

关联动态特征的目标自适应跟踪算法

孙志成¹,董一杰²,胡爱兰²,张瑞权²

(1.63861 部队,吉林 白城 137000;2.华北计算机系统工程研究所,北京 100083)

摘要:在复杂的靶场试验场景中,试验现场常常涉及扬尘、强光、遮挡等多变的自然环境。针对这种情况下快速运动的目标物体跟踪,提出了一种关联动态特征的单目标跟踪算法。首先使用门控循环单元(Gated Recurrent Unit,GRU)提取待跟踪目标的时序动态特征,获得候选处理目标框集合;然后利用卷积网络(Convolutional Neural Network,CNN)提取候选目标框的深度卷积特征并确定目标位置,同时分离出背景卷积特征;在跟踪过程中,使用分离出的背景卷积特征图对网络进行参数更新,增强网络的鲁棒性与自适应性。实验结果表明,所提出的算法可以对靶场图像采集系统中的被试移动目标进行自适应跟踪,并且在复杂环境背景下算法仍能保持优异的鲁棒性与适应性。

关键词:靶场试验;自适应跟踪;门控循环单元;卷积神经网络

中图分类号:TP18

文献标识码:A

DOI:10.16157/j.issn.0258-7998.212358

中文引用格式:孙志成,董一杰,胡爱兰,等.关联动态特征的目标自适应跟踪算法[J].电子技术应用,2022,48(11):57-62.

英文引用格式:Sun Zhicheng,Dong Yijie,Hu Ailan,et al. Adaptive tracking algorithm for target based on associated dynamic features[J]. Application of Electronic Technique,2022,48(11):57-62.

Adaptive tracking algorithm for target based on associated dynamic features

Sun Zhicheng¹,Dong Yijie²,Hu Ailan²,Zhang Ruiquan²

(1.63861 Troop, Baicheng 137000, China;

2.National Computer System Engineering Research Institute of China, Beijing 100083, China)

Abstract: In the complex scene of shooting range test, the test site often involves the changeable natural environment including dust, strong light, occlusion, etc. A single target tracking algorithm associated with dynamic features is proposed to track fast moving targets in this case. Firstly, the gated recurrent unit is used to extract the time series dynamic characteristics of the target which need to be tracked, so as to obtain a set of candidate processing target frames. Then, convolutional network is adopted to extract the depth convolution features of the candidate target frame and determine target position, as well as separating the background convolution features. In the tracking process, the separated background convolution feature map is applied to update network parameters to enhance the robustness and adaptability of network. Experimental results show that the proposed algorithm can adaptively track moving target in the shooting range image acquisition system, which can still maintain excellent robustness and adaptability in the context of complex environment.

Key words: range test; adaptive tracking; gated recurrent unit; convolutional neural network

0 引言

某型号系统在进行靶场试验时,需准确定位并跟踪被试设备,确保其能处于相应试验系统范围中,这对单目标跟踪提出了更高的要求。单目标跟踪逐渐成为计算机视觉所需研究和应用的重点之一^[1],为了满足某些复杂场景的使用需求,对视频中特定目标进行自适应处理逐渐成为重要的需求。随着近年来计算机技术的发展与算力的进步,单目标跟踪被广泛地应用于军事设施设备、安防监控、无人驾驶等领域^[2-4]。

国内外相关学者根据不同的工作原理对跟踪算法做了大量研究工作。Henriques^[5]等提出了核相关滤波算法,但该算法在遮挡等因素影响下会出现跟踪丢失的情

况;Zhou^[6]等提出了结合目标位置、形状、外观的多核相关滤波算法,对实际海洋雷达目标进行跟踪;卢杨^[7]等通过改进纹理特征并应用于红外目标跟踪,验证了其鲁棒性与实时性;仇祝令^[8]等考虑目标的空时域特性对正则化项进行约束求解,该方法在一定程度上提升了跟踪的实时性与精确度。

近年来,基于深度学习的方法在目标检测领域展现出了高效的性能,其逐渐也成为了目标跟踪领域研究的热点^[9]。结合深度特征的目标跟踪算法被相继提出,宋建锋^[10]等使用VGG16网络中第3组第3层提取的深度卷积特征进行跟踪,深度特征具有更高的跟踪准确率与有效性;周治国^[11]等提出了一种基于单发多盒探测器的

空间与时间信息相融合的跟踪算法,确保了跟踪速度与准确度。在过往的研究中,传统方法得到的候选处理目标框并未结合历史轨迹与时间动态信息,当目标基于上一帧位置出现较大尺度与剧烈位移变化时,往往会出现跟踪框漂移与丢失的情况;另一方面,深度卷积特征虽然在空间信息中表现出色,但由于本身结构复杂使得其对时序特征目标表征迟钝,当出现与前景相似的干扰物以及被背景严重遮挡时,其网络性能会明显下降。

针对上述研究以及问题的总结,本文提出了一种关联动态特征的移动目标自适应跟踪算法。首先使用门控循环单元提取待跟踪目标的时序特征,为避免背景特征影响目标运动状态,此过程仅利用时间信息获取候选处理目标框;然后使用卷积神经网络处理候选目标框中的图像信息,得到空间维度的深度特征图并获取目标位置信息,同时分离出当前帧的背景深度特征;最后在跟踪过程中使用分离出的背景深度特征对网络参数进行更新,提高网络对移动目标的自适应跟踪能力,以适应复杂的靶场环境要求。

1 门控循环单元

门控循环单元^[12](Gated Recurring Units, GRU)是长短记忆网络^[13]的一种变体。门控循环单元结构中包括输入向量 $x(t)$ 、先前输出向量 $h(t-1)$,每个门的输出可以通过逻辑运算和非线性变换获得,见式(1):

$$\begin{cases} r(t)=\sigma_g(\mathbf{W}_r \mathbf{x}(t)+\mathbf{U}_r \mathbf{h}(t-1)+b_r) \\ z(t)=\sigma_z(\mathbf{W}_z \mathbf{x}(t)+\mathbf{U}_z \mathbf{h}(t-1)+b_z) \\ \mathbf{h}(t)=(1-z(t)) \circ \mathbf{h}(t-1)+z(t) \circ \mathbf{h}'(t) \\ \mathbf{h}'(t)=\sigma_h(\mathbf{W}_h \mathbf{x}(t)+\mathbf{U}_h(r(t) \circ \mathbf{h}(t-1))+b_h) \end{cases} \quad (1)$$

式中, $z(t)$ 为更新门, $r(t)$ 为重置门, \mathbf{W} 为参数矩阵、 \mathbf{U} 为向量, σ_g 为 sigmoid 函数, σ_h 为 tanh 函数, \circ 为哈达玛积。本文采用门控循环单元提取待跟踪目标的时序动态特征。

2 关联动态特征的跟踪算法设计

考虑到门控循环单元对时序位置信息具有极强的敏感性,首先以当前图像前一帧的位置信息作为网络输入,对比前一帧与后一帧图像之间的前景目标位置变换提取前景目标的位置动态特征,得到候选处理目标框,为避免背景干扰信息对后续深度特征提取的影响,该阶段并未使用图像信息;然后使用卷积神经网络提取候选处理目标框的深度特征并确定目标位置,同时将背景卷积特征分离出来;最后在跟踪过程中,利用背景卷积特征更新网络参数。图1为本文算法网络框架。

2.1 基于时间顺序的动态特征提取

靶场被试设备的相关视频数据,实则是由图像采集系统将单帧副图像基于时间顺序组合的结果。本节利用门控循环单元对时间序列的敏感性并结合历史位置动态信息,得到当前时刻候选目标框。

时序特征提取网络部分共有3层GRU网络,经过

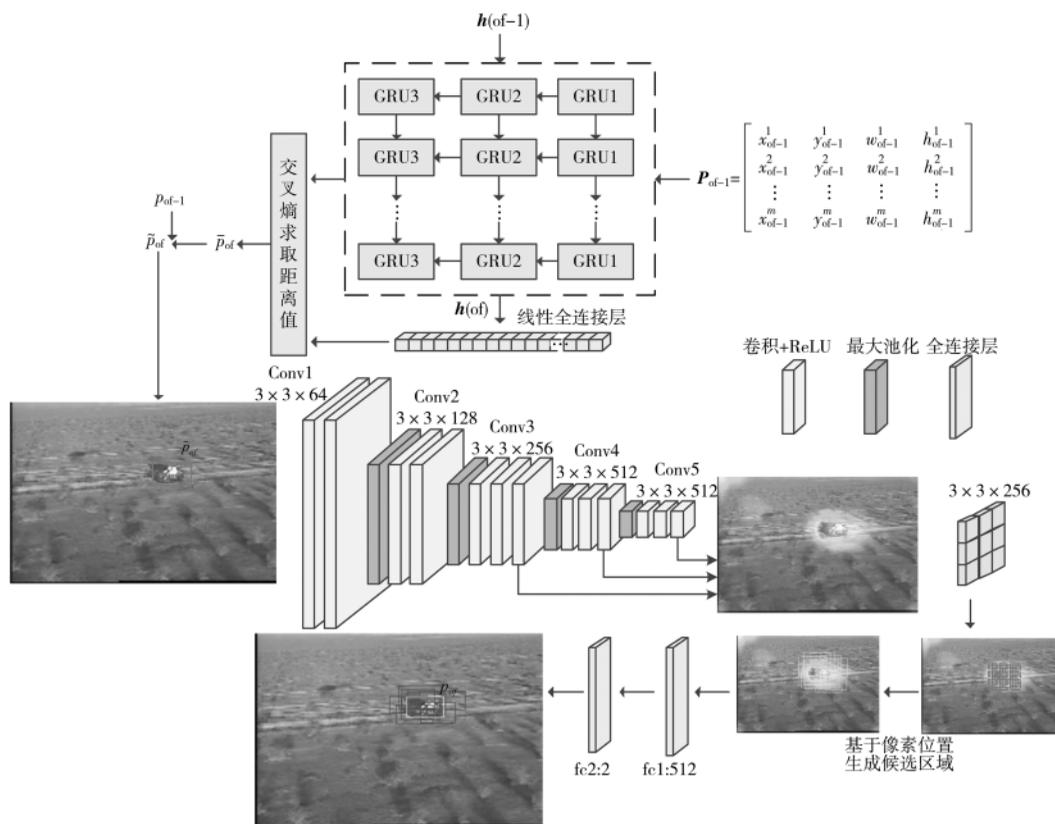


图1 本文算法网络框架

实验调参确定每层神经元数量:第一层包含 128 个神经元,第二层包含 64 个神经元,第三层包含 32 个神经元。末端加入线性全连接层,该部分最终需输出当前帧 of 隐含层状态 $h(of)$ 的特征值,所以不能使用会限制输出范围的非线性激活函数。

由于当前帧 of 的前一帧 of-1 的目标框位置信息 p_{of-1} 是确定的,该位置信息包含了目标框左上角坐标 x_{of-1} 、 y_{of-1} ,目标框宽度 w_{of-1} ,以及目标框高度 h_{of-1} 。结合目标物体运动的随机性,以该目标框为中心使用泊松分布构建 $m \times 4$ 维候选框矩阵 P_{of-1} ,见式(2),该矩阵作为门控循环单元的输入,得到隐含层状态 $h(of)$,见式(3):

$$P_{of-1} = \begin{bmatrix} 1 & 1 & 1 & 1 \\ x_{of-1} & y_{of-1} & w_{of-1} & h_{of-1} \\ 2 & 2 & 2 & 2 \\ x_{of-1} & y_{of-1} & w_{of-1} & h_{of-1} \\ \vdots & \vdots & \vdots & \vdots \\ m & m & m & m \\ x_{of-1} & y_{of-1} & w_{of-1} & h_{of-1} \end{bmatrix} \quad (2)$$

$$h(of) = g_{GRU}(h(of-1), P_{of-1}, W_{GRU}, b_{GRU}) \quad (3)$$

式中, $g_{GRU}(\cdot)$ 为式(1)的计算过程, $h(of-1)$ 为前一帧隐含层状态, W_{GRU} 为门控循环网络权重系数矩阵, b_{GRU} 为偏置项。经式(3)处理后可得到运动目标时序特征。GRU 网络末端线性全连接层的输出,即当前帧 of 隐含层状态 $h(of)$ 的特征值,见式(4):

$$chv = W_{FC}h(of) + b_{FC} \quad (4)$$

式中, chv 为特征值, W_{FC} 为全连接层权重系数矩阵, b_{FC} 为全连接层偏置项。

然后得到候选目标框矩阵 P_{of-1} 相对于前一帧目标框 p_{of-1} 的概率分布函数,见式(5):

$$P(p_{of-1}^1, p_{of-1}^2, \dots, p_{of-1}^m | p_{<of}) = chv \quad (5)$$

结合式(4)、式(5),使用 softmax 函数计算矩阵 P_{of-1} 中的每个矩阵框概率分布,见式(6):

$$P(p_{of-1}^{m'} | p_{<of}) = \frac{e^{chv_{m'}}}{\sum_{k=1}^m e^{chv_k}} \quad (6)$$

利用交叉熵函数求得提取到的目标框矩阵 P_{of-1} 与前一帧目标框 p_{of-1} 之间的距离值,见式(7):

$$D(P(p_{of-1}), P(p_{of-1}^m)) = - \sum_{i=1}^m P(p_{of-1}^i) \log P(p_{of-1}^i) \quad (7)$$

按升序的方式选取距离值最小的前 5 个目标框,并取其位置信息的平均值得到目标框 \bar{p}_{of} 。融合目标框 \bar{p}_{of} 与前一帧目标框 p_{of-1} 位置信息得到当前帧待处理目标框 \bar{p}_{of} 。目标框位置信息 \bar{p}_{of} 将作为卷积特征网络的输入,用于准确提取待跟踪目标的卷积特征,并与背景卷积特征区分开来。

2.2 候选目标特征提取

本文算法框架中候选目标特征提取部分主要由卷积神经网络部分与候选区域提取部分组成。目标框 \bar{p}_{of} 图

像作为卷积网络输入,经由卷积层、最大池化层提取当前帧图像的目标框卷积特征与背景卷积特征。

2.2.1 特征图像提取

卷积神经网络由卷积层以及最大池化层组成,如图 1 所示。其具体步骤如下:输入图像经卷积层运算,使用 ReLU^[14] 作为激活函数。经过卷积层得到特征矩阵,进入池化层进一步提取最有用信息,本文采用最大特征值池化的方法,对特征矩阵进行降维运算。本文采用 Conv3-3、Conv4-3、Conv5-3 层的输出进行多层卷积特征融合^[15],最终得到融合后的卷积特征图,其使得网络模型在尺度变化等因素的影响下仍能保持优异的鲁棒性。

2.2.2 候选区域提取

以当前帧待处理目标框 \bar{p}_{of} 所对应的特征图,基于其单位像素位置生成 n 个候选区域。结合上述卷积网络中卷积层 Conv5-3 最后生成的候选区域感受野为 164 像素 \times 164 像素,使用大小为 164 像素和宽高比 1.49 作为候选区域生成的参数。待处理目标框 \bar{p}_{of} 与其生成的候选区域之间区域重叠面积为 IOU (Intersection Over Union) 值,采用 IOU 值判定的方式将候选区域分为目标和背景,当 IOU > 0.7 时为正样本及目标区域,IOU < 0.3 时为负样本及背景区域。

将候选框区域特征输入全连接层进行映射转换,其中 fc2 层采用 softmax 函数,最终得到 n 个候选区域 $R = [r_1, r_2, \dots, r_i, \dots, r_n]$ 的目标分数 $f^+(r_i)$ 和背景分数 $f^-(r_i)$,对应目标分数最大的第 r_i 个候选框,即为当前帧 of 的待跟踪目标所在位置 p_{of} 。

2.3 模型训练

综上所述,模型训练阶段也将分为两步,均采用离线的方式进行训练。

(1) 对门控循环单元网络的离线训练

门控循环单元网络的损失函数定义见式(8):

$$\text{loss}_{GRU} = - \frac{1}{S} \sum_{j=1}^{OF} \ln P(p_{of}^j = p_{of} | p_{<of}) \quad (8)$$

式中, $P(p_{of}^j = p_{of} | p_{<of})$ 为第 of 帧模型所预测的目标框为真实框的概率, S 为投入训练的数据集规模, OF 为按时间序列逐步长展开的总帧数。

采用 Adam^[16] 算法进行反向梯度优化得到损失函数的最优值。在 GRU 部分使用 dropout^[17],指定层输入单元 dropout 比率为 0.1,指定循环单元 dropout 比率为 0.5。

(2) 对卷积神经网络的离线训练

为解决跟踪目标框出现漂移的情况,在对卷积神经网络训练阶段,使用两种类别损失项与较小区域重叠面积阈值结合的损失函数来保证跟踪目标框的准确性,见式(9):

$$\text{loss}_{cnn} = \lambda \sum_i \text{loss}_{cls}(x_i, x_i^*) + \mu \sum_i \text{loss}_{cls}(y_i, y_i^*) \quad (9)$$

式中, $\text{loss}_{cls}(\cdot)$ 为二值交叉熵损失函数, λ 和 μ 为两项间

的平衡权重, x_i 和 y_i 为两个不同候选目标框经全连接层映射变化得到的目标类别置信度分数, x_i^* 为 IOU 阈值 0.7 时所得到的类别值, y_i^* 为直接使用特征图中的映射区域作为类别值。

2.4 网络模型更新

为了使得网络模型在复杂环境下仍能保持优异的鲁棒性与适应性, 采用背景更新与长期更新相结合的方法对全连接层进行更新。采用背景更新^[18]对网络参数调整的方式, 可以在短时间内提升网络模型对待跟踪目标尺度变化以目标姿态大幅调整的适应能力。同时结合长期更新的方法, 可以使得网络模型在背景噪声、光线变换等环境因素下保持较好的鲁棒性。选取最近跟踪成功的 50 帧图像, 其经过特征图像提取和候选区域提取所生成的待跟踪目标框即 IOU>0.7 时的正样本, 并结合上述背景更新时所采用的背景负样本对全连接层参数进行更新。

3 结果与分析

3.1 数据集划分

采用跟踪数据集 TrackingNet^[19]对网络模型进行训练, 选取该数据集的 800 段视频序列, 将其按照 3:1 的比例划分为训练集与验证集。然后为了测试网络模型的泛化能力, 采用 Visual Tracker Benchmark 数据集中的 8 段与本文跟踪对象及场景相似的视频序列 (Car1:1020 帧、Car2:913 帧、Car4:659 帧、Car24:3059 帧、BlurCar1:742 帧、BlurCar2:585 帧、RedTeam:1918 帧、MotorRolling:164 帧) 作为测试集, 对训练好的模型进行测试。为了再次验证本文所提算法的有效性, 最后通过图像采集系统所采集到的真实靶场视频数据对网络模型进行应用验证。

3.2 评价指标与结果分析

本文选取平均中心像素误差 (Average Pixel Error, ARE) 与平均重叠率 (Average Overlap Rate, AOR) 作为评判标准。ARE 是根据预测目标框中心位置和真实目标框中心位置的像素距离作为误差, 该误差值越小说明算法的跟踪精准度越高。AOR 是以预测目标框与真实目标框之间的重叠面积来对成功跟踪进行评判, 对整个视频片段来说, 单帧跟踪成功数越多, 算法对视频片段跟踪成功率越高。

将本文算法与几种具有代表性的跟踪算法 (KCF^[15]、HCF^[20]、CFNet^[21]、MDNet^[22]) 进行对比试验。图 2 展示了上述 5 种算法在 BlurCar1 视频序列中第 20 帧、第 50 帧、第 150 帧的跟踪结果。从跟踪结果上可以直观地看到: KCF、HCF 算法在面对画面模糊的情况下, 从跟踪一开始就出现了跟踪框漂移的现象; 在第 50 帧较为清晰的目标中, 漂移现象得到了轻微的改善; 但在第 150 帧跟踪目标变得更为模糊的情况下, KCF 与 HCF 算法彻底丢失跟踪目标。CFNet、MDNet 算法在第 20 帧并未出现明显的跟踪框漂移现象, 随着视频序列的递进, 两种算

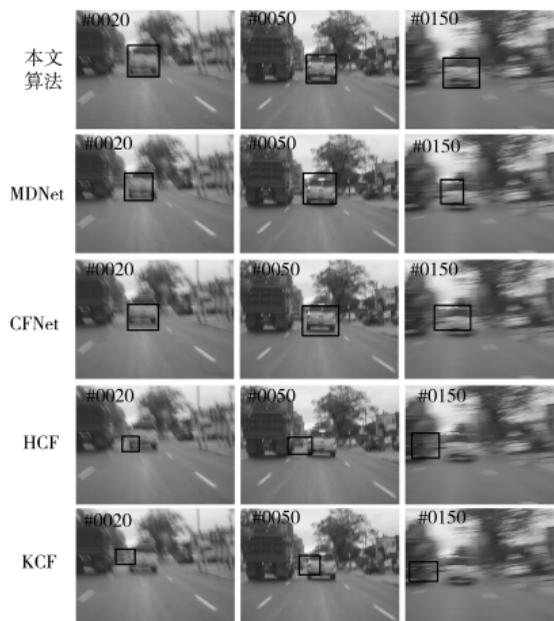


图 2 算法在 BlurCar1 视频中的跟踪结果

法的跟踪匹配度较高; 但在第 150 帧画质模糊的情况下, 可以看到 MDNet 跟踪框出现了尺度收缩的情况, 即跟踪框仅能匹配到待跟踪目标的部分区域, CFNet 跟踪框出现了较为明显漂移。本文算法在结合深度特征与深度卷积网络的基础上引入了位置动态特征, 从跟踪结果中可以看到该算法克服了画面模糊、光照弱、背景光源干扰等跟踪难点, 在视频序列中对目标始终能够保持稳定的跟踪。

图 3 展示了 6 种算法在 RedTeam 视频序列中第 20 帧、第 200 帧、第 500 帧、第 800 帧、第 900 帧、第 1530 帧的跟踪结果。该 6 帧图像能够较为全面地反映整个序列中的待跟踪目标与背景的变化特征: 待跟踪目标随着时序变化, 其尺度由小变大, 在移动过程中第 800 帧出现了对比较为强烈的白色干扰物体; 在第 900 帧时干扰背景基本与待跟踪目标位置处于同一位置。KCF 与 HCF 相比在第 900 帧丢失了跟踪目标, 目标框对白色背景进行了误跟踪, 但在第 1530 帧两种算法同时对目标成功跟踪, 但目标框出现了不同程度的漂移。CFNet 与 MDNet 算法跟踪框漂移现象得到了改善, 但跟踪框尺度不能完全匹配目标物体的现象依旧存在, 在第 800 帧和第 900 帧跟踪框尺度不能完全覆盖目标区域并且存在着向上移动的趋势。本文算法始终保持目标框的自适应尺度匹配以及良好的跟踪状态, 体现出了本文算法的自适应跟踪能力并进一步表征了其在复杂环境和各种干扰因素下仍能保持优异的鲁棒性与适应性的能力。

为了量化上述算法跟踪性能及其在测试数据集中的整体表现, 采用平均中心像素误差与平均重叠率作为对每种方法的评价标准, 如表 1 和表 2 所示。从表中结果可以直观地看到, 本文所提出的算法相比于其他算法

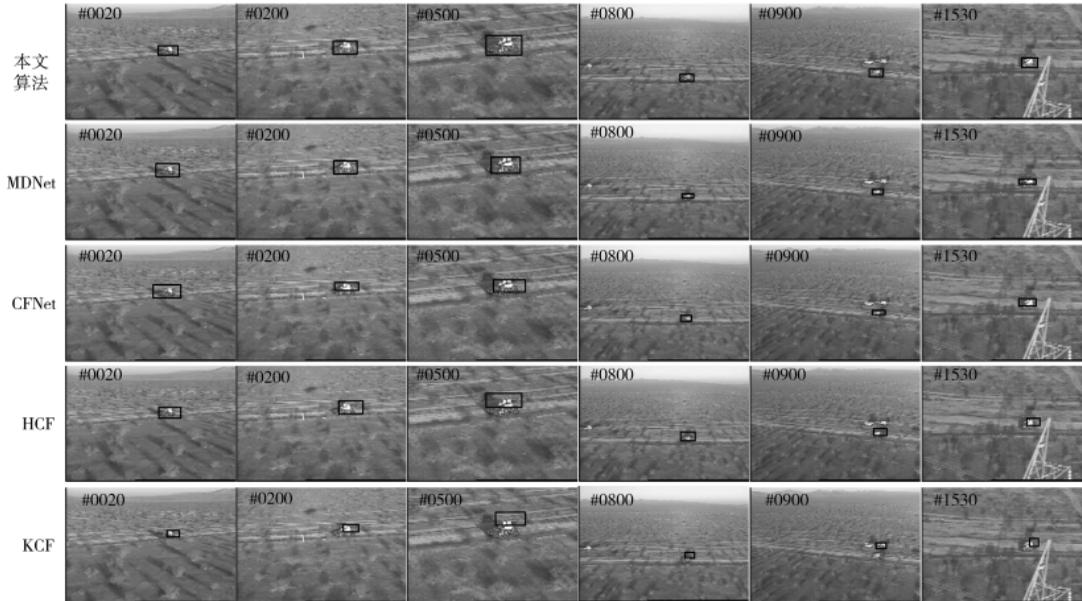


图3 算法在 RedTeam 视频中的跟踪结果

表1 测试集中的平均中心像素误差

视频序列	KCF	HCF	CFNet	MDNet	本文算法
Car1	36.720	24.187	16.655	10.536	6.014
Car2	28.090	17.644	21.211	11.082	10.380
Car4	25.521	12.013	11.076	8.374	5.294
Car24	23.220	20.478	13.358	9.227	4.348
BlurCar1	212.432	188.776	53.252	31.119	10.068
BlurCar2	36.016	18.019	23.533	11.110	8.175
RedTeam	42.273	28.319	20.072	14.812	7.019
MotorRolling	232.019	137.404	58.022	41.093	9.144

表2 测试集中的平均重叠率

视频序列	KCF	HCF	CFNet	MDNet	本文算法
Car1	0.413	0.522	0.612	0.624	0.690
Car2	0.487	0.591	0.524	0.604	0.625
Car4	0.512	0.635	0.651	0.677	0.718
Car24	0.541	0.562	0.604	0.633	0.734
BlurCar1	0.093	0.114	0.341	0.433	0.604
BlurCar2	0.410	0.596	0.571	0.634	0.641
RedTeam	0.382	0.518	0.593	0.625	0.654
MotorRolling	0.089	0.131	0.388	0.470	0.631

展现出了较高的跟踪精准度与目标重叠率,直观且量化地证明了提取位置动态特征来获得候选处理目标框这一方法的有效性与正确性,同时进一步证明了结合深度卷积网络提取候选处理目标框深度特征的结构应用在目标跟踪任务中的鲁棒性与稳健性。

经过测试集对算法进行验证后,使用图像采集系统所采集到的靶场视频数据对算法的实际性能验证。该视频数据中包含了试验现场某型号设备以及扬尘、扬沙、强光等多变的环境背景,其对本文算法未来实际应用于

试验现场自适应目标跟踪任务提供了可行性的依据。

表3为综合表现的统计结果,可以看到本文关联时序特征的跟踪算法具有最优的误差值与重叠率,其成功跟踪率比MDNet方法提升了16.2%,平均中心像素误差降低了54.1%,平均重叠率提升了12.2%,进一步验证了算法的实际性能。通过对比平均跟踪帧率可以发现,本文算法相对于基于相关滤波算法的跟踪速度还有较大的提升空间,其耗时主要集中在提取位置动态特征来获得候选处理目标框以及模型更新的过程。

表3 综合表现统计结果

算法	平均中心像素误差	平均重叠率	成功跟踪率	跟踪速度/(f/s)
KCF	43.172	0.372	0.411	149.512
HCF	33.090	0.421	0.526	11.040
CFNet	21.071	0.561	0.650	42.540
MDNet	17.892	0.600	0.671	1.240
本文算法	8.223	0.673	0.780	2.204

4 结论

为了应对试验现场复杂的环境背景,本文提出了一种基于时序动态特征提取候选处理目标框再结合深度卷积网络提取候选框深度特征来进行跟踪任务的算法。为避免背景信息对后续深度特征提取的影响,该算法首先利用非图像信息提取当前帧前景目标的位置信息即候选目标框;然后利用卷积神经网络进行多层深度特征融合,得到融合后的卷积特征图并最终确定目标位置。跟踪过程中采用背景更新与长期更新相结合的方法对网络参数进行更新,使得网络模型在复杂背景环境下仍能保持优异的鲁棒性与适应性。在测试集中的结果表

明,本文算法有着良好的泛化能力,且展示出了稳定且高成功率的跟踪效果;在真实试验数据中的结果表明,扬沙、强光、地域广阔等现场环境下算法仍能保持较好的鲁棒性与自适应跟踪能力。在面对未来试验现场应用前,需对特征提取复杂度以及网络模型进一步优化,提升实时跟踪速率。

参考文献

- [1] LI B. An improved Bernoulli particle filter for single target tracking[J]. *Multidimensional Systems & Signal Processing*, 2017, 29(3): 799-819.
- [2] TENG Z, XING J, WANG Q, et al. Deep spatial and temporal network for robust visual object tracking[J]. *IEEE Transactions on Image Processing*, 2019, 29: 1762-1775.
- [3] 李大维, 莫波, 高可, 等. 针对弹载平台红外小目标的检测与跟踪算法[J]. *宇航学报*, 2020, 41(11): 1440-1448.
- [4] MBELWA J T, ZHAO Q, WANG F. Visual tracking tracker via object proposals and co-trained kernelized correlation filters[J]. *The Visual Computer*, 2020, 36(6): 1173-1187.
- [5] HENRIQUES J F, CASEIRO R, MARTINS P, et al. High-speed tracking with kernelized correlation filters[J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2015, 37(3): 583-596.
- [6] ZHOU Y, WANG T, HU R, et al. Multiple kernelized correlation filters(MKCF) for extended object tracking using X-band marine radar data[J]. *IEEE Transactions on Signal Processing*, 2019, 67(14): 3676-3688.
- [7] 卢杨, 张磊, 郭立媛, 等. 基于改进纹理特征的红外目标跟踪算法[J]. *液晶与显示*, 2018, 33(12): 1040-1046.
- [8] 仇祝令, 查宇飞, 吴敏, 等. 基于注意力学习的正则化相关滤波跟踪算法[J]. *电子学报*, 2020, 48(9): 1762-1768.
- [9] 徐涛, 马克, 刘才华. 基于深度学习的行人多目标跟踪方法[J]. *吉林大学学报(工学版)*, 2021, 51(1): 27-38.
- [10] 宋建锋, 苗启广, 申猛, 等. 多特征融合的相关滤波红外单目标跟踪算法[J]. *西安电子科技大学学报*, 2019, 46(5): 142-147.
- [11] 周治国, 荆朝, 王秋伶, 等. 基于时空信息融合的无人艇水面目标检测跟踪[J]. *电子与信息学报*, 2021, 43(6): 1698-1705.
- [12] UGURLU U, OKSUZ I, TAS O. Electricity price forecasting using recurrent neural networks[J]. *Energies*, 2018, 11(5): 1255-1267.
- [13] GAO C, YAN J K, ZHOU S H, et al. Long short-term memory-based deep recurrent neural networks for target tracking[J]. *Information Sciences*, 2019, 502: 279-296.
- [14] WANG G, GIANNAKIS G B, CHEN J. Learning ReLU networks on linearly separable data: algorithm, optimality, and generalization[J]. *IEEE Transactions on Signal Processing*, 2019, 67(9): 2357-2370.
- [15] QIU X, LI M, DONG L, et al. Dual-Band maritime imagery ship classification based on multilayer convolutional feature fusion[J]. *Journal of Sensors*, 2020, 2020: 8891018.
- [16] 杨观赐, 杨静, 李少波, 等. 基于 Dropout 与 ADAM 优化器的改进 CNN 算法[J]. *华中科技大学学报(自然科学版)*, 2018, 46(7): 122-127.
- [17] SRIVASTAVA N, HINTON G, KRIZHEVSKY A, et al. Dropout: a simple way to prevent neural networks from overfitting[J]. *Journal of Machine Learning Research*, 2014, 15(1): 1929-1958.
- [18] 王兵兵, 王莹, 陈治昌, 等. 基于竞争融合区域建议网络的在线行人跟踪算法研究[J]. *农业机械学报*, 2019, 50(B07): 331-338.
- [19] MULLER M, BIBI A, GIANCOLA S, et al. Tracking net: a large-scale dataset and benchmark for object tracking in the wild[C]//*Proceedings of European Conference on Computer Vision*, 2018: 310-327.
- [20] BIBI A, MUELLER M, HANEM B. Target response adaptation for correlation filter tracking[C]//*Proceedings of the 2016 IEEE European Conference on Computer Vision Workshop*, 2016: 419-433.
- [21] VALMADER J, BERTINETTO L, HENRIQUES J, et al. End-to-End representation learning for correlation filter based tracking[C]//*Proceedings of Computer Vision and Pattern Recognition*, 2017: 5000-5008.
- [22] NAM H, HAN B. Learning multi-domain convolutional neural networks for visual tracking[C]//*Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition*, 2016: 4293-4302.

(收稿日期: 2021-11-19)

作者简介:

孙志成(1983-),男,本科,工程师,主要研究方向:电子系统与兵器测试。

董一杰(1992-),男,硕士,工程师,主要研究方向:电子系统、图像处理。

胡爱兰(1973-),女,硕士,研究员级高级工程师,主要研究方向:通信与电子系统。



扫码下载电子文档

版权声明

经作者授权，本论文版权和信息网络传播权归属于《电子技术应用》杂志，凡未经本刊书面同意任何机构、组织和个人不得擅自复印、汇编、翻译和进行信息网络传播。未经本刊书面同意，禁止一切互联网论文资源平台非法上传、收录本论文。

截至目前，本论文已经授权被中国期刊全文数据库（CNKI）、万方数据知识服务平台、中文科技期刊数据库（维普网）、DOAJ、美国《乌利希期刊指南》、JST 日本科技技术振兴机构数据库等数据库全文收录。

对于违反上述禁止行为并违法使用本论文的机构、组织和个人，本刊将采取一切必要法律行动来维护正当权益。

特此声明！

《电子技术应用》编辑部

中国电子信息产业集团有限公司第六研究所