种迁移学习融合双 HOG 特征^[19] 的目标跟踪(object tracking based on transfer learning fusion of dual HOG feature, DHTL)方法,从而有效增强其鲁棒性. 本方法通过线下逐层训练 VGG 网络,线上提取当前帧目标区域的 HOG 特征,分解并标识为 HOG1 和 HOG2. 分别对 HOG1 和 HOG2 使用 DCF 进行滤波处理,选择最大输出响应作为最优特征. 最后,融合线下卷积特征响应和线上 HOG 特征响应计算得到特征响应图,即预测出的新目标位置. 本方法使用线下训练 VGG 模型提取卷积特征,利用迁移学习^[20-22] 方法融合双 HOG 特征和卷积特征用于线上训练和跟踪,并将其与 SRDCFdecon、Staple、DSST、DCFNet、SRDCF、MCCTH 等 6 个跟踪算法进行对比,实验结果表明,本方法在对比算法中具有较高的性能和准确度. 图 1 为各算法跟踪结果对比图.



图 1 各算法跟踪结果对比图

Fig. 1 Comparison of tracking results of each algorithm

1 背景知识

1.1 相关滤波

相关滤波是通过卷积操作来判别两个信号的相似度,分别对两个信号进行处理,得到的相关值越高,则表示两个信号越相似,即越接近所跟踪的目标区域.该方法利用快速傅里叶变换实现的相关滤波器,将所有循环移位的输入特征退化为目标高斯函数,不需要对目标外观进行硬阈值采样,具有很高的计算效率.

1.2 VGG 网络

2014 年,Simonyan 等^[15]提出 VGG 网络.作为特征提取器,VGG 使用多个 3×3 卷积核的卷积层代替一个卷积核较大的卷积层,既减少了参数,又增加网络的拟合表达能力.由于卷积核专注于扩大通道数,池化专注于缩小宽和高,网络是分段卷积网络^[23],从而拓深拓宽了模型架构,控制了计算量的增加. VGG 通过降低卷积核的大小,增加卷积子层数来达到同样的性能. VGG 在训练集图像上计算出所有图像 RGB 均值,然后把图像作为输入传入 VGG 卷积网络. VGG 网络第一层的通道数为 64,后面每层都进行了翻倍,直到 512 个通道,通过不断加深网络通道数,使得更多的信息可以被提取出来,从而提升图像分类性能.

1.3 迁移学习

迁移学习是把已训练好的模型参数迁移到新的模型来帮助新模型训练,解决了传统机器学习中训练数据和测试数据必须独立同分布和训练样本数量稀缺的问题,从而加快并优化模型的学习效率.提升在小样本数量分类识别上的准确率. DHTL 方法采用基于内容的特征迁移学习.在图像分类中,特征迁移学习是使用自然图像训练得到的参数初始化网络,使用 VGG 网络作为特征提取器,将提取的特征作为目标图像的特征,再使用分类器对提取到的特征进行分类预测,从而降低源领域和目标领域之间的分布差异,提高分类性能.

2 迁移学习融合双 HOG 特征的目标跟踪方法

基于线上训练和跟踪同时进行对目标跟踪速度的影响,在 HOG 特征和线下 VGG 训练提取特征的基础上,本文提出迁移学习融合双 HOG 特征的目标跟踪方法,图 2 为 DHTL 方法的目标跟踪系统框架图.

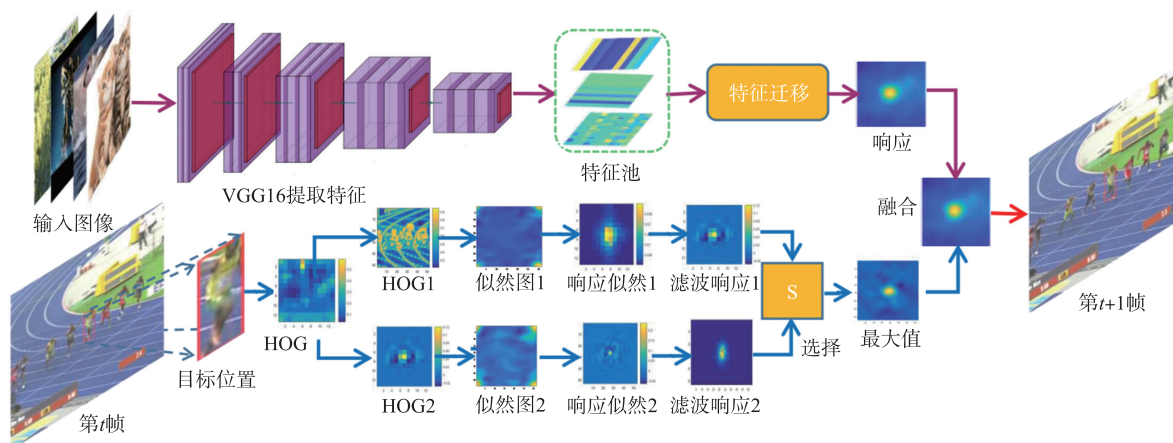


图 2 DHTL 方法的目标跟踪系统框架图

Fig. 2 Frame diagram of target tracking system of DHTL

2.1 HOG 特征

HOG 特征也称为方向梯度直方图特征^[24],是计算机视觉和图像处理领域中描述目标边缘轮廓的图像信息.由于颜色特征对边缘轮廓信息的提取影响不大,因此 HOG 特征的提取先对初始图像的 Gamma 空间和颜色空间进行归一化的预处理,以减少光照因素的影响.然后将图像从大到小分别以窗口、块、细胞为单位进行分割.计算图像横纵坐标方向的梯度,并统计每个细胞单元的梯度直方图信息.接着把块内所有的单元特征向量串联起来,得到这个块的 HOG 特征.最后组合所有的块,生成特征向量.

由于 HOG 特征属于浅层特征,无需从粗到细地进行融合,只需将其 31 个维度连接起来,然后取目标区域中所有像素灰度值的平均数,并标记为 1 维特征向量,再将其与 31 维 HOG 特征连接,形成一个 32 维

特征向量,平均分解后得到两个 16 维特征向量,分别标记为 HOG1 和 HOG2. 使用 DCF 对两个 HOG 特征分别进行相关滤波计算,保留最大响应值作为最优特征.

训练滤波器的目的是找到一个函数 $f(x_i) = w^d x_i$ 使样本 x_i 及其回归目标 y_i 的平方误差最小

$$\min_w \sum_i (f(x_i) - y_i)^2 + \lambda \|w\|^2. \quad (1)$$

式中, y 为相关响应值, λ 是正则化参数,用来控制过度拟合, w 是复数域滤波器. 求解 w ,

$$w = (X^H X + \lambda I)^{-1} X^H y. \quad (2)$$

式中, X^H 表示复共轭转置矩阵.

循环矩阵可以通过离散傅立叶变换进行对角化的重要性质,所求线性解为:

$$\hat{w} = \text{diag}\left(\frac{\hat{x}^*}{\hat{x}^* \odot \hat{x} + \lambda}\right) \hat{y} = \frac{\hat{x}^* \odot \hat{y}}{\hat{x}^* \odot \hat{x} + \lambda}. \quad (3)$$

式中, \hat{x} 表示离散傅里叶变换后的向量, $*$ 表示矩阵的复共轭, \odot 表示点乘.

因此,通过式(4)计算具有相同大小 x 的特征图矩形区域 s 的响应值 R ,并搜索出 R 的最大值,

$$R_{\max} = \max \left(F^{-1} \left(\sum_{d=1}^D \hat{w}_d \odot \hat{s}_d^* \right) \right). \quad (4)$$

式中, F^{-1} 是傅里叶逆变换, d 表示特征维数,取值范围从 1 到 D .

2.2 卷积

对于视频目标跟踪,主要考虑目标对象的精确位置. 随着卷积神经网络的正向传播,加强了对不同类别对象的语义区分,并逐步降低空间分辨率,实现精确定位. 本文用 VGG16 网络提取深度特征,使用卷积神经网络的卷积特征图 VGG-Net,对目标外观进行编码.

卷积神经网络中使用池化操作符,空间分辨率随着卷积层深度的增加而逐渐降低. VGG-Net 中池化层 5 的卷积特征图空间尺寸为 7×7 ,即输入图像大小为 224×224 的 $1/32$. 由于低的空间分辨率不足以精确定位目标,所以通过双线性插值将每个特征图调整到一个固定的更大尺寸来缓解这个问题. 设 h 为特征图, x 为上采样特征图,第 i 个位置的特征向量为

$$x_i = \sum_k \alpha_{ik} h_k. \quad (5)$$

式中,插值 α_{ik} 权重分别取决于 i 和 k 相邻特征向量的位置. 由于每一层构建的 DCF 不够精确,因此对来自不同层的多个 DCF 响应映射执行从粗到细的搜索. 在 DHTL 跟踪器中,用 HOG 作低级特征,移除完全连接层,提取出的 conv3-4、conv4-4 和 conv5-4 卷积层输出分别作为中层和高层特征. 由此保障了跟踪结果的多样性.

最后,将 HOG 特征提取的响应最大值和 VGG16 网络提取的特征响应值进行融合,结果 P 为跟踪的目标位置,

$$P = R_{\max} \oplus x_i. \quad (6)$$

2.3 算法

基于上述分析,使用迁移学习融合双 HOG 特征的目标跟踪算法对跟踪区域进行定位的具体步骤如下:

算法:迁移学习融合双 HOG 特征的目标跟踪(DHTL)

输入:视频序列 S ,初始化目标

输出:视频序列 S 中每一帧的跟踪对象目标位置

- (1) 读取第一帧跟踪对象的目标位置;
- (2) 初始化目标跟踪器;
- (3) 线下预训练 VGG16 模型,利用式(5)提取特征 X_i ;
- (4) 提取第 t 帧的 HOG 特征,并分解成 HOG1 和 HOG2,分别进行相关滤波处理;
- (5) 分别利用循环矩阵进行傅里叶变换,保留滤波处理的最大响应值 R_{\max} ;
- (6) 根据式(6)将 R_{\max} 和 X_i 进行融合,预测出的新目标位置 P_{t+1} ;
- (7) 如果是最后一帧则停止算法;否则重复执行步骤(4)~(6).

返回 视频序列的目标位置.

3 实验结果分析

为减少训练开销,直接使用预训练好的 VGG 模型提取卷积特征,作为迁移学习的输入. 本文使用 OTB-2013 和 OTB-2015 两个基准数据集进行实验,将 DHTL 算法与 SRDCFdecon、Staple、DSST、DCFNet、SRDCF、MCCTH 等 6 个跟踪算法进行实验效果对比,采用覆盖率与中心位置误差 2 种指标来进行定量分析,以验证本算法的优越性.

3.1 实验配置和参数设置

实验配置为 CPU i7-3770 处理器,内存 8G,64 位 Windows10 操作系统,在 MATLAB 环境下运行. 实验按照标准 DCF 方法中的参数来构造 HOG 特征和 VGG 网络模型. 将式(1)中的正则化参数 λ 设置为 0.02,统一所有实验序列的参数设置,设置固定的目标区域与初始目标区域大小相等.

3.2 实验结果

实验使用 OTB-2013 和 OTB-2015 两个基准数据集作为测试序列,如图 3 所示,DHTL 目标跟踪方法在空域鲁棒性评测中通过的成功率和准确率指标上表现良好. 图 4 为测试序列中得到的成功率图和准确率图. 各算法准确率性能对比如表 1 所示. 图表均显示出 DHTL 算法在不同环境中的跟踪效果优于其他跟踪算法.

从性能上分析,Staple 和 SRDCFdecon 算法均以 SRDCF 为基线,能够有效缓解边界效应,且优于标准 DCF. DSST 采用了新颖的尺度算子,更好地融合了尺度特征. DHTL 算法以 HOG 特征和线下训练 VGG 网络提取卷积特征为基准,VGG 网络的小卷积核可以增加决策函数 softmax 的非线性能力,减少网络的过拟合. 通过线下训练和线上跟踪相结合的方法,来进一步提高性能. 从图 3 可知,本文算法的平均成功率为 0.724,平均准确率为 0.794,SRDCFdecon 算法的平均成功率和准确率次之,分别为 0.719 和 0.769. DHTL 算法在线下训练 VGG 网络提取的深度卷积特征具有丰富的表达能力,结合双 HOG 特征,通过特征组合的方式,减少了低层特征易受快速运动变化的影响,进一步增强了模型的鲁棒性. 图 4 显示了 DHTL 跟踪器在快速运动、背景模糊、形状变化和平面内外旋转等方面均优于其他算法. 在快速运动、背景混乱、形变和平面内外旋转方面的跟踪精度分别为 0.748、0.811、0.743 和 0.769,比跟踪精度次之的跟踪器分别高出 0.02、0.051、0.045 和 0.02.

从效率上分析,由于 DHTL 算法采用 VGG 模型线下训练提取特征,通过迁移学习融合线上特征进行跟踪,提高了线上运行和跟踪的效率和准确率. 从图 4 和表 1 可看出,DHTL 跟踪器的跟踪准确率和成功率在处理低分辨率和运动模糊方面比较弱,分别低于 MCCTH 和 SRDCF 跟踪算法,由于低分辨率和运动模糊等因素的影响,在降采样的过程丢失了大量空间细节信息,通过双 HOG 特征组合的方式并不能精确地表达目标外观的剧烈变化. 其次,在低分辨率和运动模糊情况下,正负样本不均衡. 因此,选择合适的采样策略对跟踪性能具有较大的影响,可行的解决方法是采用多尺度训练的方式来进一步提高跟踪性能和鲁棒性. 然而在光照变化方面其跟踪精度取得了最佳效果,HOG 特征对图像几何和光学的形变都保持很好的不变性. 总体上,DHTL 算法在快速运动、背景模糊、形状变化等情况下的性能相较其他算法有明显优势.

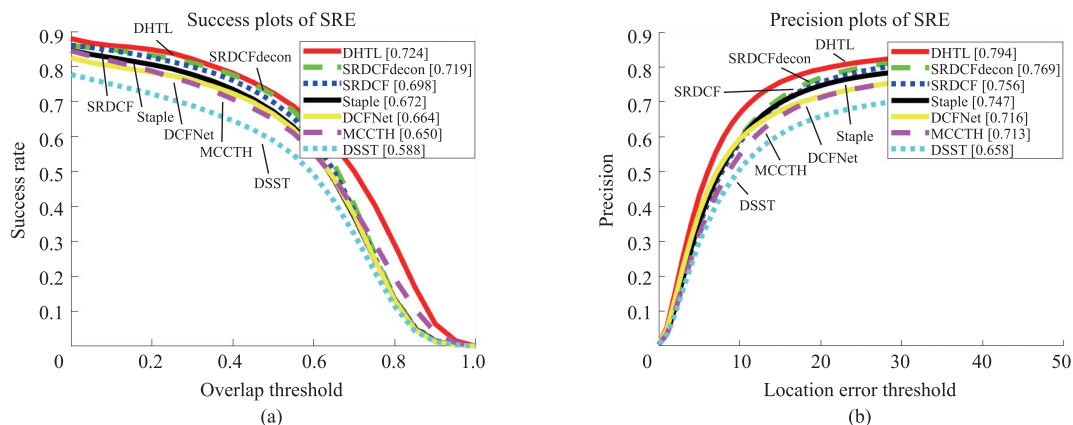


图 3 成功率和准确率图

Fig. 3 Success and precision plots

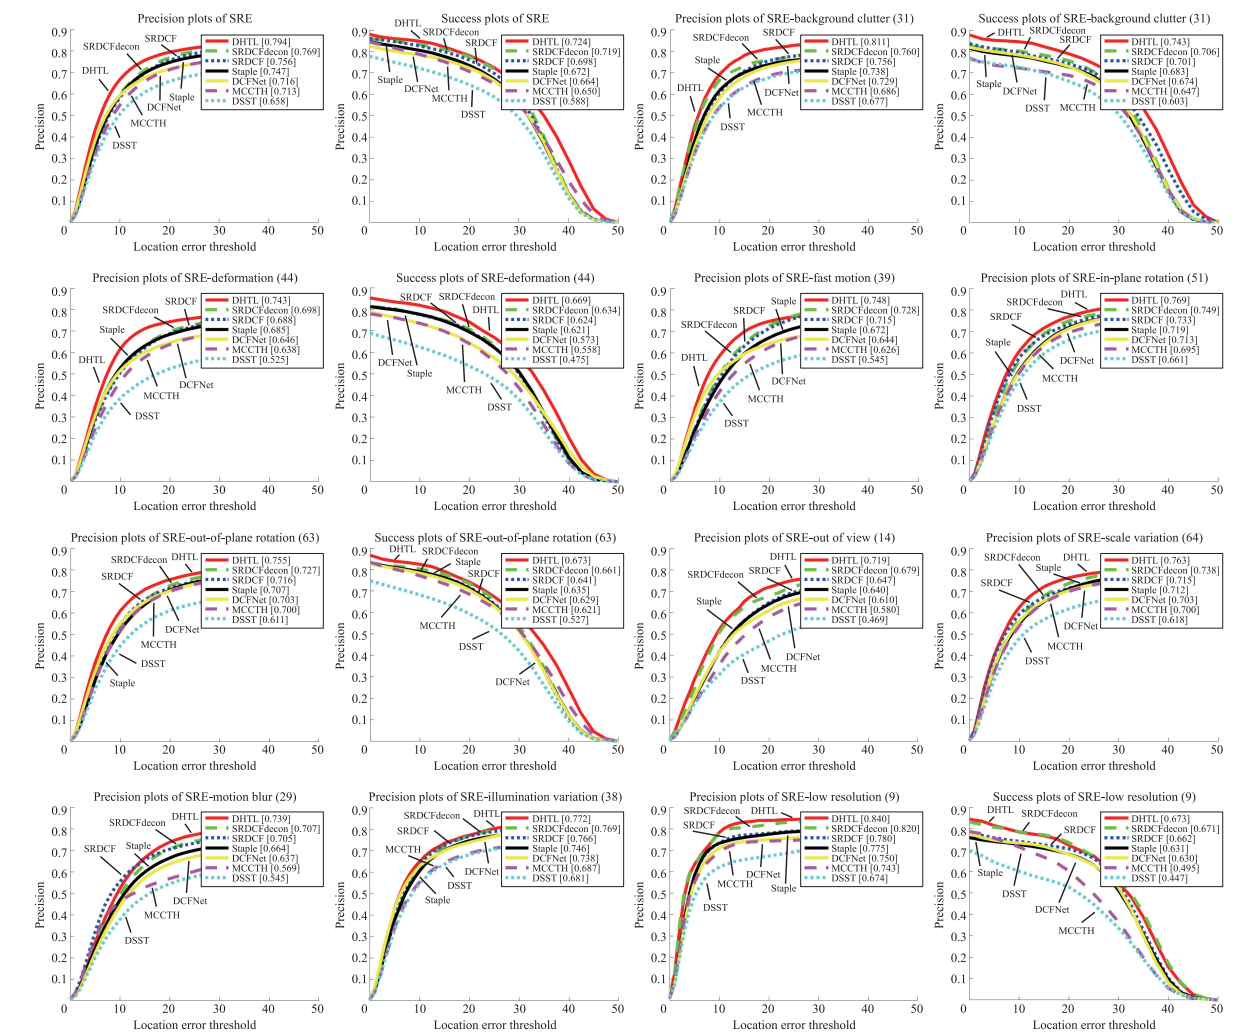


图 4 OTB-2013 和 OTB-2015 数据集测试结果

Fig. 4 Tracking results of OTB-2013 and OTB-2015 dataset

表 1 各算法准确率性能对比

Table 1 Comparison of accuracy and performance of each algorithm

算法	快速运动	背景混乱	运动模糊	形变	光照变化	平面内旋转	干扰	平面外旋转	超出视野	尺度变化
STAPLE	0.672	0.738	0.664	0.685	0.766	0.749	0.682	0.716	0.610	0.703
SRDCFdecon	0.728	0.756	0.739	0.698	0.769	0.719	0.713	0.727	0.647	0.738
DCFNet	0.626	0.686	0.637	0.638	0.681	0.695	0.691	0.700	0.640	0.700
DSST	0.545	0.677	0.545	0.525	0.687	0.661	0.574	0.611	0.469	0.618
MCCTH	0.644	0.760	0.569	0.646	0.738	0.733	0.668	0.703	0.679	0.715
SRDCF	0.715	0.729	0.707	0.688	0.746	0.713	0.693	0.707	0.580	0.712
DHTL	0.748	0.811	0.705	0.743	0.772	0.769	0.724	0.755	0.719	0.763

4 结论

本文提出了 VGG 线下训练提取卷积特征,利用迁移学习融合线上双 HOG 特征的目标跟踪方法。DHTL 方法提高了跟踪速度和准确度,在快速运动、背景混乱、形变和平面内外旋转等方面具有较好的鲁棒性。下一步将结合深度学习的浅层特征和深层特征,减少运动模糊和低分辨率的不良影响,提高目标跟踪的性能。

[参考文献] (References)

[1] 尹宏鹏,陈波,柴毅,等. 基于视觉的目标检测与跟踪综述[J]. 自动化学报,2016,42(10):1466-1489.
[2] 刘艺,李蒙蒙,郑奇斌,等. 视频目标跟踪算法综述[J]. 计算机科学与探索,2022,16(7):1504-1515.

- [3] ZOU Q,ZHANG Z,LI Q Q, et al. DeepCrack: learning hierarchical convolutional features for crack detection. [J]. IEEE Transactions on Image Processing a Publication of the IEEE Signal Processing Society, 2018, 28(3): 1498–1512.
- [4] LUKEI A,T VOJÍ L,EHOVIN L, et al. Discriminative correlation filter with channel and spatial reliability[J]. International Journal of Computer Vision, 2018, 126(7): 671–688.
- [5] BOLME D S,BEVERIDGE J R,DRAPER B A, et al. Visual object tracking using adaptive correlation filters[C]//The Twenty-Third IEEE Conference on Computer Vision and Pattern Recognition. San Francisco, CA, USA, 2010: 13–18.
- [6] 李冬冬. 基于相关滤波器和卷积神经网络的视觉跟踪方法研究[D]. 长沙: 国防科技大学, 2018.
- [7] WEI C,ZHANG K,LIU Q. Robust visual tracking via patch based kernel correlation filters with adaptive multiple feature ensemble[J]. Neurocomputing, 2016, 214: 607–617.
- [8] MARTIN D,GUSTAV H,FAHAD S K, et al. Learning spatially regularized correlation filters for visual tracking[C]//IEEE International Conference on Computer Vision. Plaza Foyer, BC, USA, 2015.
- [9] MARTIN D,GUSTAV H,FAHAD S K, et al. Discriminative scale space tracking[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 39(8): 1561–1575.
- [10] MARTIN D, GUSTAV H, FAHAD S K, et al. Adaptive decontamination of the training set: A unified formulation for discriminative visual tracking [C]//International Conference on Computer Vision and Pattern Recognition. Las Vegas, Nevada, USA, 2016: 1430–1438.
- [11] BERTINETTO L, VALMADRE J, GOLODETZ S, et al. Staple: complementary learners for real-time tracking [C]//International Conference on Computer Vision and Pattern Recognition. Las Vegas, Nevada, USA, 2016: 1401–1409.
- [12] WANG Q, GAO J, XING J, et al. DCFNet: Discriminant correlation filters network for visual tracking[J]. arXiv Preprint arXiv: 1704.04057, 2017.
- [13] ADAM A, RIVLIN E, SHIMSHONI I. Robust fragments-based tracking using the integral histogram[C]//IEEE Computer Society Conference on Computer Vision and Pattern Recognition. New York, NY, USA, 2006, 1: 798–805.
- [14] CHANG L, FENG D P, WU H F, et al. Multi-cue adaptive correlation filters for visual tracking[C]//6th International Conference on Digital Home. Guangzhou, China, 2016: 89–94.
- [15] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. arXiv Preprint arXiv: 1409.1556, 2014.
- [16] MA C, HUANG J B, YANG X, et al. Robust visual tracking via hierarchical convolutional features[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018, 41(11): 2709–2723.
- [17] NAM H, HAN B. Learning multi-domain convolutional neural networks for visual tracking [C]//IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, Nevada, USA, 2016: 4293–4302.
- [18] CHAO M, HUANG J B, YANG X, et al. Hierarchical convolutional features for visual tracking [C]//IEEE International Conference on Computer Vision. Santiago, Chile, 2015: 3074–3082.
- [19] 林淑彬, 丁飞飞, 杨文元. 融合双 HOG 特征和颜色特征的目标跟踪[J]. 江苏科技大学学报(自然科学版), 2020, 34(4): 64–70.
- [20] 游梓童, 吴福明, 赵森, 等. 融合高阶信息增强模块的复杂背景植物叶片图像分类[J]. 南京师范大学学报(工程技术版), 2022, 22(3): 45–52.
- [21] YI W, LIM J, YANG M H. Online object tracking: a benchmark [C]//IEEE Conference on Computer Vision and Pattern Recognition. Portland, Maine, USA, 2013: 2411–2418.
- [22] WU Y, LIM J, YANG M H. Object tracking benchmark[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37(9): 1834–1848.
- [23] 聂瑜, 陈春梅, 刘桂华. 基于 VGG16 改进的特征检测器[J]. 信息与控制, 2021, 50(4): 483–489.
- [24] 宋建辉, 孙晓南, 刘晓阳, 等. 融合 HOG 特征和注意力模型的孪生目标跟踪算法[J/OL]. 控制与决策, 2021: 1–9[2022-10-27]. <https://doi.org/10.13195/j.kzyjc.2021.1235>.

[责任编辑: 陈 庆]