

DOI: 10.13382/j.jemi.B2104012

ECO 多特征融合目标工件跟踪方法研究*

刘秀平¹ 袁 皓¹ 李梦璐¹ 王圣鹏¹ 徐 健¹ 张立昌¹ 闫焕营²

(1. 西安工程大学 电子信息学院 西安 710048; 2. 深圳罗博泰尔机器人有限公司 深圳 518109)

摘 要:针对复杂环境中目标工件跟踪精度不高的问题,提出了一种基于 ECO 改进的目标工件跟踪方法。首先基于 ECO 相关滤波器框架,采用 VGG 特征与传统手工特征加权融合的方法,有效提高目标工件跟踪精度;然后,利用快速判别尺度空间跟踪器实现对目标工件的尺度自适应跟踪;最后,引入一种高置信度更新指标确定跟踪模型的稀疏更新策略,提高算法鲁棒性。在 OTB-2015 标准数据集上进行测试,并与其他主流跟踪算法进行对比,实验结果表明,该算法的平均跟踪精度和平均重叠精度均为最优,分别达到 89.2% 和 68.6%;对于使用 CCD 工业相机拍摄的目标工件数据集,同样具备良好的跟踪性能,进一步验证了算法有效性。

关键词: ECO; 工件跟踪; 特征融合; 相关滤波

中图分类号: TP391.4; TN911.73 **文献标识码:** A **国家标准学科分类代码:** 540.10

Research on target work-piece tracking method based on ECO multi-feature fusion

Liu Xiuping¹ Yuan Hao¹ Li Menglu¹ Wang Shengpeng¹ Xu Jian¹ Zhang Lichang¹ Yan Huanying²

(1. School of Electronics and Information, Xi'an Polytechnic University, Xi'an 710048, China;

2. Shenzhen Municipal Robotel Robot Technology Co., Ltd, Shenzhen 518109, China)

Abstract: Aiming at the low tracking accuracy of target work-piece in complex environment, an improved tracking method for target work-piece based on ECO is presented. Firstly, based on the framework of eco correlation filter, VGG features and traditional manual features are weighted and fused to improve the tracking accuracy. Then, the fast discriminant scale space tracker is used to track the target work-piece adaptively. Finally, a high confidence update index is introduced to determine the sparse update strategy of the tracking model to improve the robustness of the algorithm. Tested on the OTB-2015 standard dataset and compared with other mainstream tracking algorithms, the experimental results show that the average tracking accuracy and the average overlap accuracy of the algorithm are both optimal, reaching 89.2% and 68.6%, This algorithm also has good tracking performance for target work-piece dataset taken with CCD industrial camera, which further verifies the validity of the algorithm.

Keywords: ECO; work-piece tracking; feature fusion; correlation filtering

0 引 言

目标跟踪在智能制造、工业自动化等领域具有广泛应用前景,是当前计算机视觉领域的研究热点^[1-2]。如今,为了实现智能工厂自动装配,对目标工件的跟踪速度、精度等方面提出了更高要求,所以研究高效的工件跟踪算法有着重要的现实意义^[3-5]。

国内外学者针对运动目标的跟踪问题提出多种有效方法。但在公开文献中,对工件跟踪方法研究较少。随着深度学习的广泛应用,由于深层神经网络具有强大的特征学习能力,能够极大地提高跟踪精度,而相关滤波 (correlation filtering, CF) 在跟踪速度方面表现突出。所以将深度学习和相关滤波结合成为目标跟踪算法的主流方向之一^[6-7]。基于分层卷积特征 (hierarchical convolutional features, HCF) 的视觉跟踪^[8]是一种将深度

学习与核相关滤波(kernelized correlation filters, KCF)^[9]相结合的跟踪算法,该方法选用 3 层卷积神经网络分别训练相关滤波器,有效提高跟踪精度,但是网络计算量大,跟踪算法速度慢。为了权衡跟踪速度和精度之间的关系,基于空间正则化相关滤波(SRDCF)的视觉跟踪算法^[10]采用单层神经网络,可以有效降低深度特征计算量,提升算法速度。连续卷积跟踪算法(C-COT)^[11],采用多层卷积特征,通过连续空间域插值转换操作,可以将不同分辨率的特征输入滤波器。基于高效卷积运算(efficient convolution operators, ECO)的跟踪算法^[12]是以 C-COT 算法为基础进行改进,减少了模型参数,更新频率,降低计算复杂度。

在实际的工业生产中,存在工件遮挡、尺度变化以及跟踪不稳定等难点问题,都会影响跟踪算法性能。为了解决上述问题,主要是利用深层卷积神经网络提取具有强大表征能力的深度特征来提高精度,但随着网络层数加深,结构复杂,计算量的增长导致算法跟踪效率大幅度降低。

因此,本文提出一种基于 ECO 多特征融合目标工件跟踪方法,首先利用轻量型 VGG 网络结构提取目标特征,并与传统手工特征相融合;其次,利用快速判别尺度空间跟踪器(fast discriminative scale space tracking, fDSST)^[13]对目标工件进行尺度自适应估计;最后,引入一种高置信度更新指标,平均峰值相关能量(average peak-to correlation energy, APCE)^[14]确定跟踪模型的稀疏更新策略。该方法在工件跟踪中速度、精度等方面均有良好表现。

1 ECO 相关滤波器

1.1 连续卷积算子

C-COT^[11]中引入了一种学习连续卷积算子,在目标训练样本中引入隐式插值模型,将不同特征图转移到连续空间域 $t \in [0, T]$,插值函数操作由算子 J_d 给出:

$$J_d \{x^d\}(t) = \sum_{n=0}^{N_d-1} x^d[n] b_d \left(t - \frac{T}{N_d} n \right) \quad (1)$$

式中: b_d 是一个周期为 $T > 0$ 的插值核。因此,结果 $J_d \{x^d\}$ 是一个插值的特征层,视为一个连续的 T 周期函数。使用 $J \{x\}$ 表示整个插值的特征图,其中 $J \{x\}(t) \in \mathbf{R}^D$ 。

目标置信函数是通过学习一个线性卷积算子 S_f 得到的,该算子以卷积滤波器 $f = (f^1, \dots, f^D) \in L^2(T)^D$ 为参数。将卷积算子定义为:

$$S_f \{x\} = \sum_{d=1}^D f^d * J_d \{x^d\} \quad (2)$$

通过对所有滤波器卷积响应进行求和,在连续空间

域得到最终的置信函数来定位目标。

每个训练样本 x_j 用置信函数 $y_j \in L^2(T)$ 来标记, y_j 是卷积算子 S_f 应用于训练样本 x_j 的期望输出。对滤波器 f 进行训练,给定一组 m 个样本的训练集 $\{(x_j, y_j)\}_1^m \subset \mathcal{X} \times L^2(T)$,用于最小化公式:

$$E(f) = \sum_{j=1}^m \alpha_j \|S_f \{x_j\} - y_j\|^2 + \sum_{d=1}^D \|\omega f^d\|^2 \quad (3)$$

C-COT 算法虽然在跟踪精度上表现很好,但由于模型参数庞大,导致速度缓慢;因为该算法采取逐帧更新方式,并将每一帧跟踪结果都加入训练集,所以容易产生过拟合。

1.2 高效卷积算子

ECO^[12]继续沿用 C-COT^[8]的学习连续空间卷积运算集成多分辨率目标特征图。通过在跟踪器中引入因式分解操作,解决模型参数过大,计算复杂度高等问题。使用主成分分析法(principal component analysis, PCA)^[15]减少模型参数数量,只从全部 D 个滤波器选择其中贡献大的 C 个。得到的分解卷积算子如下:

$$S_{pf}(x) = P f * J \{x\} = \sum_{c,d} p_{d,c} f^c * J_d \{x^d\} = f * P^T J \{x\} \quad (4)$$

式中: P 为一个 $D \times C$ 矩阵, P^T 类似一个线性降维算子, $p_{d,c}$ 是额外需要学习的系数,这样 d 个特征可以由 C 个滤波器基表示, $\sum_{c=1}^C p_{d,c} f^c$ 。并使用高斯-牛顿算法和共轭梯度法对 $S_{pf} \{x\}$ 进行优化。并且使用高斯混合模型(Gaussian mixture mode, GMM)^[16]建立样本集的概率生成模型,使 $p(x) = \prod_{l=1}^L \pi_l N(x; \mu_l; I)$ 。给定一个新的样本 x_j ,初始化权重为 $\pi_m = \gamma$,均值为 $\mu_m = x_j$ 。当样本集数目超过极限 L 时,丢弃一个权重 π_l 低于阈值的样本,或者将最接近的两个分量 k 和 l 合并成一个公共分量 n :

$$\pi_n = \pi_k + \pi_l, \mu_n = \frac{\pi_k \mu_k + \pi_l \mu_l}{\pi_k + \pi_l} \quad (5)$$

利用 Parseval 公式在傅里叶域内有效计算所需的距离比较,构造的损失函数为:

$$E(f) = \sum_{l=1}^L \pi_l \|S_f \{\mu_l\} - y_0\|_{L^2}^2 + \sum_{d=1}^D \|w f^d\|_{L^2}^2 \quad (6)$$

优化连续模型更新策略,直接采用参数 N_s 确定滤波器的更新频率,使每帧共轭梯度计算降低到 N_{cc}/N_s ,当 $N_s \approx 5$ 的时候,对跟踪性能提升的贡献最大。且模型更新不会影响样本空间模型的更新。

2 多特征 ECO 跟踪算法

在相关滤波跟踪器框架中,ECO 算法通过降低滤波器数量、模板更新频率以及压缩样本集 3 个方面减少系

统计算负担,相对提高了跟踪效率。但对于使用深度神经网络提取高维特征需要消耗大量时间的问题仍然没有得到解决。算法基本流程如图 1 所示,首先通过使用轻量型 VGGNet^[17] 加速工件特征提取效率,并将 VGG 特征和传统手工特征(fHOG+CN)响应图加权融合,融合响应图最大值即为当前帧目标位置;之后对目标位置利用尺度自适应方法获得工件最佳尺度估计;最后采用稀疏更新策略对跟踪模型进行更新。

2.1 轻量型 VGG

通过深层卷积神经网络提取出的深度特征内含丰富的语义信息,具有相当强大的表征能力,是实现良好跟踪的基础。针对 VGG-19 参数量大,提取高维目标特征时耗费大量计算资源的问题,本文采用图 2 所示的轻量型 VGG-f 网络^[18] 提取目标特征,简化神经网络,使得神经网络可以在小型设备上运行,有效提高跟踪算法效率,并使用 ImageNet 数据集^[19] 预训练得到具有良好泛化能力的模型。




图 2 轻量型 VGG-f 网络结构

Fig. 2 Lightweight VGG-f network architecture

卷积神经网络不同层对于目标跟踪的贡献并不相同^[6],各卷积层性能比较如图 3 所示。其中 0 层(输入 RGB 图像)提供性能较差,第 1 卷积层获得最佳性能,第 5 卷积层其次。浅层特征有较高的分辨率能够保留目标位置空间信息,深层特征包含更多的语义信息具有更好分类性能。

2.2 多特征响应融合

单一图像特征往往只能描述局部特定信息,甚至导致图像其他信息受损或者丢失,各特征及响应得分可视化如图 4 所示。本文根据以下不同类型特征表征能力的差异,选择多种互补特征在响应阶段进行加权融合。

fHOG 特征对目标细微变化和光照变化有良好的鲁棒性,但对目标大尺度形变适应性差;CN 特征能对彩色图像高效处理,更好的保留目标颜色位置信息;卷积神经




图 1 目标工件跟踪流程

Fig. 1 Target work-piece tracking flowchart




图 3 不同卷积层跟踪性能比较

Fig. 3 Comparison of convolution layer tracking performance

网络提取的深度特征对目标形变、遮挡、类间判别等问题都有很好的解决,但其空间分辨率较低,无法精确定位目标,容易造成漂移甚至跟踪失败。为了提升跟踪算法精度,充分利用互补特征,本文将得到的各类特征响应图分




图 4 特征及响应得分可视化

Fig. 4 Features and response score visualization

配不同权重。首先利用 fHOG 特征和 CN 特征的最大响应值得到手工特征权重 λ ; 其次利用 VGG 特征 Conv1 和 Conv5 的最大响应值得到 VGG 特征权重 α 。

$$\begin{cases} \lambda_{fHOG} = \frac{\max(r_{fHOG})}{\max(r_{fHOG}) + \max(r_{CN})} \\ \lambda_{CN} = \frac{\max(r_{CN})}{\max(r_{fHOG}) + \max(r_{CN})} \\ \alpha_{Conv1} = \frac{\max(r_{Conv1})}{\max(r_{Conv1}) + \max(r_{Conv5})} \\ \alpha_{Conv5} = \frac{\max(r_{Conv5})}{\max(r_{Conv1}) + \max(r_{Conv5})} \end{cases} \quad (7)$$

最后将手工特征和 VGG 特征的加权响应图进行融合, 得到最终响应图:

$$\begin{cases} r_{hand} = \lambda_{fHOG} r_{fHOG} + \lambda_{CN} r_{CN} \\ r_{deep} = \alpha_{Conv1} r_{Conv1} + \alpha_{Conv5} r_{Conv5} \\ r = w_1 r_{hand} + w_2 r_{deep} \end{cases} \quad (8)$$

式中: w_1 和 w_2 分别为对应权重, 通过搜索响应最大值即可确定跟踪目标当前位置。

2.3 尺度估计与更新

针对视频序列中运动目标工件由于拍摄远近或外观翻转引起的尺度变化问题, 本文采用 fDSST 尺度滤波器得到目标最优尺度估计。根据已得的目标位置, 以其为中心提取不同尺度的 fHOG 特征进行自适应尺度估计。用 $Q \times L$ 表示目标尺度大小, 定义一个尺度池 S , 提取以目标为中心的图像块 H_n , 大小为 $a^n Q \times a^n L$, 其中 a 为尺度因子, $n \in \left\{ \left\lceil -\frac{S-1}{2} \right\rceil, \dots, \left\lceil \frac{S-1}{2} \right\rceil \right\}$ 。为获得鲁棒近似, 使用

新样本分别对尺度滤波器的分子分母进行更新:

$$\begin{cases} A_t^l = (1 - \eta) A_{t-1}^l + \eta \bar{G} F_t^l, l = 1, \dots, d \\ B_t = (1 - \eta) B_{t-1} + \eta \sum_{k=1}^d \overline{F_t^k} F_t^k \end{cases} \quad (9)$$

式中: t 为第 t 个采样图像块, η 为学习率, $\bar{G}$ 和 $\bar{F}$ 分别为样本期望输出和 fHOG 特征的共轭复数。由式(8)计算得到目标尺度输出响应值:

$$Y_t = \frac{\sum_{l=1}^d \overline{A_{t-1}^l} Z_t^l}{B_{t-1} + \lambda} \quad (10)$$

式中: λ 为正则参数, 找到其中响应最大值即为目标最佳尺度估计结果。

在视频序列中明显可知, 相邻帧之间目标变化通常很小, 逐帧更新将不可避免地造成计算量庞大, 极大地降低跟踪速度, 并且在工件出现遮挡干扰时容易引入错误目标信息, 最终导致跟踪失败。为了提高跟踪算法的鲁棒性, 本文引入一种高置信度更新指标, 平均峰值相关能量 (APCE) 从而实现跟踪模型稀疏更新策略。其计算公式定义如下:

$$APCE = \frac{|F_{max} - F_{min}|^2}{\text{mean} \left(\sum_{q,r} (F_{q,r} - F_{min})^2 \right)} \quad (11)$$

式中: F_{max} 、 F_{min} 、 $F_{q,r}$ 分别表示当前帧滤波响应值最大、最小和 (q, r) 位置上的滤波响应值。这个判据可以反映响应图的振荡程度, 代表当前目标跟踪是否稳定。一般情况下, 当响应图只出现一个尖锐的单峰且周围呈低洼平缓状态时, 表示目标出现在跟踪范围内。相反, 当 APCE 值显著降低, 响应图出现多个峰值, 出现目标被遮挡或者目标丢失的情况, 在这种情况下选择不更新模型, 从而避


免模型漂移。只有当前 APCE 值大于历史均值,满足高置信度指标时,跟踪模型才进行更新,在有效预防遮挡干扰的同时大大降低模型更新次数,达到了加速效果。

3 实验结果与分析

3.1 实验环境及参数设置

本文所做实验均以 Visual Studio 2015、MATLAB2020b 为基础,使用 Window10 操作系统,CPU: Intel i7-7800X,GPU: NVIDIA RTX2080Ti,内存为 16 GB,卷积特征计算框架基于 MatConvNet 工具箱构建。

在分解卷积运算中,设置正则化参数为 $\lambda = 2 \times 10^{-7}$,



样本学习率 $\gamma = 0.009$,样本模型数量 $L = 35$ 。尺度滤波器数目 $S = 17$,尺度因子 $a = 1.02$,学习率 $\eta = 0.025$ 。稀疏更新策略从第 1 帧开始,使用高斯牛顿迭代 $N_{CN} = 10$ 和共轭梯度迭代 $N_{CG} = 5$ 进行优化。

3.2 跟踪算法性能对比

为了验证本文算法性能,实验选取 OTB-2015 标准数据集^[20],并与近年主流跟踪算法同时进行测试评估。将采用 OPE(one-pass evaluation)得到相应的平均跟踪精确度和成功率作为算法的评估指标。各跟踪算法对比实验结果如图 5 所示,精确度曲线图显示目标中心位置与阈值的距离精确度;成功率曲线图为重叠率精度与阈值的关系,以 AUC(area under curve)作为标准。




图 5 不同算法在 OTB-2015 的测试评估结果

Fig. 5 Test and evaluation results of different algorithms in OTB-2015

由图 5 可知,本文算法在 OTB-2015 测试集上的跟踪精确度和成功率分别为 0.892 和 0.686,在整体跟踪效果中均超越了多种近年来的主流目标跟踪算法。在平均跟踪精确度上,本文比次优的 ADNet^[21]算法提高了 1.8%,在平均跟踪成功率上也提高了 3.4%。通过本文算法与其他算法单在精度方面的比较,证明在一定程度上,使用 VGG 特征与传统手工特征的有效结合可以提高算法跟踪精度;而在成功率方面的提升可能主要归功于本文引入 APCE 作为高置信度指标,使用稀疏更新策略减少了模板的错误更新,降低跟踪失败概率。

其次跟踪速度同样是衡量算法性能的一项重要指标,将本文算法与其他算法进行实验对比。测试结果如表 1 所示,本文在使用深度特征的情况下跟踪速度大幅提高,这说明采用轻量型 VGG 网络结构确实可行,能在一定程度上提高跟踪速度。

不同的数据集具有不同属性,如表 2 所示,代表目标工件跟踪应用于现实工业领域的常见难点。包括快速移动(FM),相似的背景(BC),运动模糊(MB),变形(DEF),光照变化(IV),遮挡(OCC),离开视野(OV),

表 1 不同跟踪算法平均帧率

Table 1 Average frame rate for different tracking algorithms

算法名称	平均帧率/fps
本文	24.6
ADNet	3.2
ECO-HC	53.8
HCF	8.9
BACF	35.4
SRDCF	4.7
SiamFC	58.3
KCF	173.5

尺度变化(SV)。从表 2 数据可知,本文算法在 BC、OV 和 SV 三种属性中表现均为最佳。这证明深度特征具有强大表征能力,以及传统手工特征的精准定位能力;并且算法使用 fSST 作为目标尺度估计方法,不仅提高了跟踪速度还对其在 SV 属性上的鲁棒性有所保证。但由于算法对颜色特征也有一定依赖性,受其影响在 IV 方面表现一般;特别是面对 DEF 以及 OCC 这两个跟踪难点,能够进行模型在线自适应更新的 ADNet^[21]算法要更胜一筹。

表 2 不同算法面对不同难点的精确度

Table 2 Accuracy of different algorithms for different difficulties

算法	Ours	ADNet	ECO-HC	HCF	BACF	SRDCF	SiamFC	KCF
FM	0.863	0.846	0.792	0.787	0.771	0.694	0.623	0.532
BC	0.912	0.868	0.786	0.858	0.812	0.707	0.689	0.693
MB	0.852	0.817	0.742	0.836	0.819	0.698	0.613	0.597
DEF	0.868	0.869	0.828	0.834	0.798	0.755	0.694	0.631
IV	0.865	0.875	0.749	0.822	0.821	0.672	0.653	0.652
OCC	0.886	0.892	0.866	0.827	0.779	0.769	0.706	0.669
OV	0.894	0.842	0.863	0.698	0.781	0.645	0.639	0.532
SV	0.907	0.832	0.812	0.827	0.833	0.755	0.719	—

注:排名第 1 均以特殊字符标识

3.3 多特征 ECO 算法应用于工件跟踪

为了验证算法的有效性和可靠性,本文在 OTB-2015 标准测试集实验基础上,采用 CCD 工业相机拍摄了 3 段不同复杂背景下的工件跟踪视频序列。图 6(a) 工件跟踪视频序列 1 为模拟的工业生产流水线,当目标工件处于光照条件较差的环境中,所示 5 种算法均可以跟上目标,但本文算法受到干扰的影响最低;图 6(b) 工件跟踪视频序列 2 为在简单条件下机械臂抓取目标工件的移动

过程,该序列由于没有明显的背景干扰及光照变化因素影响,五种算法表现均良好,但在第 225 帧出现小面积遮挡时,除了本文算法跟踪稳定,其他算法均发生不同程度漂移;图 6(c) 工件跟踪视频序列 3 为复杂背景干扰下机械臂抓取目标工件的移动过程,面对复杂背景环境、部分遮挡及尺度变化等一系列难点问题,其他 4 种算法均发生不同程度的跟踪漂移甚至跟踪失败,只有本文算法仍能实现稳定准确的跟踪。




图 6 工件视频序列跟踪结果

Fig. 6 Work-piece video sequence tracking results

4 结 论

本文针对目标工件跟踪问题,在 ECO 相关滤波跟踪器的基础上,提出一种 VGG 特征与传统手工特征有效融合的算法。为了满足现实应用,提高算法跟踪效率,采用快速尺度判别方法估计目标大小,并引入高置信度指数作为稀疏更新策略标准。本文算法能够在复杂环境下保

持较高的准确性和鲁棒性,实现在工业领域对目标工件长时间稳定跟踪。尽管本文算法在时效性上有所进步,但与实时性仍有差距。对此问题,将考虑使用高效的端对端神经网络实现跟踪算法效率进一步提升。

参考文献

[1] 孟球, 杨旭. 目标跟踪算法综述[J]. 自动化学报, 2019, 45(7):1244-1260.

MENG B, YANG X. Overview of target tracking

- algorithm [J]. Journal of Automation, 2019, 45 (7): 1244-1260.
- [2] 包本刚. 融合多特征的目标检测与跟踪方法[J]. 电子测量与仪器学报, 2019, 33(9): 93-99.
BAO B G. Target detection and tracking based on multi-feature fusion [J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(9): 93-99.
- [3] WANG M, SHI Q Y, et al. A real-time tracking method for magnetism-driven capsule robot[J]. Instrumentation, 2019, 6(1): 50-56.
- [4] 王鹏, 孙梦宇, 王海燕, 等. 一种目标响应自适应的通道可靠性跟踪算法[J]. 电子与信息学报, 2020, 42(8): 1950-1958.
WANG P, SUN M Y, WANG H Y, et al. A channel reliability tracking algorithm with adaptive target response [J]. Acta electronica Sinica, 2020, 42 (8): 1950-1958.
- [5] 刘强. 智能制造理论体系架构研究[J]. 中国机械工程, 2020, 31(1): 24-26.
LIU Q. Research on intelligent manufacturing theory architecture [J]. China Mechanical Engineering, 2020, 31 (1): 24-36.
- [6] DANELLJAN M, HAGER G, SHAHBAZ K F, et al. Convolutional features for correlation filter based visual tracking [C]. Proceedings of the IEEE International Conference on Computer Vision Workshops, 2015: 58-66.
- [7] 韩晓微, 王雨薇, 谢英红, 等. 基于双相关滤波器的多通道尺度自适应目标跟踪[J]. 仪器仪表学报, 2019, 40(11): 73-81.
HAN X W, WANG Y W, XIE Y H, et al. Multi channel scale adaptive target tracking based on double correlation filter [J]. Journal of Instrumentation, 2019, 40 (11): 73-81.
- [8] MA C, HUANG J B, YANG X, et al. Hierarchical convolutional features for visual tracking[C]. Proceedings of the IEEE International Conference on Computer Vision, 2015: 3074-3082.
- [9] 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, 2014, 37(3): 583-596.
- [10] DANELLJAN M, HAGER G, SHAHBAZ K F, et al. Learning spatially regularized correlation filters for visual tracking [C]. Proceedings of the IEEE International Conference on Computer Vision, 2015: 4310-4318.
- [11] DANELLJAN M, ROBINSON A, SHAHBAZ K F, et al. Beyond correlation filters: Learning continuous convolution operators for visual tracking [C]. European Conference on Computer Vision, Springer, 2016: 472-488.
- [12] DANELLJAN M, BHAT G, SHAHBAZ K F, et al. Eco: Efficient convolution operators for tracking [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 6638-6646.
- [13] DANELLJAN M, HAGER G, SHAHBAZ K F, et al. Discriminative scale space tracking [J]. IEEE Transaction on Pattern Analysis and Machine Intelligence, 2017, 39(8): 1561-1575.
- [14] WANG M, LIU Y, HUANG Z. Large margin object tracking with circulant feature maps [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 4021-4029.
- [15] 吴晓婷, 闫德勤. 数据降维方法分析与研究[J]. 计算机应用研究, 2009, 26(8): 2832-2835.
WU X T, YAN D Q. Analysis and research of data dimension reduction method [J]. Computer Application Research, 2009, 26(8): 2832-2835.
- [16] MCLACHLAN G J, RATHNAYAKE S. On the number of components in a Gaussian mixture model[J]. Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery, 2014, 4(5): 341-355.
- [17] SIMOMYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. Computer Science, 2014, arXiv:1409.1556.
- [18] CHATFIELD K, SIMONYAN K, VEDALDI A, et al. Return of the devil in the details: Delving deep into convolutional nets [J]. Computer Science, 2014, arXiv:1405.3531.
- [19] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017, 60(6): 84-90.
- [20] WU Y, LIM J, YANG M H. Object tracking benchmark[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37(9): 1834-1848.
- [21] YUN S, CHOI J, YOO Y, et al. Action-decision networks for visual tracking with deep reinforcement learning [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 2711-2720.

作者简介



刘秀平, 2006 年于长治学院获得学士学位, 2009 年于西安建筑科技大学获得硕士学位, 2013 年于西安电子科技大学获得博士学位, 现为西安工程大学副教授, 主要研究方向为机器视觉目标检测、目标跟踪。
E-mail: liuxiuping8@126.com

Liu Xiuping received his B. Sc. degree from Changzhi University in 2006, M. Sc. degree from Xi'an University of Architecture and Technology in 2009, and Ph. D. degree from Xidian University in 2013. Now he is an associate professor at Xi'an Polytechnic University. His main research interests include machine vision, target detection and target tracking.