

基于多特征融合和尺度自适应的核相关滤波算法

郑慧国, 王壮壮, 蔡志明

(福建理工大学, 福建 福州 350118)

✉ 1196462180@qq.com; 1582765508@qq.com; caizm@fjut.edu.cn



摘要: 为了提高在复杂背景下进行跟踪的精度, 在 KCF(Kernel Correlation Filter)算法的基础上提出了一种改进方案。首先, 提取 HOG(Histogram of Gradient)、CN(Color-Naming)和 LBP(Local Binary Pattern)三种特征进行融合, 获得充分的目标特征信息; 其次, 引入尺度滤波机制用于估计目标最佳尺度大小, 得出最合适的跟踪框; 最后, 提出了一个峰值更新策略, 确保模型更新不受错误信息干扰。实验表明, 改进后的算法比 KCF 算法在精确度和成功率上分别提升了 6.5% 和 4.8%, 并且在处理尺度变化、变形、旋转等方面也有很好的鲁棒性。

关键词: 核相关滤波; 目标跟踪; 尺度自适应; 多特征融合

中图分类号: TP391 **文献标志码:** A

Kernel Correlation Filter Algorithm Based on Multi Feature Fusion and Scale Adaptation

ZHENG Huiguo, WANG Zhuangzhuang, CAI Zhiming

(Fujian University of Technology, Fuzhou 350118, China)

✉ 1196462180@qq.com; 1582765508@qq.com; caizm@fjut.edu.cn

Abstract: This paper proposes an improved algorithm based on KCF(Kernel Correlation Filter) algorithm to enhance the tracking accuracy in intricate background. Firstly, three features, HOG(Histogram of Gradient), CN(Color-naming) and LBP(Local Binary Pattern), are extracted for fusion to acquire adequate target feature data. Secondly, a scale filtering mechanism is introduced to estimate the optimal scale size of the target and obtain the most suitable tracking frame. Finally, a peak update strategy is proposed to ensure that model updates are not affected by error information interference. The experiment results show that the improved algorithm has 6.5% higher accuracy and 4.8% higher success rate than the KCF algorithm, and it also shows good robustness in handling scale modifications, distortion, rotation, and other factors.

Key words: KCF; target tracking; scale adaptation; multi feature fusion

0 引言(Introduction)

随着科技的发展, 计算机视觉越来越受到人们的关注, 而目标跟踪作为计算机视觉领域中非常重要的一个研究方向, 近年来被广泛应用于视频监控、自动驾驶技术、军事导航等领域^[1]。如今, 目标跟踪技术经过十几年的研究, 已经取得了一系列突破性的进展, 并出现了一些优秀的算法, 如 KCF(Kernel Correlation Filter)算法^[2]、SRDCF(Spatially Regularized Discriminative Correlation

Filters)算法^[3]和 MSCF(Mutation Sensitive Correlation Filter)算法^[4]等, 但仍然面临许多挑战, 主要有目标运动过程中发生外观尺度变化、目标被遮挡或超出视野范围、光照变化以及目标与背景相似度较高等^[5]。如何应对这些挑战并提升算法的鲁棒性, 成为当前目标跟踪领域的研究热点。本文基于 KCF 算法在复杂背景下进行跟踪存在跟踪精度不高、鲁棒性差的缺点, 提出了改进方案, 旨在通过多特征融合、尺度自适应和峰值

检测更新以提升算法的鲁棒性,并提高算法在应对目标变形、旋转和尺度变化等方面的精度和成功率。

1 核相关滤波算法 (Kernel Correlation Filter algorithm)

KCF 算法的核心思想是将相关滤波器的求解转化为岭回归的问题,并通过循环矩阵进行分类器的训练,为了有效处理非线性分类的问题,采用核函数计算目标和预测区域的匹配度,最后将复杂的计算搬到频域,加快算法的运行速度,从而实现目标的快速跟踪。

KCF 算法首先需要找到训练样本 x_i 与回归函数 y_i 的平方误差函数,使其最小化。然后通过线性岭回归表示误差函数最小值的最优解:

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

其中:函数 f 为分类函数, λ 为正则化参数。

在分类器训练过程中,通过循环矩阵对目标区域的正负样本进行密集采样,通过高斯核函数 $\varphi(x_i)$,将特征映射到高维空间,得到一个高维线性的结果 w ,即

$$w = \sum_i a_i x_i \quad (2)$$

其中: w 由训练样本线性组合得到, a 是滤波器系数;转换到频域中得到离散傅氏解:

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

分类器训练的目的即求解滤波器系数 a ,其中 $\hat{k}^{xx}$ 为矩阵 K 的第一行向量的傅里叶变换。

在样本快速检测阶段,将计算从时域转换到频域中,由循环位移计算训练样本和待测样本的核矩阵,得到输出响应值 $\hat{f}(z)$:

$$\hat{f}(z) = \hat{k}^{xz} \hat{a} \quad (4)$$

响应值 $\hat{f}(z)$ 的极值所在的位置就是当前帧目标的实际位置。

由于跟踪过程中目标及其背景会发生变化,因此需要对模型进行更新。KCF 算法模型采用线性差值的方法对目标样本滤波器模型 a 和外观模型 x 进行更新,如公式(5)和公式(6)所示:

$$\hat{a}^t = (1 - \eta) \hat{a}^{t-1} + \eta \hat{a} \quad (5)$$

$$\hat{x}^t = (1 - \eta) \hat{x}^{t-1} + \eta \hat{x} \quad (6)$$

其中: η 为学习率, $\hat{a}^t$ 、 $\hat{x}^t$ 分别表示第 t 帧的目标样本滤波器模型及其外观模型。

2 多特征融合和尺度自适应的目标跟踪算法 (Target tracking algorithm based on multi feature fusion and scale adaptation)

KCF 算法在目标背景复杂的条件下进行跟踪时,存在跟踪精度不高、鲁棒性差的问题,容易出现跟踪漂移的情况。本文在其基础上进行改进,首先分别提取目标的 HOG(Histogram of Gradient)特征、CN(Color-Naming)特征和 LBP(Local Binary Pattern)特征,进行多特征融合。其次引入尺度滤波机制,通过位置滤波器和尺度滤波器定位目标位置并更新尺度大小,实现目标尺度自适应。最后选择 APCE(Average Peak to

Correlation Energy)作为响应图的峰值检测指标,得到正确的目标特征信息用于模型更新,从而提高算法的鲁棒性。本文提出的算法流程图如图 1 所示。




图 1 本文提出的算法流程图

Fig. 1 The flowchart of the proposed algorithm

2.1 多特征融合

传统的 KCF 跟踪算法采用单一的 HOG 特征表示目标的特征,该特征在表示目标的梯度信息时,能够很好地表达目标的局部轮廓和形状信息,对光照变化具有良好的鲁棒性^[6],但是对于目标变形和快速运动等影响的应对能力不足。为了解决单一的特征无法应对复杂多变环境的问题,可以采用增加其他特征提取的方法,提高目标在各种场景下获取特征信息的能力。本文采用 HOG、CN 和 LBP 三种特征线性融合进行目标特征的提取,有效地提升了算法在各种复杂场景下进行目标跟踪的鲁棒性。其中,CN 特征将三通道的 RGB 图像通过映射的方式转换成 11 维的颜色通道,提升了算法对不同颜色特征信息的处理能力,但 11 维的通道也提升了算法处理的复杂性,影响了运算速度,因此又通过 PCA 方法,将特征从 11 维降低到 2 维,提升该算法的运算速度。CN 特征能够有效描述目标的颜色特征信息,并进行全局表征,对目标变形和快速运动的鲁棒性也十分出色^[7]。LBP 特征通过在一个 3×3 的窗口中对比邻域像素,用中心像素值与其他 8 个领域像素值对比,并将对比结果用二进制数 0 或 1 表示,然后将得到的 8 组二进制数转换成十进制数,转换后的值就是 LBP 值。LBP 特征能够描述图像的局部纹理信息,在处理旋转和灰度方面有较好的稳定性。HOG、CN 和 LBP 三种特征线性融合的计算公式如下:

$$C = C_{\text{HOG}} + C_{\text{CN}} + C_{\text{LBP}} \quad (7)$$

其中, C 表示三种特征线性融合后的结果,其特征通道数为 34。

2.2 尺度自适应

传统的 KCF 跟踪算法采取固定大小的尺度更新滤波器,其跟踪框无法满足目标的多尺度变化,导致跟踪的准确度较低。针对该情况,本文采用 DSST(Discriminative Scale Space Tracker)算法中提出的多尺度方法实现目标的尺度自适应。DSST 算法的核心思想是采用一种三维滤波器,该滤波器由一维尺度滤波器和二维位置滤波器组成且两者相互独立,因此该算法将目标跟踪问题转化为用位置滤波器确定目标中心平移、用尺度滤波器估计目标尺度变化情况的两个独立问题^[8];其思路是先用位置跟踪方法定位新一帧目标的位置,然后在定位好的位置处,用训练好的尺度分类器得出新一帧的尺度,同时用新位置和新尺度更新分类器参数,并重复这个过程,使分类器得到目标每一帧的位置和尺度参数,实现尺度自适应。尺度自适应算法的工作机制如下。

首先,提取目标所在图像的多维特征 f ,使用岭回归求解最小化代价函数 ϵ ,构造出最优滤波器:

$$\epsilon = \left\| \sum_{l=1}^d h^l \times f^l - g \right\|^2 + \lambda \sum_{l=1}^d \|h^l\|^2 \quad (8)$$

公式(8)中,融合后的特征维度为 $d=34$, f^l 表示第 l 维通道的样本特征; h^l 表示第 l 维通道的滤波器模型; g 代表训练样本 f 对应的回归期望; λ 为正则化系数。

然后,通过最小二乘对公式(8)在傅里叶域中求解得到尺度滤波器:

$$H^l = \frac{A_t^l}{B_t} = \frac{\overline{GF^l}}{\sum_{k=1}^N \overline{F^k} F^k + \lambda} \quad (9)$$

其中: $\overline{G}$ 表示共轭复数; N 表示训练样本的总数。

再然后,提取新一帧的图像 Z ,利用公式(10)求得最大响应值,得到当前帧的目标位置。

$$y = F^{-1} \left(\frac{\sum_{l=1}^d \overline{A^l} Z^l}{B + \lambda} \right) \quad (10)$$

最后,以当前帧中心位置为中心点,再通过尺度滤波器获取 s 个当前帧中目标的不同尺度大小,根据公式(9)得到的最大响应值确定新的尺度大小。目标最佳尺度选择原则如下:

$$a^n P \times a^n R \quad (11)$$


其中: $n \in \left\{ \lfloor \frac{-(s-1)}{2} \rfloor, \dots, \lfloor \frac{(s-1)}{2} \rfloor \right\}$, $\lfloor \cdot \rfloor$ 表示向下取整, P 、 R 分别为前一帧目标的宽和高, $s=33$ 为尺度滤波器的不同尺度数量, $a=1.02$ 为尺度因子。

2.3 峰值检测更新


跟踪算法的模型更新关乎目标在跟踪过程中能否实现持续跟踪。传统的跟踪算法在进行更新时,没有充分考虑模型在某一帧更新是否有利于目标的持续跟踪,因此当跟踪出现偏差时,更新模型会导致分类器学习到大量错误信息,致使在后续帧中目标跟踪的失败。

本文从跟踪器的峰值响应角度出发,观察到如果目标在没有受到干扰时,跟踪器的响应值表现为一个明显的峰值,在某一帧更新滤波器不会造成跟踪效果的减弱;当存在遮挡、光照变化等情况时,会导致得到的响应图出现多峰值的情况,单峰值和多峰值响应图如图 2 所示。若在某一帧更新滤波器,则很

有可能会将错误信息作为目标特征信息纳入模型中,导致跟踪过程发生漂移。



(a) 无干扰下的单峰值响应



(b) 干扰情况下的多峰值响应

图 2 单峰值和多峰值响应图

Fig. 2 Response graphs of single and multiple peaks

在图 2(a)中,目标没有受到其他因素的干扰,跟踪器的响应值为单峰值,而在图 2(b)中,目标受到遮挡、背景杂波等因素干扰,跟踪器的响应值呈现出多峰值的情况。因此,本文选取 APCE 作为响应图峰值检测指标,当检测到跟踪器的响应值出现一个明显的峰值时,说明此时无干扰,可以直接更新跟踪器;当检测到跟踪器的响应值为多个峰值时,说明此时存在干扰,需要根据当前帧的 APCE 值和平均历史峰值判断目标的受干扰程度,只有当 APCE 乘以常数 β 大于平均历史峰值时,跟踪器才会选择在该帧中进行更新,反之则不进行更新,防止出现将干扰信息更新到跟踪器中,造成跟踪效果下降的情况。APCE 的更新公式如下:

$$APCE = \frac{|F_{\max} - F_{\min}|^2}{\text{mean} \left(\sum_{w,h} (F_{w,h} - F_{\min})^2 \right)} \quad (12)$$

其中: $F_{w,h}$ 代表目标在 (w,h) 位置处的响应值, $F_{\max}$ 代表响应最大值, $F_{\min}$ 代表响应最小值。

3 实验结果与分析 (Experimental results and analysis)

3.1 实验环境与评价指标

本文算法使用 MATLAB 2018a 开发平台进行测定,实验平台配置 Intel(R) Xeon(R) CPU E5-2620 v3@ 2.40 GHz 的计算机,内存为 16 GB。实验的参数设置为正则化参数 $\lambda=10^{-4}$,初始模型更新率 $\eta=0.025$, $\beta=0.6$,LBP 特征提取的 $cell_size=20$ 。

本文算法的实验平台采用 OTB 系列数据集提供的评估系统,评价方式为 OPE(One-Pass Evaluation)。OPE 是指对目标第一帧初始化以后,在没有其他随机因素干扰的情况下,一次性地跑完整条序列。实验的评估指标分别是成功率曲线和精确度曲线。

成功率曲线通过目标预测框和目标真实框区域内像素的交并比表示,当在某帧时的交并比大于指定的阈值时,则判断此帧跟踪成功。通常情况下,设定该阈值 $T_0=0.5$ 。成功率(S)定义公式如下:

$$S = \frac{|r_t \cap r_0|}{|r_t \cup r_0|} \quad (13)$$

其中: r_t 表示候选框, r_0 表示人工标注的跟踪框, $||$ 表示区域的像素数目。

精确度曲线通过目标预测框中心点与目标真实框中心点的欧式距离大小表示。当在某帧时的欧式距离大于制定的阈值时,则判断此帧跟踪成功。本文设定的阈值 CLE 为 20 个像素点。精确度(P)的定义公式如下:

$$P = \frac{N_t}{N_s} \quad (14)$$


其中, N_t 、 N_s 分别指第 t 帧帧数和总帧数。

3.2 实验分析


为了表现本文算法的优越性,将本文算法与 CSK (exploiting the circulant structure of tracking-by-detection with kernels)、KCF、DSST、fDSST (Fast Discriminative Scale Space Tracker)^[9] 算法在 OTB100 数据集评估系统上进行了对比,其精确度和成功率检测结果如图 3 所示。

从图 3(a)和图 3(b)可知,本文所提算法在精确度和成功率方面都取得了最优的效果。在精确度曲线中,本文算法在设置阈值为 20 像素点处的精确度达到 77.3%,相比于原始的 KCF 算法提升了 6.5%,相较于多尺度跟踪算法 DSST 和目前性能较好且运行速度较快的 fDSST 算法,分别提升了 3% 和 6.4%;在成功率曲线中,本文算法在阈值 $T_0=0.5$ 时的成功率达到 63.5%,相较于原始的 KCF 算法提升了 4.8%,并且在低阈值时,算法一直处于最优状态。


为了体现目标在变形、平面内旋转和尺度变化 3 种情况下进行跟踪的鲁棒性,本文选择 DEF (Deformation)、IPR (In-Plane Rotation)、SV (Scale Variation) 3 种属性对比本文提出算法的效果。对比结果如图 4 所示。




(a) 精确度曲线




(b) 成功率曲线



(a) 变形精确度曲线




(b) 变形成功率曲线




(c) 平面内旋转精确度曲线

图 3 算法对比检测结果


Fig. 3 Algorithm comparison detection results



(d) 平面内旋转成功率曲线



(e) 尺度变化精确度曲线



(f) 尺度变化成功率曲线

图4 5种算法在变形、平面内旋转、尺度变化方面的结果对比
Fig. 4 Comparison of results of five algorithms in terms of scale modifications, deformation, and in-plane rotation

由图4(a)、图4(b)可知,本文所提算法在变形方面的精确度达到了81.2%,比原始的KCF算法提高了18.3%;在成功率方面达到了64.9%,相较于KCF算法提高了12.7%,并且远远超过其他算法。由此可见,本文所提算法在变形方面具有很好的性能。由图4(c)和图4(d)可知,本文所提算法在平面内旋转方面的精确度达到了78.7%,成功率达到了62.4%,相较于KCF算法分别提高了4.5%和2.5%,相比其他算法,本文算法在平面内旋转方面处于领先地位。在图4(e)、图4(f)尺度变化方面,本文算法的精确度和尺度自适应与DSST算法仅相差3.8%,并且成功率最优,为49.1%。由此可见,本文算法在尺度自适应方面取得了良好的效果。

4 结论(Conclusion)

本文针对目标跟踪在复杂背景下存在鲁棒性差、跟踪精度不高的问题,提出了一种融合多特征并进行目标尺度自适应的核相关滤波跟踪算法。该算法通过多特征融合操作,改善因特征提取不足而引起的跟踪漂移的情况;通过尺度自适应策略,改善因尺度变化引起的跟踪精度不高的情况;通过峰值更新机制,避免因遮挡等原因导致错误更新情况的产生,提升了目标持续跟踪的能力。

本文算法在OTB100评估系统上与现有的多个目标跟踪算法进行对比实验,得出其精确度和成功率分别达到了77.3%和63.5%,表明该算法的鲁棒性和跟踪精度得到了整体提升,同时验证出本文算法在变形、平面内旋转和尺度变化3个方面取得了良好的效果。

参考文献(References)

- [1] HAO J X, ZHOU Y M, ZHANG G S, et al. A review of target tracking algorithm based on UAV[C]//IEEE. Proceedings of the IEEE: 2018 IEEE International Conference on Cyborg and Bionic Systems (CBS). Piscataway: IEEE, 2018: 328-333.
- [2] 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.
- [3] LI E, TIAN C, ZUO W M, et al. Learning spatial-temporal regularized correlation filters for visual tracking[C]//IEEE. Proceedings of the IEEE: 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2018: 4904-4913.
- [4] ZHENG G Z, FU C H, YE J J, et al. Mutation sensitive correlation filter for real-time UAV tracking with adaptive hybrid label[C]//IEEE. Proceedings of the IEEE: 2021 IEEE International Conference on Robotics and Automation (ICRA). Piscataway: IEEE, 2021: 503-509.
- [5] 彭建盛, 许恒铭, 李涛涛, 等. 生成式与判别式视觉目标跟踪算法综述[J]. 科学技术与工程, 2021, 21(35): 14871-14881.
- [6] 楼立志, 张涛, 张绍明. 基于DPM和R-CNN的高分二号遥感影像船只检测方法[J]. 系统工程与电子技术, 2019, 41(3): 509-514.
- [7] 张红颖, 胡文博. 多特征融合的尺度自适应相关滤波跟踪算法[J]. 系统工程与电子技术, 2019, 41(5): 951-957.
- [8] 马康, 娄静涛, 苏致远, 等. 结合特征融合和尺度自适应的核相关滤波器目标跟踪算法研究[J]. 计算机科学, 2020, 47(增刊2): 224-230.
- [9] DANELLJAN M, HÄGER G, KHAN F S, et al. Discriminative scale space tracking[J]. IEEE transactions on pattern analysis and machine intelligence, 2017, 39(8): 1561-1575.

作者简介:

郑慧国(1997-),男,硕士生。研究领域:计算机视觉,目标跟踪。

王壮壮(1997-),男,硕士生。研究领域:计算机视觉,目标跟踪。

蔡志明(1977-),男,博士,教授。研究领域:计算机视觉与图像处理。本文通信作者。