

基于多域卷积神经网络与自回归模型的空中小目标 自适应跟踪方法

蔺素珍¹, 郑 瑶¹, 禄晓飞², 曾建潮¹

¹中北大学计算机与控制工程学院, 山西 太原 030051;

²酒泉卫星发射中心, 甘肃 酒泉 735000

摘要 针对星空背景下卫星跟踪中运动小目标与伪目标交会造成的跟踪漂移问题,提出一种基于多域卷积神经网络(MDNet)与自回归(AR)模型的空中小目标自适应跟踪方法。对用 MDNet 采集到的图像序列第 1 帧的正样本进行 bounding-box 回归模型训练;再训练用最小信息准则和最小二乘法确定阶数和参数的 AR 模型,估计目标运动轨迹并预测目标位置;最后,将该目标位置作为 MDNet 的采样中心,约束采样候选区域,用 bounding-box 回归模型调整目标位置。实验用 8 种跟踪方法测试了 8 组场景复杂的视频序列,结果表明,本文方法的成功率及平均覆盖率均显著高于其他 7 种典型算法,具有较高的精确性和稳健性。

关键词 机器视觉;小目标跟踪;多域卷积神经网络;自回归模型

中图分类号 TP391 **文献标识码** A

doi: 10.3788/AOS201737.1215006

Adaptive Tracking Algorithm for Aerial Small Targets Based on Multi-Domain Convolutional Neural Networks and Autoregression Model

Lin Suzhen¹, Zheng Yao¹, Lu Xiaofei², Zeng Jianchao¹

¹School of Computer and Control Engineering, North University of China, Taiyuan, Shanxi 030051, China;

²Jiuquan Satellite Launch Center, Jiuquan, Gansu 735000, China

Abstract The adaptive tracking algorithm for the aerial small target is proposed based on the multi-domain convolutional neural networks (MDNet) and the autoregression (AR) model, to solve the tracking drift problem that the pseudo targets and the small target converge in the sky background. Firstly, the positive samples of the first frame in the image sequence are collected by MDNet to train the bounding-box regression model. Secondly, the AR model with its order and parameters determined by the Akaike information criterion and least squares method is trained to estimate the target track and to predict the target position. Finally, the region of sampling candidate is constrained since MDNet collects samples centered on the predicted target location, and then the target position is adjusted by the bounding-box regression model. Eight groups of benchmark video sequences are tested with the proposed algorithm and another seven classical tracking algorithms, and obtained results are compared. The experimental results show that the success rate and the average overlap rate of the proposed adaptive tracking algorithm are higher than those of other algorithms, and the proposed algorithm has higher accuracy and robustness.

Key words machine vision; small target tracking; multi-domain convolutional neural network; autoregression model

OCIS codes 150.0155; 100.4999; 150.1488

1 引 言

空中目标跟踪是航空航天领域各类探测系统的关键技术之一,由于观测距离较远,该类目标在地面观测和跟踪过程中,往往因缺少形状和纹理特征而呈现为小目标甚至点目标状态,造成检测和跟踪困难。特别是夜晚星空背景下,卫星等小目标与恒星较难区分,当其他卫星和行星等伪目标与其交会时,跟踪就更加困难。

收稿日期: 2017-05-27; **收到修改稿日期:** 2017-07-26

基金项目: 山西省应用基础研究项目(201701D121062)

作者简介: 蔺素珍(1966—),女,博士,教授,主要从事机器视觉与图像处理方面的研究。E-mail: lsz@nuc.edu.cn

因此,精确跟踪空中小目标具有挑战性。

根据目标特征及跟踪策略的不同,小目标跟踪算法大致可分为基于特征的跟踪方法^[1-2]、基于模板匹配的跟踪方法^[3]和基于统计的跟踪方法^[4]三大类。基于特征的跟踪方法综合考虑了背景和目标的特征,极大地提高了跟踪算法的稳健性,成为当前的研究热点。该方法主要采用光流法^[5]、相邻帧差法^[6]和背景减法^[7]进行目标跟踪,这些方法各有特点,但共同之处都是针对特定目标由人工设计特征,所以算法泛化能力不强。为此,有研究探索了基于深度学习的小目标跟踪方法^[8-9],代表性的有基于深度卷积神经网络以数据驱动方式自动学习特征的方法^[2]和利用双层卷积神经网络增强特征表示的方法^[10],二者均能有效区分目标与背景信息,在降低跟踪误差的同时极大提高算法的稳健性。在此基础上,Nam 等^[11]基于多域卷积神经网络(MDNet)跟踪方法较好地解决了伪目标干扰问题,但该方法用于星空背景下的小目标跟踪,特别是存在伪目标与目标交会时,往往会产生跟踪漂移。

为此,本文提出基于 MDNet 与自回归(AR)模型的空中小目标自适应跟踪方法。利用 MDNet 自适应提取空中小目标的特征后,训练模型^[12]以估计目标运动轨迹并预测目标位置,再经约束 MDNet 采样候选区域有效区分目标与伪目标,解决星空背景下卫星跟踪过程中伪目标对运动小目标的干扰问题。

2 跟踪方法

2.1 方法框架

方法框架如图 1 所示。

1) 训练 bounding-box 回归模型:MDNet 以标定的第 1 帧目标位置为中心采样,将正样本的特征作为特征训练集训练 bounding-box 回归模型。

2) AR 模型训练与预测:输入当前帧前 T 帧目标位置训练 AR 模型,估计目标的运动轨迹;将当前帧前 p 帧的目标位置输入训练好的 AR 模型,预测目标位置。

3) 网络测试:输入测试数据,MDNet 以预测的目标位置为中心采样生成候选样本,计算样本置信度并将置信度最高的样本输入 bounding-box 回归模型,调整目标位置完成跟踪。

4) 完善与修改:整个网络完成跟踪后,根据评价指标分析各因素对跟踪效果的影响,进一步对 AR 模型进行优化和完善。

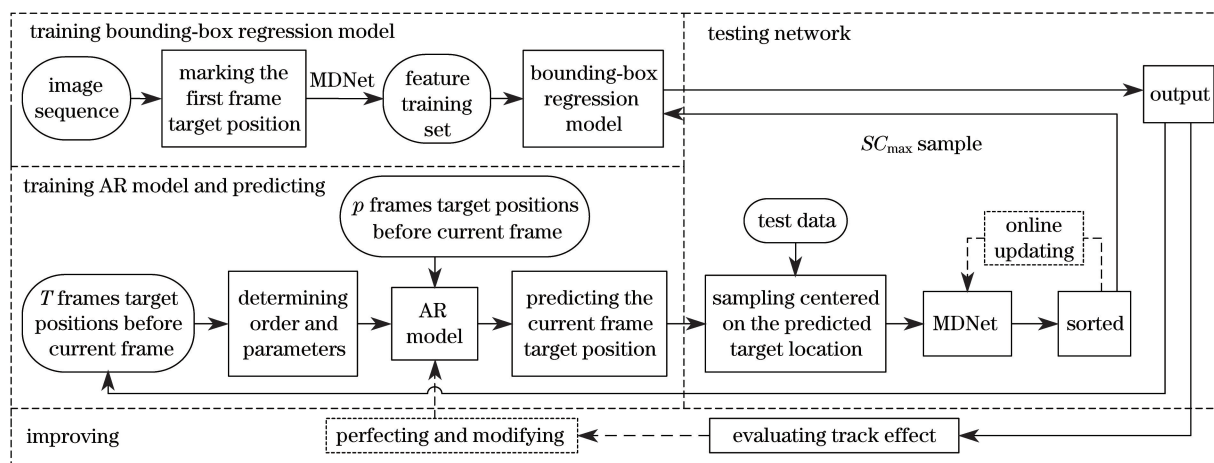


图 1 方法框架图

Fig. 1 Framework of the method

2.2 MDNet 跟踪器

MDNet 跟踪器采用难例挖掘和 bounding-box 回归模型训练样本,通过训练特定域层(fc6)获得目标通用的特征表达,用于各类场景的目标跟踪。MDNet 网络结构如图 2 所示,输入图像大小为 107 pixel × 107 pixel, conv1~conv3 为卷积层,采用视觉几何组-中速卷积神经网络(VGG-M)结构自适应提取特征,fc4~fc6 为全

连接层,将特征图表示转换为一维向量,fc6 有 K 个分支,每个分支包含一个二分类层:网络输出图像目标与背景的置信度。具体训练过程见文献[11]。




图 2 MDNet 结构图
Fig. 2 Structure of MDNet

2.3 在线跟踪

2.3.1 AR 模型

AR 模型常用于动态数据处理中的模型预测^[13],表达式为

$$x_t = \varphi_1 x_{t-1} + \varphi_2 x_{t-2} + \dots + \varphi_p x_{t-p} + \varepsilon_t, \quad (1)$$

式中 $\{x_t | t=1, 2, \dots, T\}$ 是一个时间序列的子样观测值, T 为时间序列的长度, $x_{t-1}, x_{t-2}, \dots, x_{t-p}$ 为自身某时刻 t 的前 p 个时刻的子样观测值, ε_t 为预测误差, $\varphi_1, \varphi_2, \dots, \varphi_p$ 为模型的参数, p 为模型的阶数。

用 AR 模型预测目标位置的关键是确定模型参数和阶数。常用的参数估计法包括矩估计、最大似然估计、最小二乘法估计等。最小二乘法估计比矩估计精度高,比最大似然估计计算简单^[14],因此本文采用最小二乘法估计参数并用其最小信息准则(AIC 准则)确定阶数。

(1)式的最小二乘解为

$$\boldsymbol{\beta} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y}, \quad (2)$$

式中 $\boldsymbol{\beta}$ 为参数矩阵, \mathbf{X} 为 T 时刻前的观测值矩阵, \mathbf{Y} 为 $T+1$ 时刻预测值的矩阵。

因此 AR(p)模型的残差方差的无偏估计公式为

$$\hat{\sigma}_t^2 = \frac{\sum_{t=p+1}^T \hat{\varepsilon}_t^2}{T - 2p}. \quad (3)$$

最小信息准则的形式为

$$f_{\text{AIC}}(p) = \ln \hat{\sigma}_p^2 + \frac{2p}{T}. \quad (4)$$

设模型阶的上界为 p_{\max} , $m = \{1, 2, \dots, p_{\max}\}$, $\hat{\sigma}_p^2$ 是用最小二乘法对 AR(p)模型拟合的残差方差估计。在不同阶数下,若 $p=m$ 时 $f_{\text{AIC}}(p)$ 取最小值,则确定 m 为模型的阶数。

2.3.2 在线跟踪过程

1) 训练 bounding-box 回归模型

标定第一帧目标位置 $X_n^1 = (x_1, y_1, s_w, s_h)$, MDNet 以 X_n^1 为中心采样生成回归样本,设重叠率的阈值 $r=0.6$,将大于 r 的样本作为 S_1^+ 输入网络经 conv1~conv3 的特征图表示,fc4~fc6 将特征图表示转换为一维向量训练 bounding-box 回归模型;提取第一帧图像 S_1^+, S_1^- 经 conv3 的特征图表示,选择难例样本 M_1^- 和 S_1^+ 输入至网络微调 fc4~fc6。

2) AR 模型训练与预测

①训练 AR 模型:根据(4)式可得 $p=4$ 时 $f_{\text{AIC}}(p)$ 最小,确定模型为 AR(4)模型。经实验得 $T=16$,输入训练数据 \mathbf{X} ,根据(2)式计算出模型不同的参数矩阵 $\boldsymbol{\beta}$,再由(3)式选出最佳参数,训练 AR 模型,估计目标的运动轨迹。

②预测目标位置:从第 $n(n \geq 17)$ 帧开始预测,将参数和第 n 帧中前 4 帧目标的位置代入(1)式,分别对

x, y 坐标进行预测,得到第 n 帧目标位置的预测值为 (x'_n, y'_n) 。

3) 网络测试与完善

MDNet 以 (x'_n, y'_n) 为中心采样约束采样候选区域,用多维高斯分布采样 M ($M=256$) 个候选样本 $X_n^i = (x_i, y_i, s_i), i=1, 2, \dots, M$, 输入网络得 X_n^i 目标和背景的置信度,将 SC_{\max} 样本输入 bounding-box 回归模型进行调整,最终确定目标位置,完成跟踪。最后,根据定性和定量分析结果,进一步优化和完善 AR 模型。

3 实验结果与分析

对涵盖了噪声、单个伪目标、多个伪目标、快速运动、遮挡等复杂情况的 8 组视频图像序列进行测试,如表 1 所示。实验对比算法为基于学习机制的深度学习跟踪(DLT)算法^[8]、AR 模型辅助深度学习(DLTAR)算法、实时性较强的尺度自适应的多特征跟踪(SAMF)算法^[15]、判别性尺度空间跟踪(DSST)算法^[16]、可对特征进行辨别分类的核化相关滤波器跟踪(KCF)算法^[17]、卷积网络跟踪(CNT)算法^[10]和 MDNet 算法。

表 1 实验中的测试图像序列
Table 1 Experimental test image sequences

Image sequence	True target	Track/Speed	Main challenge
seq1	1	Straight line/Faster	Single pseudo target, moving fast
seq2	2	Curve/Fast	Single pseudo target, background interference
seq3	3	Straight line/Fast	Multiple pseudo targets rendezvous, background interference
seq4	4	Curve/Fast	Multiple pseudo targets rendezvous, background interference
seq5	5	Curve/Faster	Multiple pseudo targets rendezvous, background interference, moving fast
seq6	6	Straight line/Fast	Multiple pseudo targets rendezvous, similar noise
seq7	7	Straight line/Slow	Multiple pseudo targets rendezvous, similar noise
seq8	8	Curve/Fast	Multiple pseudo targets rendezvous, background interference

3.1 定性分析

对以星空为背景、同时存在目标和伪目标的 seq1~seq8 为对象进行定性分析,图 3 所示为部分跟踪结果。

1) 伪目标和噪声干扰

① 单个伪目标干扰

图 3(a)、(b)为单个伪目标及噪声对目标的干扰。SAMF、CNT、MDNet 算法在目标与伪目标交会时误检跟错目标;DLT、DLTAR 算法有时可完成跟踪,但在二者交会期间发生漂移,跟踪不稳定;本文方法稳定完成目标跟踪。

② 多个伪目标多次干扰

图 3(c)~(h)为多个伪目标,且全程多次与目标交会的情况。图 3(c)~(e)及图 3(h)中对比算法均在目标与多个伪目标第 1 次交会时发生跟踪漂移;图 3(d)和图 3(e)中第 146 帧、图 3(h)中第 130 帧为目标与多个伪目标第 2 次交会,对比算法已丢失目标,本文方法仍能稳定跟踪;图 3(e)、(f)中干扰物较多,DLTAR 算法发生严重漂移,DLT、SAMF 算法出现轻微漂移,CNT、MDNet 算法误检目标;图 3(f)、(g)中噪声与目标大小相似,DLT、SAMF 算法受噪声干扰发生轻微漂移,本文方法在抑制噪声的同时自适应更新跟踪模型,实现了全程稳定跟踪目标。

2) 目标快速移动

图 3(a)、(e)中目标移动速度快,SAMF 算法分别在第 43 帧和第 60 帧发生跟踪漂移,DLT、DLTAR 算法跟踪效率下降,本文方法精确跟踪目标。




图 3 跟踪算法性能的定性比较。(a) seq1; (b) seq2; (c) seq3; (d) seq4; (e) seq5; (f) seq6; (g) seq7; (h) seq8

Fig. 3 Qualitative comparison of tracking algorithm performance. (a) seq1; (b) seq2; (c) seq3; (d) seq4; (e) seq5; (f) seq6; (g) seq7; (h) seq8

3.2 定量分析

选择中心位置误差(CLE)、平均覆盖率(MOR)、成功率(SR)作为评测指标。

中心位置误差计算公式为

$$E_{CL} = \sqrt{(x_{ng} - x_{nt})^2 + (y_{ng} - y_{nt})^2}, \quad (5)$$

式中 (x_{ng}, y_{ng}) 和 (x_{nt}, y_{nt}) 分别为第 n 帧目标的实际中心位置和跟踪结果的目标中心位置。

成功率和平均覆盖率计算公式为

$$R_s = \frac{N_s}{N}, \quad (6)$$

$$R_{MO} = \frac{\text{area}(S_t \cap S_g)}{\text{area}(S_t \cup S_g)} / N, \quad (7)$$

式中 N 为图像序列帧数, N_s 为跟踪成功的次数, S_t 为跟踪方法输出的跟踪框区域, S_g 为实际目标区域,area表示区域面积。 N_s 由(7)式统计获得,若 $R_{MO} > 0$,则 N_s 增加一次。

8种跟踪方法对8组图像序列的评价结果如图4、表2~4所示。

图4中目标与伪目标交会时为跃变点。图4(a)和图4(b)中只包含单个伪目标,在跃变点附近,DLT、DLTAR算法在跟踪成功的情况下发生轻微漂移,中心位置误差较高,其他算法无法获取目标位置,跟踪失败;图4(c)~(h)包含多个伪目标且伪目标与目标多次交会,与单个伪目标干扰相比,DLT、DLTAR算法的中心位置误差偏高,跟踪效率较差,其他对比算法的中心位置误差持续累积。图4(a)和图4(e)中目标快速

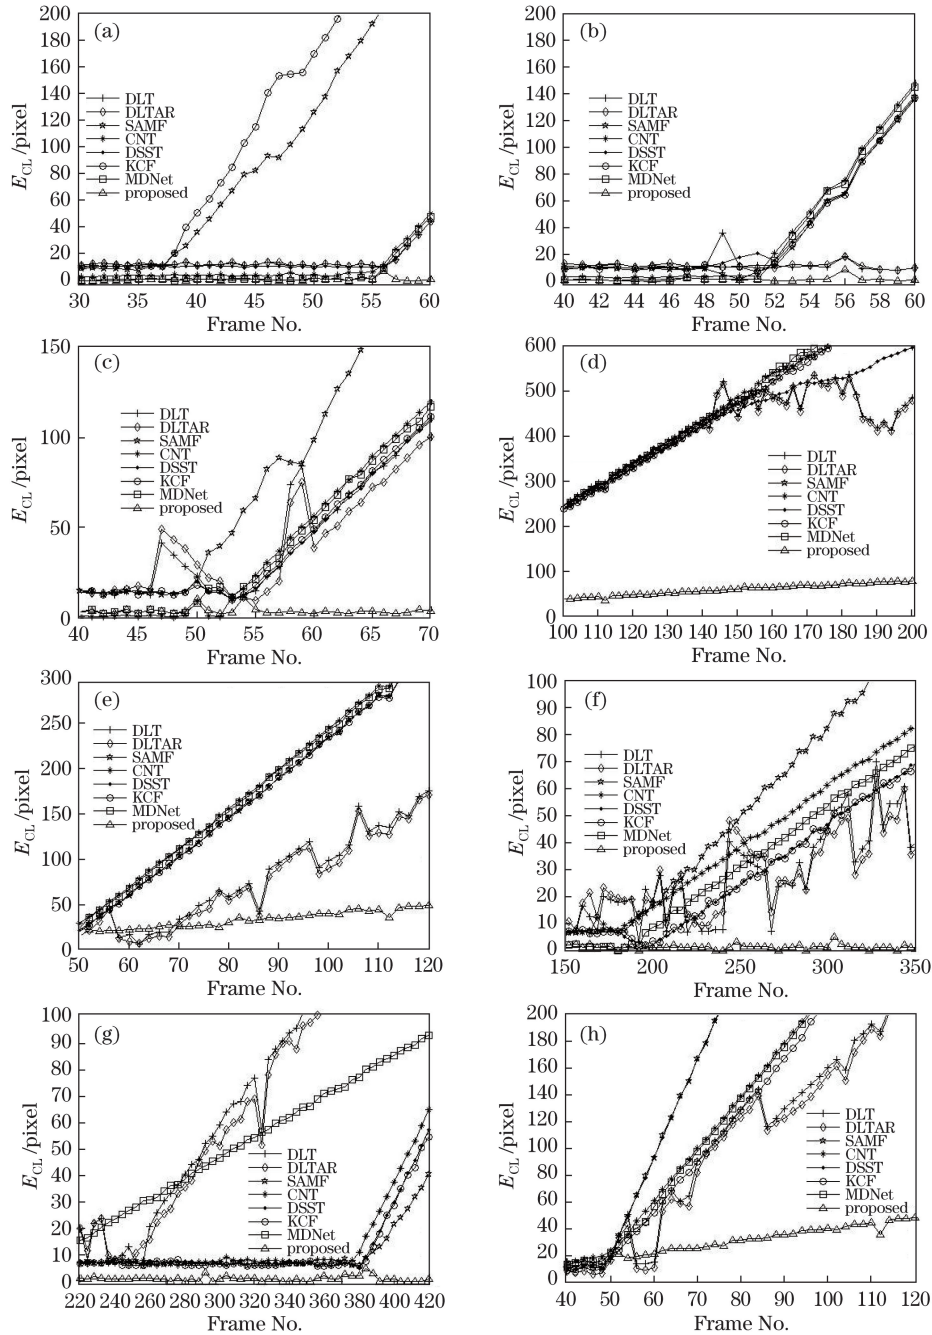


图 4 中心位置误差比较。(a) seq1; (b) seq2; (c) seq3; (d) seq4; (e) seq5; (f) seq6; (g) seq7; (h) seq8

Fig. 4 Comparison of center location error. (a) seq1; (b) seq2; (c) seq3;
(d) seq4; (e) seq5; (f) seq6; (g) seq7; (h) seq8

运动, SAMF、KCF 算法早期发生跟踪漂移, 相较于其他算法中心位置误差较大。本文方法在不同运动轨迹和运动状态下都保持较低的中心位置误差和较高的跟踪精度。

表 2~4 表明, 存在单个伪目标干扰时, 在跟踪成功的情况下 DLT 算法的成功率及 DLTAR 算法的平均覆盖率仅次于本文方法, DLTAR 算法的平均中心位置误差比 DLT 算法略低。但是, 由于 DLT 算法采样区域比 MDNet 算法大且采集到的样本数量多, AR 模型在预测目标位置时稍有误差便跟踪到采样区域的其他样本, 影响了 DLT 算法的网络稳定性, 导致 DLTAR 算法跟踪过程中多次发生跟踪漂移, 成功率不及 DLT 算法; 其他算法跟踪失败。存在多个伪目标干扰时, 对比算法的全程平均覆盖率与仅有单个伪目标干扰时的平均覆盖率相比有所下降。在这两种情况下, 本文方法保持了较高的成功率和平均覆盖率, 与仅使用

MDNet 算法相比成功率均值由 38.5% 提高到 97.7%，平均中心位置误差大幅度降低，平均覆盖率均值由 19.37% 提高到 46.94%，表现出较强的抗干扰能力和稳健性。

表 2 成功率
Table 2 Success rate

Image sequence	DLT	DLTAR	SAMF	CNT	DSST	KCF	MDNet	Proposed
seq1	51.9	32.9	35.6	55.7	55.4	35.6	55.6	100.0
seq2	92.4	71.7	51.5	51.8	49.5	50.5	51.7	99.5
seq3	57.6	28.4	53.5	52.8	53.2	53.5	52.3	95.3
seq4	16.5	7.2	13.9	19.5	13.7	10.5	21.7	96.4
seq5	18.2	8.1	12.7	19.3	12.4	9.8	21.9	95.8
seq6	38.6	16.4	36.4	39.8	36.3	28.7	40.2	98.7
seq7	37.9	16.2	61.2	39.4	35.8	21.1	41.7	99.1
seq8	17.7	8.1	13.2	20.7	11.2	10.3	22.8	96.6
Mean	41.4	23.6	34.8	37.4	33.4	27.5	38.5	97.7

表 3 平均中心位置误差
Table 3 Mean center location error

Image sequence	DLT	DLTAR	SAMF	CNT	DSST	KCF	MDNet	Proposed
seq1	90.1	98.7	215.9	84.8	88.1	228.3	84.7	1.3
seq2	13.6	14.4	184.8	184.8	186.2	184.9	184.8	0.9
seq3	17.4	16.1	70.5	68.7	70.7	71.5	68.4	4.9
seq4	251.4	257.3	275.2	283.4	258.1	273.5	281.9	40.9
seq5	158.2	149.3	262.4	256.3	272.5	272.5	274.6	46.7
seq6	53.7	48.7	72.8	53.4	45.0	46.7	46.7	1.3
seq7	70.3	68.7	20.2	28.0	26.5	26.0	40.8	1.2
seq8	243.5	233.8	305.2	242.2	317.7	238.4	243.9	40.7
Mean	112.3	110.9	175.9	150.2	158.1	167.7	153.2	17.2

表 4 平均覆盖率
Table 4 Mean overlap rate

Image sequence	DLT	DLTAR	SAMF	CNT	DSST	KCF	MDNet	Proposed
seq1	34.97	32.28	19.66	34.81	32.38	20.64	35.48	64.63
seq2	61.84	59.26	21.37	31.89	26.00	21.40	32.80	64.12
seq3	56.64	58.25	33.04	30.26	33.49	33.40	31.56	60.08
seq4	5.89	5.14	5.57	5.64	6.01	6.02	7.72	31.56
seq5	6.69	7.02	5.10	5.49	5.91	6.14	7.88	30.47
seq6	6.59	6.81	7.32	9.18	9.18	9.76	15.49	39.18
seq7	6.47	7.85	16.30	17.17	15.76	16.68	15.76	39.21
seq8	6.52	7.24	5.39	5.59	6.01	6.03	8.28	46.29
Mean	23.20	22.98	14.22	17.50	16.84	15.00	19.37	46.94

4 结 论

提出了一种基于 MDNet 和 AR 模型的空中小目标自适应跟踪方法。通过采用具有强大特征表达能力的 MDNet 有效分类目标,自适应提取目标特征,在跟踪过程中利用 AR 模型对目标运动轨迹进行估计并预测不同轨迹和运动状态的目标位置,采用 bounding-box 回归模型调整目标位置,实现了星空背景下伪目标

与目标交会时稳定、精确的跟踪。采用星空背景下包含单个及多个伪目标的 8 组图像序列进行测试,结果表明,本文方法的成功率及平均覆盖率均值均优于其他 7 种算法,相比仅使用 MDNet 算法分别提高了 59.2% 和 27.57%。定量和定性分析表明,在伪目标、噪声和星空背景干扰、遮挡、目标运动速度快等复杂场景下本文方法与其他典型算法相比,具有较高的精确性和稳健性。

本文方法跟踪速度较慢,而且仅针对单目标跟踪进行了研究,这是其局限性所在。下一步将研究快速的多目标跟踪算法。

参 考 文 献

- [1] Li Shuangshuang, Zhao Gaopeng, Wang Jianyu. Distractor-aware object tracking based on multi-feature[J]. *Acta Optica Sinica*, 2017, 37(5): 0515005.
李双双, 赵高鹏, 王建宇. 基于特征融合和尺度自适应的干扰感知目标跟踪[J]. *光学学报*, 2017, 37(5): 0515005.
- [2] Chen Y, Yang X, Zhong B, *et al.* CNNTracker: online discriminative object tracking via deep convolutional neural network[J]. *Applied Soft Computing*, 2016, 38: 1088-1098.
- [3] Li Z, Gao S, Ke N. Robust object tracking based on adaptive templates matching via the fusion of multiple features[J]. *Journal of Visual Communication & Image Representation*, 2017, 44: 1-20.
- [4] Qian K, Zhou H, Rong S, *et al.* Infrared dim-small target tracking via singular value decomposition and improved kernelized correlation filter[J]. *Infrared Physics & Technology*, 2017, 82: 18-27.
- [5] Li Dan, Bao Rong, Sun Jinping, *et al.* Tracking method of multi-resolution LK optical flow combined with SURF[J]. *Journal of Computer Application*, 2017, 37(3): 806-810.
厉丹, 鲍蓉, 孙金萍, 等. 多分辨率 LK 光流联合 SURF 的跟踪方法[J]. *计算机应用*, 2017, 37(3): 806-810.
- [6] Wang Yixian, Shi Dele, Yang Ning. Fusion algorithm of frame difference and mean shift for high-speed UAVs' tracking[J]. *Journal of Naval Aeronautical and Astronautical University*, 2016, 31(4): 437-441.
王宜贤, 石德乐, 杨宁. 帧差法和 Mean shift 算法融合的高速无人机目标跟踪[J]. *海军航空工程学院学报*, 2016, 31(4): 437-441.
- [7] Tan Yan, Wang Yujun. On a combination of background difference improved CamShift target tracking method[J]. *Journal of Southwest China Normal University (Natural Science Edition)*, 2016, 41(9): 120-125.
谭艳, 王宇俊. 一种结合背景差分的改进 CamShift 目标跟踪方法[J]. *西南师范大学学报(自然科学版)*, 2016, 41(9): 120-125.
- [8] Li H, Li Y, Porikli F. DeepTrack: Learning discriminative feature representations online for robust visual tracking[J]. *IEEE Transactions on Image Processing*, 2016, 25(4): 1834.
- [9] Cai Yuzhu, Yang Dedong, Mao Ning, *et al.* Visual tracking algorithm based on adaptive convolutional features[J]. *Acta Optica Sinica*, 2017, 37(3): 0315002.
蔡玉柱, 杨德东, 毛宁, 等. 基于自适应卷积特征的目标跟踪算法[J]. *光学学报*, 2017, 37(3): 0315002.
- [10] Zhang K, Liu Q, Wu Y, *et al.* Robust visual tracking via convolutional networks without training[J]. *IEEE Transactions on Image Processing*, 2015, 25(4): 1779-1792.
- [11] Nam H, Han B. Learning multi-domain convolutional neural networks for visual tracking [EB/OL]. (2016-01-06) [2017-03-20]. <https://arxiv.org/abs/1510.07945>.
- [12] Lu F B, Qiao H, Wang S Y, *et al.* Time-varying coefficient vector autoregressions model based on dynamic correlation with an application to crude oil and stock markets[J]. *Environmental Research*, 2017, 152: 351-359.
- [13] Wan H J, Xiao L. Variational Bayesian learning for robust AR modeling with the presence of sparse impulse noise[J]. *Digital Signal Processing*, 2016, 59: 1-8.
- [15] Wang Yuan. Second-order least squares estimation for linear regression model[D]. Beijing: Beijing Jiaotong University, 2016.
王媛. 线性回归模型的二阶最小二乘估计[D]. 北京: 北京交通大学, 2016.
- [16] Li Y, Zhu J K. A scale adaptive kernel correlation filter tracker with feature integration[C]. *European Conference on Computer Vision*, 2014, 8926: 254-265.
- [17] Danelljan M, Häger G, Khan F S, *et al.* Accurate scale estimation for robust visual tracking[C]. *Proceedings of the British Machine Vision Conference*, 2014: 65.1-65.11.
- [18] Henriques J F, Caseiro R, Martins P, *et al.* High-speed tracking with kernelized correlation filters[C]. *International Conference for High Performance Computing, Networking, Storage and Analysis, SC14, IEEE*, 2014: 375-386.