

基于孪生网络快速运动弱目标实时跟踪

郑军松, 郭浩*, 李阿标, 安居白

大连海事大学信息科学技术学院, 辽宁 大连 116026

摘要 针对现有目标跟踪算法对快速运动弱目标跟踪效果不佳的问题, 提出了一种时空连续的多特征融合孪生网络算法。首先以全卷积孪生网络为基本框架; 其次设计了一种从粗到细结合空间信息和语义信息的鲁棒性特征来表达快速运动弱目标, 并添加了特征注意力; 最后采用时空信息连续性模型对整体信息进行有效的更新, 从而选定最佳跟踪目标。在快速运动弱目标跟踪序列中, 与 5 种不同的特征选择及更新方式的算法进行对比, 所提算法表现出良好的实时跟踪效果; 并将所提算法与 9 种不同类算法和 5 种同类孪生网络算法进行了对比, 所提算法综合性能表现优异。实验结果表明, 所提算法具有较好的鲁棒性及实时性, 能有效地对快速运动弱目标进行跟踪。

关键词 图像处理; 目标跟踪; 弱目标; 孪生网络; 粗到细; 时空信息

中图分类号 TP391.41

文献标志码 A

doi: 10.3788/LOP202259.0410011

Real-Time Tracking of Fast Moving Weak Object Based on Siamese Network

Zheng Junsong, Guo Hao*, Li Abiao, An Jubai

School of Information Science and Technology, Dalian Maritime University, Dalian, Liaoning 116026, China

Abstract Aiming at the problem that the existing target tracking algorithms have poor effect on fast moving weak targets, a spatio-temporal continuous multi-feature fusion siamese network algorithm is proposed. First, the full convolution siamese network is used as the basic framework; second, a robust feature combining spatial information and semantic information from coarse to fine is designed to express fast-moving weak targets, and feature attention is added; Finally, the spatio-temporal information continuity model is used to effectively update the overall information, so as to select the best tracking target. In the fast moving weak target tracking sequence, compared with five different feature selection and update algorithms, the proposed algorithm shows good real-time tracking effect; the proposed algorithm is compared with 9 different algorithms and 5 similar twin network algorithms, and the comprehensive performance of the proposed algorithm is excellent. Experimental results show that the proposed algorithm has good robustness and real-time performance, and can effectively track fast moving weak objects.

Key words image processing; object tracking; weak object; siamese network; coarse-to-fine; spatio-temporal information

1 引言

目标跟踪是计算机视觉中一个极具挑战性的

任务, 在跟踪过程中易受光照变化、遮挡与否、尺度变化、运动快慢、形状变化等因素的影响。在快速运动弱目标跟踪场景中, 传统特征难以适应目标变

收稿日期: 2021-02-26; 修回日期: 2021-03-27; 录用日期: 2021-04-02

基金项目: 国家自然科学基金(61471079)

通信作者: *guohao0512@dlnu.edu.cn

化,采用深度特征所得到的目标缺失边缘信息,使得定位不准确,误差累积;且目标与背景时刻发生变化,难以捕捉到当前的全局信息,使得跟踪发生漂移。因此对于一个鲁棒的模型来说,实现快速运动弱目标的有效跟踪需要解决两个关键点:鲁棒特征和有效模板更新。

当前国内外目标跟踪算法主要有相关滤波算法^[1]和基于深度学习的算法两类。相关滤波表示两个信号之间的相似程度,最早被引入跟踪领域是 Bolme 等^[2]提出的误差最小平方算法,随后基于此算法有了很多相关的改进。Henriques 等^[3-4]使用一个线性分类器来求解相关滤波,引入核方法和多通道特征处理算法,利用傅里叶空间可对角化的性质将矩阵的运算转化为向量积,降低了计算量,但该算法对快速运动目标的跟踪效果不佳。而后很多相关滤波跟踪算法融合了卷积神经网络(CNN)特征,如 Danelljan 等^[5]使用 CNN 特征,将不同分辨率的特征图通过立方插值和 Hessian 矩阵求得亚像素精度的目标位置,但当目标与周围背景颜色相似时,跟踪容易漂移,且在速度大约为 1 frame/s 时,实时性大于 24 frame/s。Bai 等^[6]提出“多维特征合并的相关滤波”思路,把握不同跟踪场景的内部关系实现更稳定的跟踪,但跟踪过程易受相似目标的干扰而失败。基于深度学习的目标跟踪算法把图像分类训练的 CNN 迁移到目标跟踪中来^[7]。早期 Wang 等^[8]利用卷积层特征构建特征选择网络,并根据是否有目标被干扰选择对应的特征网络来实现跟踪,但当背景模糊时,跟踪失败,且跟踪速度为 3 frame/s。Nam 等^[9-10]提出了树分支的 CNN 模型^[9]及多分支分类模型^[10]等算法,但该算法参数量大,难以满足实时性的要求。Held 等^[11]提出了首个速度达到 100 frame/s 的算法,该算法分别提取当前帧和前一帧目标特征,并将这些特征级联后输入全连接层进行比较实现位置回归,进而计算出目标的位置,但当背景出现连续变化时,回归误差增大导致跟踪失败。而后孪生网络的引入大大减小了计算量,且在速度上有了很大的突破,如 Valmadre 等^[12]对孪生网络提取的特征进行相关滤波变换进而选定目标,很好地在训练中融入相关滤波,但该算法在面对快速运动的目标或者背景变换的场景中跟踪效果不佳;此后 Li 等^[13]将孪生网络和检测中的区域推荐网络结合,实现了对跟踪目标的自适应,该算法可以利用被跟踪目标的信息,

完成检测器的初始化,并通过区域候选网络对目标位置进行精准的预测,但在变换复杂的背景下难以有效应用。

综上所述,本文在全卷积孪生网络模型的基础上,提出了一种时空连续的多特征融合孪生网络算法。首先通过改善快速运动弱目标的特征表示,模型既能识别目标也能保证目标的边缘信息完整;其次通过时空信息连续性模型修正目标与背景的信息来合理地捕捉快速运动场景下的全局信息,实现鲁棒性跟踪。实验结果表明,所提算法在快速运动场景中跟踪效果良好,且在综合性能对比上表现突出。

2 基本原理

2.1 全卷积孪生网络算法

全卷积孪生网络算法^[14]由两个结构相同且网络权值共享的分支组成,基础网络为去除全连接层后的 Alexnet^[15]。模板分支 \mathbf{Z} 为序列第 1 帧,匹配分支 \mathbf{X} 为后续帧,二者提取特征 φ 并计算特征相似度矩阵 $f(\mathbf{Z}, \mathbf{X})$, 矩阵中最大值点为目标最大响应点,其中 $*$ 为相似度计算即卷积, \mathbf{b} 为偏差。

$$f(\mathbf{Z}, \mathbf{X}) = \varphi(\mathbf{Z}) * \varphi(\mathbf{X}) + \mathbf{b}. \quad (1)$$

训练时采用交叉熵定义正负样本的损失,对候选位置求平均损失来定义训练损失,并最小化损失来训练参数。

$$\arg \min_{\theta} E_{(\mathbf{Z}, \mathbf{X}, \mathbf{y})} \frac{1}{D} \sum_{u \in D} l\{y[u], f(\mathbf{Z}, \mathbf{X}; \theta)[u]\}, \quad (2)$$

式中: l 为交叉熵函数; u 为相似度矩阵 \mathbf{D} 中的某一个元素; $f(\mathbf{Z}, \mathbf{X}; \theta)$ 表示以训练参数为 θ 的相似度计算; $y[u]$ 表示当前 u 位置为正样本或者负样本,且 $y[u] = +1$ 和 $y[u] = -1$ 分别为正样本和负样本;与目标中心距离不超过 2 的样本为正样本,反之为负样本。

2.2 问题描述

快速运动弱目标(如暗目标、相似目标、小目标)难跟踪的原因在于目标与背景对比度低,在快速运动下背景及目标不断变化导致跟踪失败。暗目标为与周围区域背景颜色相似的目标,对应区域的 LAB 颜色相似度小于 26;相似目标为与目标相似的物体;小目标的长宽是原图像尺寸的 0.1;快速运动指目标与背景在不断运动变化的物体;虚线框

为真实目标,实线框为干扰框,如图 1 所示。

2.3 特征设计

针对快速运动弱目标特征表达能力弱、信息少、目标模糊等问题,考虑到在分类任务中,网络中深层特征 Conv5 具有强的语义信息且对目标的外观变化具有不变性,而浅层特征 Conv3、Conv4 具有丰富的空间信息,能够精确定位,于是所提算法在原有的 Conv5 特征基础上结合了 Conv3、Conv4 特征。图 2 从左往右分别为原图、Conv3 特征图、Conv4 特

征图、Conv5 特征图。

由于不同卷积层特征具有相异的显著性且对应于不同的视觉模式,所提算法在网络中结合了一种特征注意力机制。首先将输入的特征经过全局均值池化(GAP),然后经过多层感知机(MLP),MLP 包括两个全连接层(FC)和激励函数(ReLU),再通过 Sigmoid 激活,最后将生成的通道权重与特征相乘得到最终的输出特征,如图 3 所示。



图 1 快速运动弱目标图。(a)暗目标、相似目标、小目标;(b)暗目标;(c)小目标

Fig. 1 Fast moving weak object graphs. (a) Dark objects, similar objects, small objects; (b) dark objects; (c) small objects




图 2 卷积特性图

Fig. 2 Convolution characteristic diagram




图 3 特征注意力

Fig. 3 Feature attention

最后将 3 层特征的相似度匹配结果以一种粗到细的方式结合,逐步对目标进行准确定位。给定一组相关响应图 $\{f_i\}$ 来分层推断目标区域,即将前 1 层最大值位置正则化来搜索后 1 层的最大值。设 $(m^o, n^o) = \arg \max f_i(m, n)$ 为最大值在第 i 层的位置,则目标在第 $i+1$ 层中最佳位置的表达式为

$$(m, n) = \arg \max_{|m - m^o| + |n - n^o| \leq r} f_{i+1}(m, n) + \lambda f_i(m, n), \quad (3)$$

式中: $|m - m^o| + |n - n^o| \leq r$ 表示在第 i 层最大值位置距离为 r 的邻域范围。

2.4 时空信息连续模型设计

针对快速运动弱目标及背景在时空上不断发生变化,难以捕捉该场景下的全局信息的问题,如图 4 所示,所提时空信息连续性模型孪生网络只选用第 1 帧作为模板 Z ,忽略后续帧目标及背景的变化,可以有效地对目标信息及背景信息进行选择和更新。

考虑到相邻帧之间的目标及背景的变化是微妙的,若每帧都进行更新会增加不必要的计算量,且跟




图 4 目标及背景在时空上的变化

Fig. 4 Temporal and spatial variation of target and background

踪失败有一个误差累积的过程,因此对模型跨时段每 10 帧进行一次修正,选用当前预测帧前 1 帧的跟踪结果与目标模板来共同结合预测当前帧。

$$F(\mathbf{Z}, \mathbf{X}) = \alpha \times f(\mathbf{Z}, \mathbf{X}) + \beta \times f(\mathbf{Z}', \mathbf{X}), \quad (4)$$

式中: α, β 为融合系数; $f(\mathbf{Z}, \mathbf{X})$ 为预测帧与目标模板相似计算的结果, $f(\mathbf{Z}', \mathbf{X})$ 为预测帧与辅助模板相似计算的结果。该方法能有效地融合当前背景信息及快速运动弱目标的变化状态,有利于全局信息的稳定更新。

2.5 时空连续多特征融合孪生网络框架流程

所提算法框架如图 5 所示,主要步骤如下。

1) 特征提取:第 1 帧图像以目标为中心裁剪出 127×127 区域作为主模板,预测帧的前 1 帧图像以

目标中心裁剪出 127×127 区域作为辅助模板,预测帧以前 1 帧图像预测的目标为中心裁剪出 255×255 区域,并分别提取出 Conv3、Conv4 及最后 1 层特征。

2) 观测模型:将预测帧提取的 3 层特征分别与主模板、辅助模板的 3 层对应特征进行相似度计算,得到相应的 $f(\mathbf{Z}, \mathbf{X})$, 如(1)式所示。

3) 位置估计:将 3 个相似度计算结果以粗到细的方式融合估计最大值位置,并把最大值位置通过尺度变换找到对应目标位置。

4) 辅助模板更新:将输出的预测帧目标位置保留作为更新下 1 次预测所需的辅助模板,重复步骤 1)~3)进行后续跟踪。

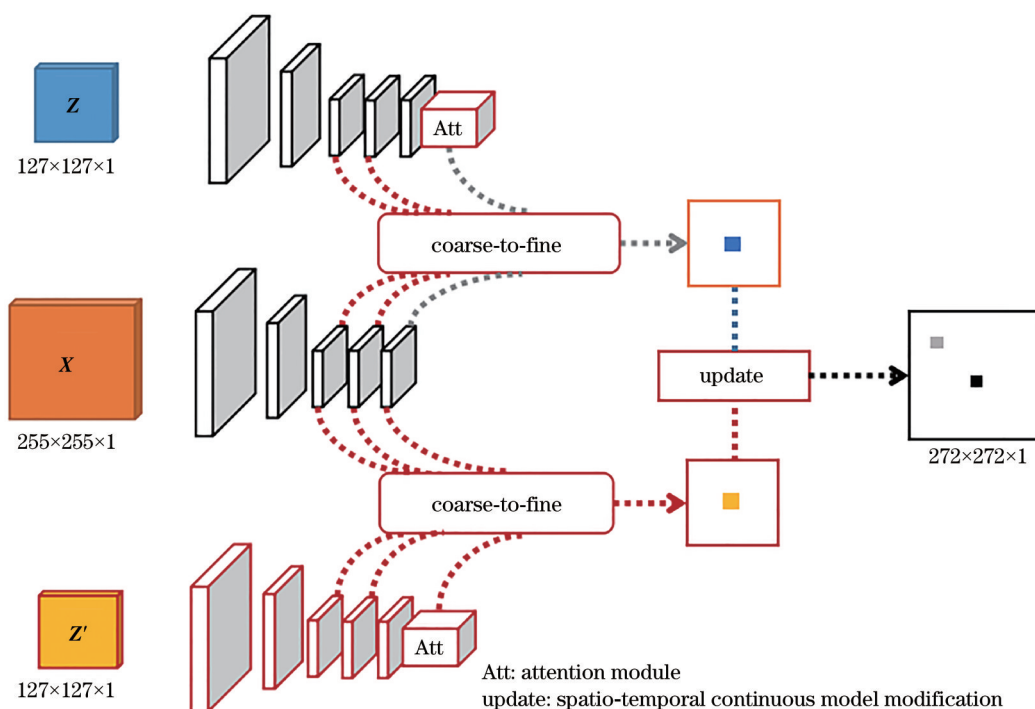


图 5 所提算法框架图

Fig. 5 Frame diagram of proposed algorithm

3 数据集

3.1 训练集及预处理

所提算法采用覆盖了大约 4500 个逐帧注释的视频序列且超过 10 万个每 30 帧注释视频的 ILSVRC2015 数据集^[16]对模型进行训练,训练样本对从标注的视频数据集得到,均以目标为中心且尺寸统一,如果超出图像尺寸则用像素平均值填充。采用随机梯度下降(SGD)进行 30 次训练,前 25 次学习率为 1×10^{-2} ,后 5 次为 1×10^{-3} ,每次由 50000

随机抽样样本对组成,小批量样本数为 8,运用 3 个尺度搜索对象,尺度惩罚系数为 0.9745。其中 λ 的取值为 $[0.25, 0.25, 0.5]$, α, β 为 $[0.8, 0.2]$, r 对应相似度矩阵的大小。训练通过验证集验证,训练合理,无过拟合。

3.2 跟踪数据

在 OTB100^[17]中选取符合快速运动弱目标场景的 6 个序列,分别对相似目标、暗目标、小目标的不同场景的长时和短时的跟踪序列进行测试,序列中还包含遮挡(OCC)、形变(DEF)、光照(IV)、平面旋

转(I/OPR)等挑战因素,如表1所示。

4 实验结果与分析

算法实验环境为 ubuntu 14.04+Python 3+torch 1.1。硬件环境为 DELL Precision t7920 和显卡 NVIDIA TITAN RTX,平均跟踪速度达到 88 frame/s。

在测试序列中与 5 个不同算法进行了对比,图 6 为有代表意义的 4 帧跟踪结果,跟踪序列分别对应于表 1。对比的 5 个算法选用的特征及更新与否如表 2 所示。

为了进行更加全面的分析,将所提算法与 9 种算法进行了定量评估对比,结果如图 7 所示,分别计算各

表 1 测试序列

Table 1 Tracking sequence

Sequence	Challenge	Total frames	Weak object frame
Bolt 2	BC,DEF	293	Similar object:1-293
Skiing	IV,SV,OPR,DEF	81	Small object:1-26;32-35;38-81
CarDark	BC,IV	393	Dark object:258-336
MotorRolling	FM,BC,MB,LR	164	Dark object:14-16;40-46;99-105
Matrix	FM,BC,IV,OCC I/OPR,IV,SV	100	Small object:1-57;similar object:1-56 Dark object:3-13;19-30;74-86
Car 1	FM,BC,LR,MBIV,SV	1020	Small object:525-1020;similar object:102-300 Dark object:251-540;614-799;819-897

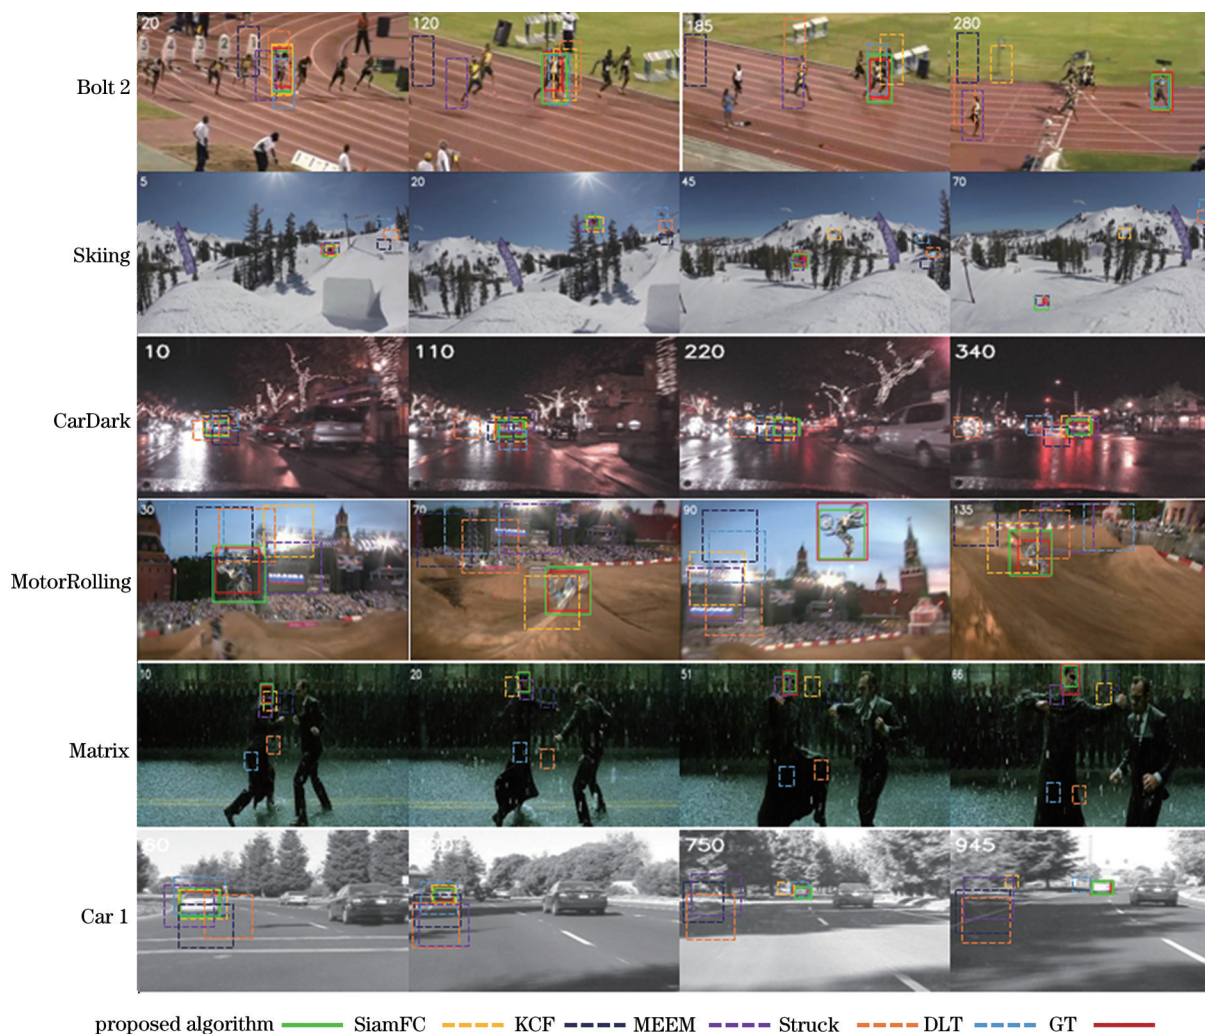


图 6 跟踪结果

Fig. 6 Tracking results

表 2 六个算法的区别

Table 2 Differences between six algorithms

Algorithms	Feature	Update
Proposed algorithm	Conv3+Conv4+Conv5	Yes
SiamFC ^[14]	Conv5	No
KCF ^[4]	HOG	No
MEEM ^[18]	CIE Lab	Yes
Struck ^[19]	Haar	Yes
DLT ^[20]	SDAE	Yes

种算法在 OTB100、OTB50(OTB50 为 OTB100 的

同挑战因素的子集)的不同区域重叠阈值的成功率 (AUC) 及不同错误阈值下的中心定位的准确率 (PRE), 其中成功率为跟踪框与标注框的平均交并比, 准确率为二者中心点的距离小于一定阈值的帧数比。并将所提算法与较新的孪生网络类算法 SiamFC、CFnet^[12]、MBST^[21]、Siam-tri^[22]、SINT++^[23]进行了整体比较, 结果如表 3 所示, 其中 SiamFC-MF 为使用所提改进特征设计的算法。实验结果表明, 所提算法在实时性条件下, 在 OTB100 上的准确率均优于其他算法, 在上述两种指标中取得不错的整体成绩。

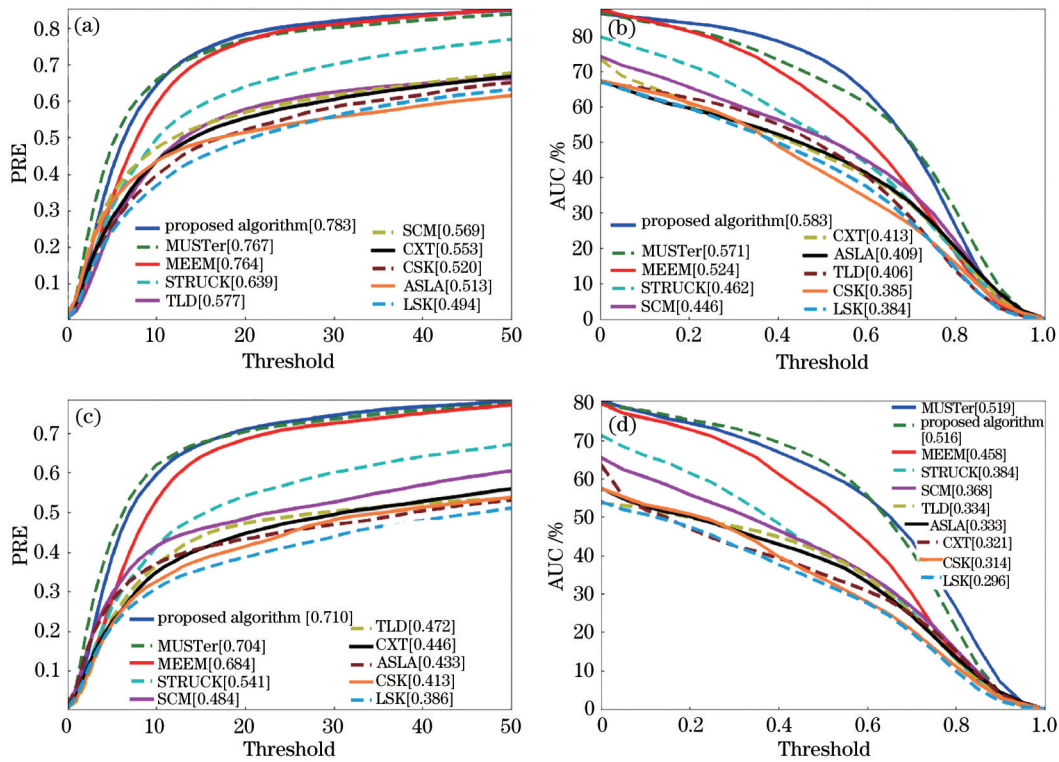


图 7 OTB100/50 上的成功率和准确率。(a) OTB100 准确率; (b) OTB100 成功率; (c) OTB50 准确率; (d) OTB50 成功率
 Fig. 7 Success rate and precision on OTB100/50. (a) OTB100 accuracy rate; (b) OTB100 success rate; (c) OTB50 accuracy rate; (d) OTB50 success rate

表 3 孪生网络类算法比较

Table 3 Comparison of class algorithms

Algorithms	OTB100		OTB50		Speed / (frame · s ⁻¹)
	AUC	PRE	AUC	PRE	
Proposed algorithm	0.583	0.783	0.516	0.710	88
SiamFC-MF	0.581	0.774	0.513	0.696	112
SiamFC	0.578	0.770	0.513	0.692	180
CFnet-conv5	0.586	0.711	0.539	0.67	43
MBST	0.599	0.783	0.536	0.718	42.9
Siam-tri	0.590	0.781	0.531	0.713	86.3
SINT++	0.574	0.768	0.624	0.839	1

为验证所提算法对不同场景的普适性,对车辆行驶、行人流动、体育运动等场景进行了跟踪,图 8 为具有代表性 4 帧跟踪结果,所提算法跟踪框与真实目标框能保持一致的运动变化,重叠率高。实验结果表明,所提算法在以上不同场景中均能实现准确的实时跟踪,验证了算法的普适性。

5 结 论

针对快速运动弱目标跟踪出现的难点,提出了一种时空连续的多特征融合孪生网络算法。首先设计了一种以粗到细结合空间信息和语义信息的特征并添加特征注意力,然后运用跨时段更新方式使得模型捕获当前的全局信息。所提算法在快速运动弱目标场景中长时跟踪及短时跟踪表现良好,表明了算法的有效性;相比于同类及不同类算法,

在速度上达到了实时性的要求,展现出较好的跟踪效果,表现出不错的综合性能。所提算法适用于视频监控、机器人视觉导航等实际应用。在未来的工作中,可充分利用全卷积孪生网络算法的简洁性、实时性进行自适应性尺度^[24]变换,使得算法能够有效处理边界效应,能够完全适应目标的剧烈形变,从而提高算法的整体效率。



图 8 不同场景跟踪结果图

Fig. 8 Tracking results for different scenes

参 考 文 献

- [1] Yu Y Y, Shi Z L, Liu Y P. Foreground-aware based spatiotemporal correlation filter tracking algorithm[J]. *Laser & Optoelectronics Progress*, 2019, 56(22): 221503.
虞跃洋, 史泽林, 刘云鹏. 基于前景感知的时空相关滤波跟踪算法[J]. *激光与光电子学进展*, 2019, 56(22): 221503.
- [2] Bolme D S, Beveridge J R, Draper B A, et al. Visual object tracking using adaptive correlation filters[C]//2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, June 13-18, 2010, San Francisco, CA, USA. New York: IEEE Press, 2010: 2544-2550.
- [3] Henriques J F, Caseiro R, Martins P, et al. Exploiting the circulant structure of tracking-by-detection with kernels[M]//Fitzgibbon A, Lazebnik S, Perona P, et al. *Computer vision-ECCV 2012. Lecture notes in computer science*. Heidelberg: Springer, 2012, 7575: 702-715.
- [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] Danelljan M, Robinson A, Shahbaz Khan F, et al. Beyond correlation filters: Learning continuous convolution operators for visual tracking[M]//Leibe B, Matas J, Sebe N, et al. *Computer vision-ECCV 2016. Lecture notes in computer science*. Cham: Springer, 2016, 9909: 472-488.
- [6] Bai S, He Z Q, Dong Y, et al. Multi-hierarchical independent correlation filters for visual tracking[C]//2020 IEEE International Conference on Multimedia and Expo (ICME), July 6-10, 2020, London, UK. New York: IEEE Press, 2020: 1-6.
- [7] Liu M J, Cao Y Z, Zhu S Y, et al. Feature fusion video target tracking method based on convolutional neural network[J]. *Laser & Optoelectronics Progress*, 2020, 57(4): 041502.
刘美菊, 曹永战, 朱树云, 等. 基于卷积神经网络的特征融合视频目标跟踪方法[J]. *激光与光电子学进展*, 2020, 57(4): 041502.
- [8] Wang L J, Ouyang W L, Wang X G, et al. Visual tracking with fully convolutional networks[C]//2015 IEEE International Conference on Computer Vision (ICCV), December 7-13, 2015, Santiago, Chile. New York: IEEE Press, 2015: 3119-3127.
- [9] Nam H, Baek M, Han B. Modeling and propagating CNNs in a tree structure for visual tracking[EB/OL]. (2016-08-25) [2021-02-20]. <https://arxiv.org/abs/1608.07242>.
- [10] Nam H, Han B. Learning multi-domain convolutional neural networks for visual tracking[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 4293-4302.
- [11] Held D, Thrun S, Savarese S. Learning to track at 100 FPS with deep regression networks[M]//Leibe B, Matas J, Sebe N, et al. *Computer vision-ECCV 2016. Lecture notes in computer science*. Cham: Springer, 2016, 9905: 749-765.
- [12] Valmadre J, Bertinetto L, Henriques J, et al. End-to-end representation learning for correlation filter based tracking[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 5000-5008.
- [13] Li B, Yan J J, Wu W, et al. High performance visual tracking with Siamese region proposal network [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 8971-8980.
- [14] Bertinetto L, Valmadre J, Henriques J F, et al. Fully-convolutional Siamese networks for object tracking [M]//Hua G, Jégou H. *Computer vision-ECCV 2016 workshops. Lecture notes in computer science*. Cham: Springer, 2016, 9914: 850-865.
- [15] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks [J]. *Communications of the ACM*, 2017, 60(6): 84-90.
- [16] Russakovsky O, Deng J, Su H, et al. ImageNet large scale visual recognition challenge[J]. *International Journal of Computer Vision*, 2015, 115(3): 211-252.
- [17] Wu Y, Lim J, Yang M H. Object tracking benchmark [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2015, 37(9): 1834-1848.
- [18] Zhang J M, Ma S G, Sclaroff S. MEEM: robust tracking via multiple experts using entropy minimization [M]//Fleet D, Pajdla T, Schiele B, et al. *Computer vision-ECCV 2014. Lecture notes in computer science*. Cham: Springer, 2014, 8694: 188-203.
- [19] Hare S, Golodetz S, Saffari A, et al. Struck: structured output tracking with kernels[J]. *IEEE Transactions on Pattern Analysis and Machine*

- Intelligence, 2016, 38(10): 2096-2109.
- [20] Wang N Y, Yeung D Y. Learning a deep compact image representation for visual tracking[C]//Advances in Neural Information Processing Systems 26: 27th Annual Conference on Neural Information Processing Systems 2013, December 5-8, 2013, Lake Tahoe, Nevada, United States. [S.l.: s.n.], 2013: 809-817.
- [21] Li Z X, Bilodeau G A, Bouachir W. Multi-branch siamese networks with online selection for object tracking[M]//Bebis G, Boyle R, Parvin B, et al. Advances in visual computing. Lecture notes in computer science. Cham: Springer, 2018, 11241: 309-319.
- [22] Dong X P, Shen J B. Triplet loss in Siamese network for object tracking[M]//Ferrari V, Hebert M, Sminchisescu C, et al. Computer vision-ECCV 2018. Lecture notes in computer science. Cham: Springer, 2018, 11217: 472-488.
- [23] Wang X, Li C L, Luo B, et al. SINT++: robust visual tracking via adversarial positive instance generation [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 4864-4873.
- [24] Tang X M, Chen Z G, Fu Y. Action prediction and scale adaptive target tracking algorithm[J]. Laser & Optoelectronics Progress, 2020, 57(8): 081014.
汤学猛, 陈志国, 傅毅. 行动预测及尺度自适应目标跟踪算法[J]. 激光与光电子学进展, 2020, 57(8): 081014.