

文章编号: 1671-0576(2022)01-0048-08

无人机对地运动目标跟踪算法

杜 君¹, 孟夏莹¹, 顾丹丹¹, 许祯瑜², 刘 健¹

(1. 上海无线电设备研究所, 上海 201109; 2. 上海卫星工程研究所, 上海 201109)

摘 要: 提出一种基于改进相关滤波器的无人机对地运动目标跟踪算法。该算法提取目标梯度方向直方图特征、颜色特征、深度特征等多种特征, 利用空间可靠性图改进相关滤波器, 提高对不规则形状目标的跟踪性能, 基于高效卷积算子进行特征降维和紧凑样本空间构建, 降低数据冗余。根据相关滤波器得到的目标特征响应确定目标跟踪框的位置, 实现目标跟踪。经实验验证: 该算法的跟踪平均中心距离误差为 16.07, 跟踪成功率曲线下面积参数为 0.54, 均优于目前其他先进算法; 跟踪平均帧率最高可达 44.09 帧/秒, 具有较好的实时性。

关键词: 目标跟踪; 相关滤波; 特征提取; 空间可靠性

中图分类号: TN911.73

文献标志码: A

DOI: 10.3969/j.issn.1671-0576.2022.01.009

Method for Ground Moving Target Tracking of UAV

DU Jun¹, MENG Xiaying¹, GU Dandan¹, XU Zhenyu², LIU Jan¹

(1. Shanghai Radio Equipment Research Institute, Shanghai 201109, China;
2. Shanghai Satellite Engineering Research Institute, Shanghai 201109, China)

Abstract: An algorithm of tracking moving target on the ground by unmanned aerial vehicle (UAV) based on improved correlation filter is proposed. Multiple features of the target, such as histogram of gradient (HOG) feature, color names (CN) feature, convolutional neural network (CNN) feature are extracted. To improve the tracking performance of irregular objects, the spatial reliability graph is used to improve the correlation filter. Based on efficient convolution operator, feature dimension reduction and compact sample space are constructed to reduce data redundancy. The position of the target tracking box is determined according to the target characteristic response obtained by the correlation filter. So the target tracking is accomplished. Experimental results show that the mean centre location error (CLE) is 16.07, the area under curve(AUC) of tracking success rate is 0.54. Both evaluation parameters are superior to other advanced algorithms. The algorithm can track small moving target accurately in real time, with an average frame rate of 44.09 frames per second.

收稿日期: 2021-10-14

基金项目: 国家自然科学基金(61901269); 上海市自然科学基金(20ZR1455100)

作者简介: 杜 君(1994—), 女, 硕士, 工程师, 主要从事光学图像目标检测、跟踪、识别技术研究。

Key words: target tracking; correlation filtering; feature extraction; spatial reliability

0 引言

近年来,基于判别相关滤波器(discriminative correlation filter, DCF)的方法在跟踪基准测试^[1]的准确性和鲁棒性方面表现出持续的性能提升。基于 DCF 的跟踪算法一般是基于多维特征^[2]、鲁棒性尺度估计^[3]、非线性内核^[4]、长期内存组件^[5],或通过建立复杂的学习模型^[6]及减少边界效应^[7]来实现的,但这些改进明显降低了跟踪速度,无法满足目标跟踪的实时性要求。近几年,卷积神经网络(convolutional neural networks, CNN)深度特征^[8-9]也被应用到基于判别相关滤波器的算法中,但高维参数空间容易过度拟合,且高维度将导致计算复杂度增加,跟踪速度变慢,同样无法满足目标跟踪的实时性要求。

为了在提升无人机对地面运动目标跟踪精度的同时保持一定的实时性,本文提出了基于改进相关滤波器和目标多特征融合的运动目标跟踪算法。通过提取梯度方向直方图(histogram of gradient, HOG)特征、三维颜色(color names, CN)特征和 CNN 深度特征等多维特征,对各特征进行选择组合并融合,实现对目标的有效表征。其中,梯度方向直方图特征对几何和光学形

变具有良好不变性;相对于一维灰度特征,三维颜色特征包含更加丰富的目标信息,且具有运动方向不变性,在快速运动、快速变形情况下跟踪效果较好,并且没有边界效应;卷积神经网络浅层的深度特征能较好地表征目标的轮廓信息,高层的深度特征能较好地表征目标的语义信息。

1 算法原理

1.1 算法流程

基于改进相关滤波器和目标多特征融合的运动目标跟踪算法流程如图 1 所示。首先从输入图像中的目标局部搜索区域提取目标多通道特征,在初始帧中初始化空间可靠性图,基于空间可靠性图对相关滤波器进行改进,自动估计的空间可靠性图将相关滤波器限制在适合于跟踪的部分,以改善不规则形状目标的搜索范围和跟踪性能;然后利用线性降维算子矩阵,减少模型中的参数数目,训练样本分布的紧凑生成模型,降低空间和时间复杂度,提供更好的样本多样性;最后用改进的相关滤波器与提取的特征进行响应,确定目标跟踪框的位置。相关滤波器、样本和空间可靠性图通过相应规则不断优化更新。




图 1 跟踪算法流程图

1.2 提取样本特征

根据上一帧确定的目标中心位置确定当前帧的局部搜索区域,提取目标局部搜索区域中的目标多通道特征,将提取的多通道特征存储于一个元胞数组中,进而用于训练,得到每个特征通道相应的相关滤波器。将各个通道特征与相应滤波器

的响应分数的加和作为最终预测目标位置的响应分数。同一帧图像提取的 3 种特征的特征图如图 2 所示。

将从图像中提取的特征图作为训练样本, M 种训练样本表示为 $\{x_j\}_1^M \subset \mathcal{X}(j \in \{1, 2, \dots, M\})$, \mathcal{X} 表示样本空间。从同一图像块中提取的第 j 个训练样本 x_j 包含 D 个特征通道样本




图 2 同一帧图像提取的 3 种特征的特征图

$x_j^1, x_j^2, \dots, x_j^D$ 。传统的 DCF 方法^[4,7]假设特征通道具有相同的空间分辨率,即具有相同数量的空间采样点,而本文使用 N_d 表示 x_j^d 的空间样本点的个数,特征通道序号 $d \in \{1, 2, \dots, D\}$ 。将特征通道样本 $x_j^d \in R^{N_d}$ 视为一个函数 $x_j^d(n)$,其中离散空间变量 $n \in \{0, 1, \dots, N_d - 1\}$, R^{N_d} 表示有 N_d 个空间样本点的矩阵空间。样本空间表示为 $\chi = R^{N_1} \times R^{N_2} \times \dots \times R^{N_D}$ 。为了能在连续空间域解决学习问题,引入隐式插值模型,将特征映射转移到连续空间域,将 $[0, B) \subset \mathbf{R}$ 看作特征图的空间支持,其中标量 B 代表支持区域的大小, \mathbf{R} 为实数集。在实践中, B 是任意的,因为它表示坐标系的缩放。对于第 d 个特征通道 J_d , 定义插值运算表达式为 $J_d: R^{N_d} \rightarrow \Gamma^2(B)$ 。其中 $\Gamma^2(B)$ 为经过插值后特征通道的连续空间, Γ^2 为二维空间大小。最终连续域的特征通道表达式^[10]为

$$J_d\{x^d\}(t) = \sum_{n=0}^{N_d-1} x^d(n) b_d(t - Bn/N_d) \quad (1)$$

式中: $J_d\{x^d\}$ 为一个内插特征层,可看作是一个连续的周期函数,表示特征图的周期扩展,其中 x^d 为第 d 个特征通道的训练样本; $t = 1, 2, \dots, T$, 表示第 t 帧; b_d 为一个周期为 B 的插值核,且满足 $B > 0$ 。本文用 $J\{x\} = \{J_d\{x\}\}_{d=1, D}$ 表示整个插值特征映射,其中 $J\{x\}(t) \in R^{N_d}$, 相应的滤波器记为 $f = \{f_d\}_{d=1, D}$, 其中 f_d 为第 d 个特征通道对应的相关滤波器。

1.3 构建空间可靠性图

本算法基于空间可靠性图,使最后学习到的相关滤波器参数只集中在置信分数高的区域,即目标区域,其他区域几乎为 0,可有效抑制背景信息。

大多数的相关滤波器^[11]都假定有独立的特征通道。在学习阶段通过最小化损失函数,即通道相关输出与期望输出 $y \in \Gamma^2(B)$ 之间差的平方和,来获得最佳滤波器。最小化损失函数等价

关系遵循帕斯瓦尔(Parseval)定理,即

$$\begin{aligned} \operatorname{argmin}_f \sum_{d=1}^D \| J_d * f_d - y \|^2 + \lambda \sum_{d=1}^D \| f_d \|^2 = \\ \operatorname{argmin}_f \sum_{d=1}^D (\| \hat{f}_d^H \operatorname{diag}(\hat{J}_d) - \hat{y}_d \|^2 + \lambda \| \hat{f}_d \|^2) \end{aligned} \quad (2)$$

式中: $\operatorname{argmin}(\cdot)$ 为最小化函数; $*$ 为卷积运算符; $\| \cdot \|$ 为范数运算符; 算子 $i = \operatorname{vec}(F(i))$ 是一个转换成列向量的傅里叶变换; $\operatorname{diag}(\cdot)$ 为对角矩阵; H 为厄米特转置运算符; $\lambda = 0.01$ 为正则化参数。通过把式(2)中每个通道的梯度复杂度均衡到零,最小化公式得到封闭形式的解决方案。由于输入循环假设,并假设所有像素对滤波器学习的可靠性相同,使该解决方案受到边界缺陷制约。因此,引用一个有效的空间可靠性图构造方法,得到一种新的空间约束相关滤波器学习框架。

空间可靠性图 m 的组成元素 $m \in \{0, 1\}$ 表示每个像素的学习可靠性。像素 x 与目标外观 a 有关的条件概率 $p(m=1 | a, x)$ 被指定为

$$p(m=1 | a, x) \propto p(a | m=1, x) \times p(x | m=1) p(m=1) \quad (3)$$

式中: $p(a | m=1, x)$ 表示外观模型似然度,通过贝叶斯规则从目标前景-背景颜色模型(其在跟踪期间被保持为颜色直方图)中计算得到; $p(x | m=1)$ 表示空间先验概率; $p(m=1)$ 表示前景和背景直方图提取的区域面积的比率。中心元素可靠性的变形不变性在此方法中通过定义弱空间先验而得到强化。弱空间先验定义为

$$p(x | m=1) = k(x; \sigma) \quad (4)$$

式中: $k(x; \sigma)$ 是一种改进的 Epanechnikov 内核。定义 $k(r; \sigma) = 1 - (r/\sigma)^2$, 其中 σ 为尺寸参数,表示小包围框轴,取值区间为 $[0.5, 0.9]$ 。设目标在中心的先验概率为 0.9, 可将远离中心的像素概率转换为统一的先验概率。

标记空间可靠性图 m 的空间一致性,可通过将式(3)作为马尔可夫随机场中的一元项来实现。使用有效的求解器^[12]计算 m 的最大后验解,可得到目标后验概率。空间可靠性图的构建过程如图 3 所示。图 3(a)为跟踪目标边界框的训练原图,图 3(b)为在马尔可夫随机场优化中作为一元项使用的空间先验概率,图 3(c)为根据前景-背景

颜色模型得到的目标对数似然,图 3(d)为经马尔可夫随机场正则化后的目标后验概率二值化空间可靠性图。




图 3 空间可靠性图的构建

1.4 基于空间可靠性图改进相关滤波器

为了符号清楚起见,假定只有一个特征通道,即 $D = 1$,并且丢弃通道索引 d 。因为滤波器学习在通道上是独立的,则简化后的目标函数为

$$\begin{aligned} & \operatorname{argmin}_f \|J \odot f - y\|^2 + \lambda \|f\|^2 = \\ & \operatorname{argmin}_f \|\hat{f}^{\text{H}} \operatorname{diag}(\hat{J}) - \hat{y}\|^2 + \lambda \|\hat{f}\|^2 \end{aligned} \quad (5)$$

式中: \odot 为同或逻辑运算符。空间可靠性图 m 标识了在学习过程中应忽略的滤波器中的像素,即引入约束 $f = m \odot f$ 。

引入对偶变量 f_c (它的主要作用是让算法能够收敛)和约束条件 $f_c - m \odot f \equiv 0$,根据 Augmented Lagrangian 方法^[13]构建增广拉格朗日表达式,并通过乘子交替方向法^[14]迭代最小化。最终得到的空间约束滤波器

$$f^{i+1} = m \odot F^{-1}(\hat{l}^i + \mu \hat{f}_c^{i+1}) / (\lambda / 2D + \mu^i) \quad (6)$$

式中: i 是当前帧帧号,取值为正整数; $F^{-1}(\cdot)$ 是傅里叶逆变换函数; \hat{l} 是复拉格朗日乘子; $\mu > 0$ 是约束惩罚系数。用于更新约束惩罚系数 μ 的标准方案为 $\mu^{i+1} = \beta \mu^i$,其中 $\beta = 3$ 为增广拉格朗日优化参数。

1.5 基于卷积算子分解的特征降维

根据上一帧确定的目标中心位置确定当前帧的局部搜索区域。已知插值特征映射和相应的滤波器表达式,两者通过卷积计算就可得到预测目标位置的响应。预测目标位置的检测分数

$$S_f\{x\} = f * J\{x\} = \sum_{d=1}^D f_d * J_d\{x^d\} \quad (7)$$

采用最小化损失函数来学习滤波器,可将式(2)改写为损失函数

$$E_t(f) = \sum_{j=1}^M \alpha_j \|S_f\{x_j\} - y_j\|_{r_2}^2 + \sum_{d=1}^D \|\omega f_d\|_{r_2}^2 \quad (8)$$

式中: $\alpha_j \geq 0$ 为样本 x_j 的权重; y_j 为样本 x_j 的标记检测分数,是周期重复的高斯函数; ω 为空间惩罚项,用来缓解周期假设的缺点,允许扩展空间支持^[7],是 t 的函数; $\|\cdot\|_{r_2}$ 为 Γ^2 空间的 2 范数。定义为

$$\|g(t)\|_{r_2}^2 = \frac{1}{T} \int_0^T |g(t)|^2 dt \quad (9)$$

式中: $g(t)$ 表示一个周期函数; T 为周期。

每个特征通道对应一个相关滤波器,但学习到的多数滤波器的作用微不足道,且对于高维深层特征尤为明显。这种滤波器对目标定位帮助很小,而且会影响训练时间。故不单独为特征通道 J_d 学习滤波器,而是使用一组数量较少的主滤波器 $f = [f_c]$ ($c \in \{1, 2, \dots, C\}$),其中滤波器个数 $C < D$ 。将特征通道 J_d 的滤波器构造为一组学习系数为 $p_{d,c}$ 的滤波器的线性组合 $\sum_{c=1}^C p_{d,c} f_c$ 。其学习系数可以简洁地表示为 $D \times C$ 维矩阵 $\mathbf{P} = [p_{d,c}]$ 。然后,可以将新的多通道滤波器写成矩阵向量积 $\mathbf{P}\mathbf{f}$ 。因此,卷积算子分解得到的新的响应分数为

$$\begin{aligned} S_{P\mathbf{f}}\{x\} &= \mathbf{P}\mathbf{f} * J\{x\} \\ &= \sum_{c,d} p_{d,c} f_c * J_d\{x^d\} \\ &= \mathbf{f} * \mathbf{P}^T J\{x\} \end{aligned} \quad (10)$$

式(10)的最后一个等式是由卷积的线性关系推导得出的。卷积分解还可以被看作以下两步运算:在第 t 帧上的特征向量 $J\{x\}$ 首先乘以 \mathbf{P} 的转置矩阵 \mathbf{P}^T ,得到的 C 维特征图再与滤波器 \mathbf{f} 进行卷积。因此矩阵 \mathbf{P}^T 类似于线性降维算子,从 D 维特征滤波器到 C 维特征滤波器降低了线性复杂度。

根据式(8),通过最小化式(10)的损失函数来一起学习矩阵 \mathbf{P} 和滤波器 \mathbf{f} 。本文使用高斯-牛顿(Gauss-Newton)法和共轭梯度法来学习矩阵 \mathbf{P} 和滤波器 \mathbf{f} 。

本算法从第一帧设置学习矩阵 \mathbf{P} ,并在之后的跟踪中保持不变。学习过程中,只有投影的特征映射 $\mathbf{P}^T J\{x\}$ 需要存储,从而显著节省内存。为了保持跟踪器的鲁棒性,采用主成分分析

(principal component analysis, PCA)方法初始化系数矩阵 \mathbf{P} 。

1.6 构建紧凑的样本空间模型

经过测试,如本算法在每一帧中收集新的样本,会产生样本的大量冗余,导致跟踪效率降低。为了既能减少因外观上的缓慢变化导致的样本大量冗余,又能较全面地描述外观的变化,引入一个紧凑的样本集模型^[15]。

将训练数据建模为高斯分量的混合体,其中每个组件代表外观的不同方面,实现紧凑而多样的数据表示,从而降低过度拟合的风险。

此方法是基于样本特征映射 x 和相应的期望输出 y 的联合概率分布 $p(x, y)$ 。给出 $p(x, y)$,直观的目标是找到可以最大限度地降低预期的相关误差的过滤器。替换式(8),将损失函数进一步完善为

$$E_l(f) = E(\|S_f\{x\} - y\|_{r_2}^2) + \sum_{d=1}^D \|\omega f_d\|_{r_2}^2 \quad (11)$$

式中: $E(\cdot)$ 为数学期望。损失函数用样本联合概率分布 $p(x, y)$ 进行评估,表达式为

$$p(x, y) = \sum_{j=1}^M \alpha_j \delta_{x_j, y_j}(x, y) \quad (12)$$

式中: α_j 是权重系数; $\delta_{x_j, y_j}(\cdot)$ 是在训练样本和期望输出 (x_j, y_j) 处的冲击响应函数。式(8)的原始损失函数是通过估计样本分布而得到的一个特例。 α_j 通常设置为指数衰减,由学习率 γ 控制,满足 $\alpha_j \sim (1 - \gamma)^{M-j}$ 。学习率决定了目标函数能否收敛到局部最小值,以及何时收敛到最小值。由实验可知,当 $\gamma = 0.025$ 时,损失函数能够最快收敛到最小值。而提出估计样本分布 $p(x, y)$ 的紧凑模型,可以使式(11)的损失函数得到更有效的近似。

样本 x 和其期望输出 y 是一一对应的,输出的形状符合峰值在目标中心的高斯分布。因此,可以假设目标位于图像区域中,高斯分布峰值输出假设为 y_0 ,通过移动 x 使所有 $y = y_0$ 都是相同的。 y 不变,改变 x 的值,使峰值平移量体现在水平分量上。此时,样本分布可以被分解为 $p(x, y) = p(x) \delta_{y_0}(y)$,其中 $\delta_{y_0}(y)$ 表示单位冲激函数。现在只需要估计 $p(x)$ 。应用高斯混合

模型(Gaussian mixture model, GMM)估计 $p(x)$,表达式为

$$p(x) = \sum_{h=1}^H \pi_h N(x; \mu_h; \mathbf{I}) \quad (13)$$

式中: H 是高斯分量的数量; π_h 是第 h 个分量的优先权重; $N(x; \mu_h; \mathbf{I})$ 是 GMM 定义的高斯分量,其中 $\mu_h \in \mathcal{X}$ 是第 h 个高斯分量的平均数, \mathbf{I} 是恒等矩阵形式的协方差矩阵。协方差矩阵被设置为恒等矩阵,避免了高维样本空间中的代价推断。

利用 Declercq 和 Piater 在线算法的一个简化版本更新 GMM。每次新增一个样本 x_{new} ,初始化一个新的分量 $N(x; \mu_z; \mathbf{I})$,且权重 $\pi_z = \gamma$,平均数 $\mu_z = x_{\text{new}}$ 。如果分量的数量超过事先设定的上限 H ,则需要简化 GMM。若分量的权重低于设定门限,这个分量将被舍弃;否则,合并最近的两个分量 k 和 h 为一个共同的分量 n 。分量 n 的权重 π_n 和平均数 μ_n 为

$$\begin{cases} \pi_n = \pi_k + \pi_h \\ \mu_n = \frac{\pi_k \mu_k + \pi_h \mu_h}{\pi_k + \pi_h} \end{cases} \quad (14)$$

式中: π_k, π_h 分别为分量 k 和 h 的权重; μ_k, μ_h 分别为分量 k 和 h 的平均数。

在傅里叶域使用 Parseval 公式快速计算分量 k 和 h 之间的距离 $\|\mu_k - \mu_h\|$ 。此时,式(11)可近似为

$$E_l(f) = \sum_{h=1}^H \pi_h \|S_f\{\mu_h\} - y_0\|_{H^2}^2 + \sum_{d=1}^D \|\omega f_d\|_{H^2}^2 \quad (15)$$

与式(8)比较,式(15)在复杂度上的主要区别是样本的数量由原来的 M 减少到 H 。在实验中,将分量的数量 H 设置为 $M/8$,具体仿真参数设为 $M=400, H=50$ 。样本分布模型 $p(x, y)$ 结合 1.5 节的卷积分解,通过用映射样本 $\mathbf{P}^T J\{x\}$ 替换样本 x ,使计算复杂度进一步降低,从而提升跟踪速度。这种映射不影响公式形式,因为矩阵 \mathbf{P} 在第一帧进行学习后,在之后的跟踪中保持不变。

1.7 更新策略

当空间可靠性图更新时,首先直接提取当前图像的前景直方图 \bar{q}^f 和背景直方图 \bar{q}^b ,然后结

合上一帧的前景直方图 q_{i-1}^f 和背景直方图 q_{i-1}^b 得到最终的前景和背景直方图,更新策略为

$$\begin{cases} q_i^f = (1 - \eta_q)q_{i-1}^f + \eta_q \tilde{q}^f \\ q_i^b = (1 - \eta_q)q_{i-1}^b + \eta_q \tilde{q}^b \end{cases} \quad (16)$$

式中: η_q 为学习率。

无人机航拍图像中会出现目标过小,颜色与周围环境分辨不明显,外观形状模糊的问题。当目标被相似颜色物体遮挡时,如果每帧都更新空间可靠性图,会因为临近图像帧样本过度形似而产生样本的过度拟合。经过大量的实验发现,当空间可靠性图每隔 3 帧或 6 帧更新一次时,跟踪效果更好。

利用共轭梯度法更新滤波器和降维矩阵增量。如果滤波器模型更新在每一帧进行,计算数据量将偏大,计算负载将过重。本算法采用稀疏的更新方案,每间隔一定帧数更新一次滤波器。用模型更新间隔 N_{filter} 来确定更新的频率,其中 $N_{\text{filter}} = 1$ 对应在一帧都更新滤波器。

经实验观察,当 $N_{\text{filter}} \approx 5$ 时跟踪精度和成功率更高,说明模型适度更新时跟踪效果更好。这是因为构建紧凑的样本空间模型减少了对最近邻近帧训练样本的过度拟合。但是也要有效把控 N_{filter} 的取值,取值太大会使得模型响应速度跟不上目标的变化速度。

当空间可靠性图更新间隔 N_{mask} 与模型更新间隔 N_{filter} 满足 $N_{\text{mask}}/N_{\text{filter}} = v$ 时,跟踪效果更好。其中, $v \geq 1$,且 v 为整数。

2 实验验证

2.1 目标跟踪精度实验

将本文算法与同时考虑通道和空间可靠性的

判别相关滤波器(discriminative correlation filter with channel and spatial reliability, CSR-DCF)算法^[16]、高效卷积运算符跟踪(efficient convolution operators for tracking, ECO)算法^[17]、采用直方图和颜色特征的高效卷积运算符跟踪(efficient convolution operators for tracking-HOG and CN, ECO-HC)算法^[17]、连续域卷积操作跟踪(beyond correlation filters: learning continuous convolution operators for visual tracking, C-COT)算法^[10]、融合学习的实时跟踪(complementary learners for real-time tracking, Staple)算法^[18]、运用核相关滤波器(kernelized correlation filters, KCF)的高速跟踪算法^[4]、多尺度空间跟踪(discriminative scale space tracking, DSST)算法^[3]、自适应颜色特征贡献的实时视觉跟踪(adaptive color attributes for real-time visual tracking, CN)算法^[2]、基于多专家熵最小化的鲁棒跟踪(robust tracking via multiple experts using entropy minimization, MEEM)算法^[19]、长时间相关跟踪(long-term correlation tracking, LCT)算法^[5]等 10 个算法进行跟踪效果对比,实验数据包括 15 个无人机航拍数据集,视频序列分辨率为 1280 像素 \times 720 像素,实验中目标均为像素数小于 20 像素 \times 20 像素的小目标。

真实目标矩形框中心与跟踪结果矩形框中心之间的平均欧氏距离记为平均中心距离误差(center location error, CLE),用 E_{CL} 表示。以 E_{CL} 为评价指标,本文算法与 CSR-DCF、ECO、ECO-HC、C-COT、Staple、KCF、DSST、CN、MEEM、LCT 算法的平均中心距离误差如表 1 所示。可知,本文算法平均中心距离误差低于其他算法,跟踪效果更好。

表 1 本文算法与其他算法平均中心距离误差比较

算法	本文算法	CSR-DCF	ECO	ECO-HC	C-COT	Staple	KCF	DSST	CN	MEEM	LCT
E_{CL}	16.07	49.26	25.85	29.94	25.82	63.18	79.43	88.32	89.75	29.39	138.80

2.2 目标跟踪成功率实验

跟踪成功率表征的是估计目标矩形框与真实目标矩形框的重叠率,即两个矩形框重叠(overlap score, OS)部分的面积比上两个矩形框取并集的面积。重叠率 R_{OS} 的数学表达式为

$$R_{\text{OS}} = \frac{R_{\text{gt}} \cap R_{\text{t}}}{R_{\text{gt}} \cup R_{\text{t}}} \quad (17)$$

式中: R_{gt} 为人工标定的目标真实区域; R_{t} 为目标跟踪框区域。

使用成功率曲线图中各曲线下的面积(area under curve, AUC)作为评价指标,用 A_{UC} 表示。

成功率曲线图的横坐标从 0 到 1 取连续阈值,纵坐标为重叠率大于该阈值的所有帧占该序列总帧数的百分比。本文算法与其他算法的 A_{uc} 如表 2

表 2 本文算法与其他算法成功率比较

算法	本文算法	CSR-DCF	ECO	ECO-HC	C-COT	Staple	KCF	DSST	CN	MEEM	LCT
A_{uc}	0.540	0.385	0.529	0.461	0.472	0.350	0.292	0.265	0.316	0.445	0.232

2.3 目标跟踪效率实验

目标跟踪效率对比实验,采用平均帧率(frames per second,FPS)作为评价指标,用 R_f 表示,目标跟踪平均帧率如表 3 所示。与同样使用深度特征的 ECO 和 C-COT 算法相比,本文算法

表 3 本文算法与其他算法目标跟踪平均帧率对比

算法	本文算法	CSR-DCF	ECO	ECO-HC	C-COT	Staple	KCF	DSST	CN	MEEM	LCT
R_f /(帧/秒)	13.94	12.97	7.96	61.23	0.55	66.47	142.62	32.62	87.79	6.17	23.11

3 结论

本文提出基于改进相关滤波器和目标多特征的无人机对地运动目标跟踪算法。提取和组合目标多通道特征,对目标进行更有效表征,基于高效卷积算子分解进行特征降维和紧凑的样本空间模型构建,提高样本多样性。空间可靠性图和滤波器模型进行较为稀疏的更新,提高目标跟踪精度。将本文算法与国内外 10 个先进算法在 15 个无人机航拍序列上进行目标跟踪实验对比。实验结果表明本文算法具有较优秀的跟踪效果,帧频最高可达 44.09 帧/秒,具有良好的实时性。

参考文献

[1] KRISTAN M, LEONARDIS A, MATAS J, et al. The visual object tracking VOT2016 challenge results[C]// European Conference on Computer Vision 2016 Workshops. Cham, Switzerland: Springer, 2016: 777-823.

[2] 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. Piscataway, NJ: IEEE Press, 2014: 1090-1097.

所示。可知,本文算法的成功率曲线的 A_{uc} 高于其他算法,具有更好的跟踪性能。

平均帧率更高。因为本文算法选取更容易表征物体轮廓信息的 CNN 浅层特征 Conv-3 或 Conv-5 中的一个特征层,而 ECO 和 C-COT 算法使用了浅层和高层两个卷积特征层,导致参数更多。当只提取 HOG 特征和 CN 特征时,本文算法平均帧率可达 44.09 帧/秒,具有良好的实时性。

[3] DANELLJAN M, HAGER G, KHAN F S, et al. Discriminative scale space tracking[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(8): 1561-1575.

[4] 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.

[5] MA C, YANG X, ZHANG C, et al. Long-term correlation tracking[C]// IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE Press, 2015: 5388-5396.

[6] DANELLJAN M, HAGER G, KHAN F S, et al. Adaptive decontamination of the training set: a unified formulation for discriminative visual tracking[C]// IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE Press, 2016: 1430-1438.

[7] DANELLJAN M, HAGER G, KHAN F S, et al. Learning spatially regularized correlation filters for visual tracking[J]. International Conference on Computer Vision, 2015(10): 4310-4318.

[8] MA C, HUANG J B, YANG X K, et al. Hierarchical convolutional features for visual tracking[C]// IEEE International Conference on Computer Vision. Piscataway, NJ: IEEE Press,

- 2015: 3074-3082.
- [9] DANELLJAN M, HAGER G, KHAN F S, et al. Convolutional features for correlation filter based visual tracking[C]// IEEE International Conference on Computer Vision Workshop. Piscataway, NJ: IEEE Press, 2015: 621-629.
- [10] DANELLJAN M, ROBINSON A, KHAN F S, et al. Beyond correlation filters: learning continuous convolution operators for visual tracking[C]// European Conference on Computer Vision. Piscataway, NJ: IEEE Press, 2016: 472-488.
- [11] ZHANG L, ZHANG D H, SU Y X, et al. Fast visual tracking via dense spatio-temporal context learning[C]// 11th IEEE International Conference on Control and Automation. Piscataway, NJ: IEEE Press, 2014: 127-141.
- [12] KRISTAN M, PERS J, VILDANA S, et al. A graphical model for rapid obstacle image-map estimation from unmanned surface vehicles[C]// Asian Conference on Computer Vision 2014. Cham, Switzerland: Springer, 2014: 391-406.
- [13] POSSEGGER H, MAUTHNER T, BISCHOF H. In defense of color-based model-free tracking[C]// IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE Press, 2015: 2113-2120.
- [14] BOYD S, PARIKH N, CHU E, et al. Distributed optimization and statistical learning via the alternating direction method of multipliers[J]. Foundations and Trends in Machine Learning, 2011, 3(1): 1-122.
- [15] BILI A, MUELLER M, GHANEM B. Target response adaptation for correlation filter tracking[C]// European Conference on Computer Vision. Piscataway, NJ: IEEE Press, 2016: 419-433.
- [16] LUKEZIC A, VOJIR T, CEHOVINZAJC L, et al. Discriminative correlation filter with channel and spatial reliability[C]// IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE Press, 2017: 4847-4856.
- [17] DANELLJAN M, BHAT G, KHAN F S, et al. ECO: efficient convolution operators for tracking[C]// IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE Press, 2017: 6638-6646.
- [18] BERTINETTO L, VALMADRE J, GOLODETZ S. Staple: complementary learners for real-time tracking[C]// IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE Press, 2016: 1401-1409.
- [19] ZHANG J M, MA S G, SCLAROFF S. MEEM: robust tracking via multiple experts using entropy minimization[C]// European Conference on Computer Vision 2014. Cham, Switzerland: Springer, 2015: 188-202.

(上接第 34 页)

- [7] SEBT M A, NOROUZI Y, SHEIKHI A, et al. OFDM radar signal design with optimized ambiguity function[C]// 2008 IEEE Radar Conference, Rome, Italy. Piscataway, NJ: IEEE Press, 2008: 448-452.
- [8] 刘永军, 廖桂生, 杨志伟. 基于 OFDM 的雷达通信一体化波形模糊函数分析[J]. 系统工程与电子技术, 2016, 38(9): 2008-2018.
- [9] 左家骏, 杨瑞娟, 程伟, 等. OFDM 雷达通信共享信号距离旁瓣抑制研究[J]. 信号处理, 2020, 36(10): 1662-1667.
- [10] 左家骏, 杨瑞娟, 李晓柏, 等. QAM-OFDM 雷达通信一体化信号雷达性能研究[J]. 现代雷达, 2020, 42(8): 1-5.
- [11] 王孟奇. 基于 OFDM 的雷达通信一体化信号设计[D]. 哈尔滨, 哈尔滨工业大学, 2016.
- [12] 刘田, 杨琳, 邓凯, 等. 高阶 QAM 调制下 OFDM 的载波与采样频偏联合纠正[J]. 电子学报, 2013, 41(3): 481-487.