

# 基于注意力机制的无监督单目标跟踪算法\*

林志雄, 吴丽君, 陈志聪

(福州大学 物理与信息工程学院, 福建 福州 350108)

**摘要:** 为提升目标跟踪精度, 设计一种基于注意力机制的无监督单目标跟踪算法。该算法使用 DCFNet 网络作为基本网络, 通过前向跟踪和后向验证实现无监督跟踪。为结合上下文信息, 引入特征融合方法, 且将 DCFNet 网络每一层所提取的特征通过双线性池化调整分辨率以便进行特征融合; 为关注不同特征通道上的关系, 引入通道注意力机制 SENet 模块; 设计一个反向逐帧验证方法, 在反向验证中间帧的基础上再预测第一帧, 进而减少判别位置的误差。在公共数据集 OTB-2015 上的测试结果显示, 本算法 AUC 分数达 60.6%, 速度达 61FPS。与无监督单目标跟踪 UDT 算法相比, 所设计算法取得了更优的目标跟踪性能。

**关键词:** 目标跟踪; 无监督学习; 特征融合; 注意力机制

中图分类号: TP391

文献标识码: A

DOI: 10.19358/j.issn.2096-5133.2022.06.009

引用格式: 林志雄, 吴丽君, 陈志聪. 基于注意力机制的无监督单目标跟踪算法[J]. 信息技术与网络安全, 2022, 41(6): 50-56.

## Unsupervised single target tracking algorithm based on attention mechanism

Lin Zhixiong, Wu Lijun, Chen Zhicong

(College of Physics and Information Engineering, Fuzhou University, Fuzhou 350108, China)

**Abstract:** In order to improve target tracking accuracy, this paper designs an unsupervised single target tracking algorithm based on attention mechanism. The algorithm uses the DCFNet network as the basic network to achieve unsupervised tracking through forward tracking and backward verification. In order to combine the context information, a feature fusion method is introduced, and the features extracted by each layer of the DCFNet network are adjusted for resolution by bilinear pooling for feature fusion; in order to pay attention to the relationship between different feature channels, a channel attention mechanism SENet module is introduced; a reverse frame-by-frame verification method is designed, and the first frame is predicted based on the reverse verification of the intermediate frame, thereby reducing the error of the discriminant position. The test results on the public dataset OTB-2015 show that the AUC score of this algorithm is 60.6% and the speed is 61FPS. Compared with the unsupervised single-target tracking UDT algorithm, the designed algorithm achieves better target tracking performance.

**Key words:** target tracking; unsupervised learning; feature fusion; attention mechanism

### 0 引言

目标跟踪被广泛应用于视频监控和自动驾驶等领域。在给定视频第一帧中目标位置后, 目标跟踪的任务是得到目标在后续帧中的位置信息。在有遮挡、变形和背景混乱等场景下, 准确有效地检测和定位目标仍然是个难点。

深度网络由于可以加强特征表示, 被广泛用于视觉目标跟踪领域。TAO 等人提出 SINT 网络<sup>[1]</sup>, 首次利用孪生网络提取特征, 通过匹配初始目标的外观识别候选图像位置, 实现目标跟踪任务; BERTINETTO 等人提出 SiamFC (Siamese Fully Convolution) 网络<sup>[2]</sup>, 使用离线训练的完全卷积孪生网络作为跟踪系统的基本网络, 大大提高了跟踪性能; LI 等人<sup>[3]</sup>提出了 SiamRPN 网络, 基于 SiamFC 网络引入了区域提案网

\* 基金项目: 福建省科技厅引导性项目 (2019H0006)

络 RPN 模块<sup>[4]</sup>,让跟踪系统可以回归位置、形状,进一步提高性能并加速;在此之前,基于孪生网络的跟踪器往往使用较浅的网络,很大原因在于深层网络的填充会破坏平移不变性,导致跟踪性能下降。LI 等人<sup>[5]</sup>提出在训练过程中引入位置均衡的采样策略,来缓解网络在训练过程中存在的位置偏见问题,进而在 SiamRPN 网络基础上用了 ResNet 网络<sup>[6]</sup>作为主干网络,让跟踪模型性能不再受制于网络的容量。

以上这些单目标跟踪模型都是属于有监督学习,有监督学习需要大量的有标记数据集,但是手动标记既昂贵又耗时。而互联网上有大量的未标记视频可供使用,因此无监督目标跟踪算法具有更好的实际应用价值。WANG 等人<sup>[7]</sup>提出了 UDT(Unsupervised Deep Tracking)模型,通过将前向传播和反向预测的结果进行一致性损失计算,实现在没有标签的情况下同样优化模型。但在前向传播过程中,跟踪模型若预测的位置出错,经过反向修正后可能会再回到正确的位置,这就会导致前向传播的错误预测没有被惩罚,降低了模型跟踪性能。为此,WANG 等人又进一步提出 UDT+模型<sup>[8]</sup>,通过多帧验证方法惩罚前向传播的错误预测,提升位置预测的准确性。

为了让网络学习到更多关于目标的信息,注意力机制<sup>[9]</sup>被引入到有监督目标跟踪模型中,进而提高目标跟踪模型的性能。例如,WANG Q 等人提出 RASNet 模型<sup>[10]</sup>,引入了残差注意力块、通道注意力块和通用注意力块,使得整个网络可以根据目标的变化而自适应调整注意力,可在适当缓解网络过拟合情况的同时提升网络的跟踪性能。HE 等人提出的 SA-Siam 模型<sup>[11]</sup>,主要使用了两个网络分别获取网络的语义特征和外观特征,在语义分支也添加了注意力机制,来提高跟踪的性能。

针对目前无监督单目标跟踪的精度相对有监督的较低的情况,本文设计一种基于注意力机制的无监督单目标跟踪模型。本文的主要贡献包括:

(1)本文设计一种基于注意力机制的无监督单目标跟踪算法;

(2)采用 DCFNet 网络作为主干网络,在其最后一层之后引入通道注意力机制,加强关注特征通道之间的关系,进行特征融合;

(3)设计一种反向逐帧验证方法,提高无监督单

目标跟踪性能;

(4)在标准基准的综合实验中,所设计的算法在保证算法实时性下获得较好的精度。

## 1 本文方法及模型

本文采用了 DCFNet 网络作为主干网络,对 DCFNet 网络的每一层网络提取的特征,通过下采样调整分辨率进行特征融合;此外,在 DCFNet 网络的最后一层网络后面加入通道注意力机制 SENet 网络<sup>[12]</sup>;最后结合前向传播和设计的反向逐帧验证方法,实现无监督单目标跟踪任务。整个网络结构如图 1 所示。整个网络结构具有两个网络权重分支:一个是模板分支,以模板补丁(Template patch)作为输入进行特征提取,通过相关滤波器(Correlation Filter, CF)模块进一步生成目标模板;另一个是搜索分支,以搜索补丁(Search patch)作为输入进行特征提取。两个分支采用相同的 DCFNet 网络的前两个网络层进行特征提取,以及后面对两个分支进行相同的特征融合和通道注意力机制模块操作。

将第一层网络层(conv1)提取的特征图,通过双线性池化<sup>[13]</sup>(Bilinear pooling)下采样到与第二层网络层(conv2)提取的特征图分辨率一致,将两层网络所提取特征相加取平均,得到融合后的特征图,融合后的特征图结合了浅层提取得特征图具有的位置信息。再将融合得到的特征图经过 SENet 模块,得到重新定义的特征图。最后,模板分支和搜索分支得到的特征卷积生成响应图 Response1(简称 R1)。响应图 R1 是一个高斯标记,理想情况下,响应图 R1 的峰值就是真实目标所在的位置。后向验证的操作与前向跟踪的区别在于,后向验证是将前向跟踪得到的后一帧图片的预测位置作为新的目标模板,将前一帧图片作为搜索补丁。相同理想情况下,后向验证操作得到的响应图 Response2(简称 R2)应该与最初第一帧给定的标签 Initial Label(简称 Y)相类似。为此,可以通过最小化重构误差损失,以无监督的方式训练网络,从而优化跟踪性能。最小化重构误差损失公式表示为:

$$L_{\text{un}} = \|R1 - Y\|_2^2 \quad (1)$$

### 1.1 特征融合模块

神经网络每一层网络所提取的特征具有不同的表达能力。相对浅的网络层所提取的特征往往包含较少的语义信息,包含较多的位置信息和细节信

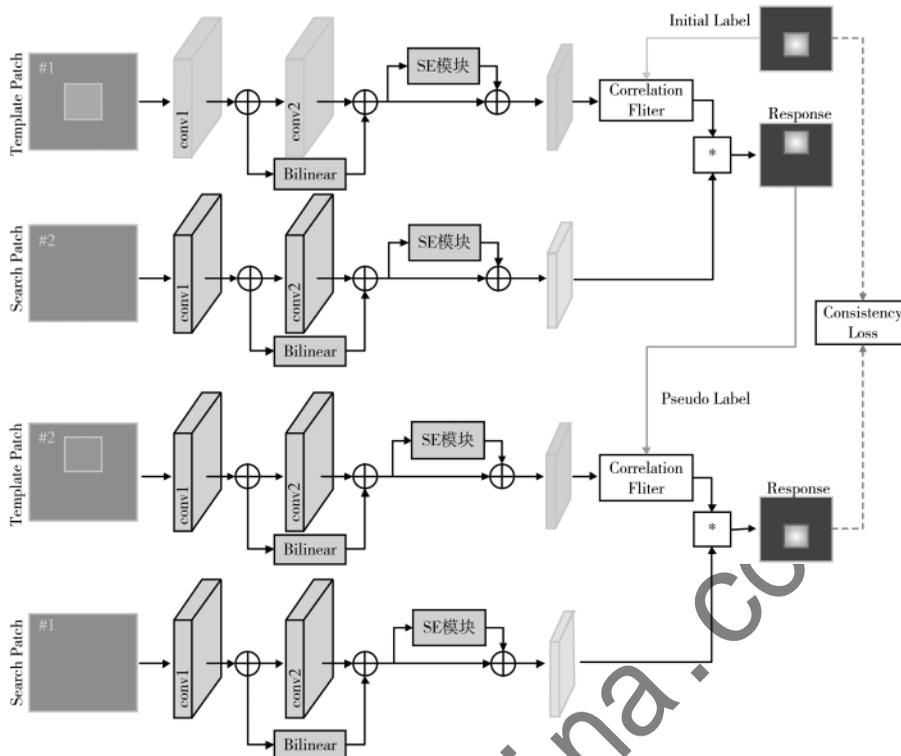


图1 本文算法的网络结构

息,主要表征了目标的边缘和轮廓等信息,特征图的分辨率较高。相对深的网络层所提取的特征由于分辨率较低,损失了大量的细节信息,但包含更多的语义信息,有着更强的分辨能力。为使最后提取的特征包含更多的位置信息,文中将 DCFNet 后面网络层提取的特征去结合前面所有网络层提取的特征,来获得更多的位置信息,可以提高目标位置的判别准确性。

常见的特征融合方法包括通道融合法和像素融合法。通道融合法是将同样大小分辨率的特征图在特征维度上叠加;而像素融合法直接将两张分辨率相等的特征图对应的像素点相加,得到的特征图和之前的在通道上保持不变。为了在引入通道注意力机制模块的时候,能更加准确地生成各个通道的权重,本文选择通道不变的像素融合法。本文采用双线性池化进行下采样特征图调整分辨率大小。整个特征融合计算过程如下所示:

$$F_s = \frac{1}{n} \sum_i^n B_p[F_i(x)] \quad i \in (1, n) \quad (1)$$

其中  $B_p$  表示双线性池化操作,  $F_i$  表示特征提取操作,  $i$  表示第几层,  $n$  表示 DCFNet 网络总的网络层数。将每一层网络层提取的特征图  $x$  进行双线性

池化  $B_p$ , 得到与深层网络层提取的特征图一样的分辨率。进行相加取平均,得到最后的特征图  $F_s$ 。

### 1.2 通道注意力机制模块

引入通道注意力机制模块是为了让网络更加关注特征通道之间的关系, SENet 网络为学习特征通道之间的相互依赖关系而设计,因此,本文算法在主干网络 DCFNet 网络的最后一层网络层后面引入 SENet 网络,来提升跟踪性能。SENet 网络的网络结构如图 2 所示。

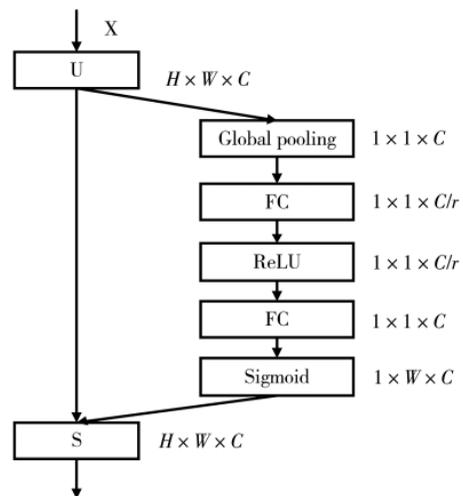


图2 SENet 的网络结构

图 2 中  $U$  为输入特征图,  $S$  为  $(H, W, C)$  维度的输出权重。SENet 网络主要包括两个操作: 压缩 (Squeeze) 操作和激励 (Excitation) 操作。压缩操作是利用全局平均池化、经过空间维度来进行的特征压缩。将原来二维特征通道压缩成一个实数, 来表示特征通道上响应的全局分布, 因此压缩之后的特征通道数不变; 激励操作由两个全连接层和一个线性修正单元 ReLU 组成。激励是通过一个  $w$  参数 (如图 2 所示) 来为每个特征通道生成各自权重, 被用来学习特征通道间的相关性。将生成的权重通过 scale 操作, 即和原特征图对应的通道的二维矩阵相乘, 达到在通道维度上对原始特征的重标定。

SENet 模块提取各个通道间的关系, 使得网络增加对信息特征的敏感性, 这些信息可以被后续转换利用, 增强 DCFNet 网络的代表性能力。

### 1.3 反向逐帧验证模块

UDT 算法的前向跟踪和后向验证是通过三帧图片来完成一次循环, 即通过第一帧去预测第二帧的目标位置, 再通过第二帧去预测第三帧的目标位置, 然后通过第三帧预测出的目标位置反向预测第一帧的目标位置, 并与第一帧原来的目标框计算一致性损失。但此举可能会造成较大的预测错误, 于是本文将第三帧目标位置先反向预测第二帧的目标位置, 再反向预测第一帧的目标位置, 最后和第一帧原来的目标框位置来计算一致性损失, 与此同时, 仍然计算第三帧预测的目标位置直接反向预测的第一帧的目标位置和第一帧原来的目标框计算一致性损失。将这两个一致性损失进行相加取平均。反向逐帧验证如图 3 所示。

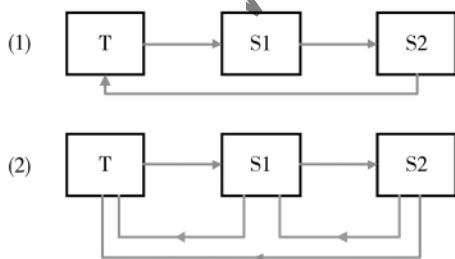


图 3 反向逐帧验证

图 3 中  $T$  为第一帧,  $S_1$  为第二帧,  $S_2$  为第三帧。图 3 中 (1) 代表 UDT 算法的多帧验证, 反向验证通过第三帧  $S_2$  直接反向预测第一帧  $T$  的目标位置。图 3 中 (2) 代表本文设计的反向逐帧验证方案,

反向验证先让第三帧  $S_3$  反向预测第二帧  $S_2$  的目标位置, 再预测第一帧  $T$  的目标位置。通过两次的反向预测可以减少反向验证轨迹上的偏移, 减小反向验证的误判概率, 提高跟踪准确性。

## 2 实验结果与分析

### 2.1 数据集设置

本文选用 ILSVRC2015 数据集作为训练数据集。在数据预处理过程中, 所设计算法不需要每一帧都有标签, 减少人力损耗。首先在每一帧中裁剪中心区域作为补丁, 补丁大小为整个图片的一半, 并调整大小为  $125 \times 125$ 。接着从连续裁剪完的 10 个补丁中随机选取三个补丁, 将其中一个补丁作为模板补丁, 其余两个补丁作为搜索补丁。本文在基准 OTB-2015 数据集下与先进的跟踪器进行测试比较。OTB-2015 数据集具有 100 个视频, 每个视频帧不仅提供了标注的目标框, 每一个视频序列还提供了不同的属性标记, 如光照变化、遮挡、形变等。

### 2.2 实验参数设置

本文实验使用动量为 0.9 的随机梯度下降 (SGD), 网络一共训练 50 个 epoch, 初始学习率设置为 102, 每 10 个 epoch 下降原来的  $10^{-1}$ , Batch Size 设为 32。所有实验都是在一台配备 4.00 GHz Intel Core I7-6700K 和 NVIDIA GTX 1070Ti GPU 的计算机上进行的。在单个 GPU 上, 本文所设计算法显示为 61FPS。在 OTB-2015 数据集上, 使用了 ROC 曲线下面积 (AUC) 作为评价指标。

### 2.3 消融实验

为了验证上述所提三种优化方案对实验结果的影响, 设计了四组实验和 UDT 算法进行对比验证, 测试结果采用 AUC 分数指标。四组实验分别在 UDT 算法的基础上加入各个模块: (1) 引入 SENet (简称 SE) 模块; (2) 引入特征融合 (简称 FU) 模块; (3) 同时引入 SENet 模块和特征融合模块; (4) 同时引入 SENet 模块、特征融合模块和反向逐帧验证 (简称 IN) 模块。实验结果如表 1 所示。

从表 1 中可以看出, 分别引入 SENet 模块和特征融合模块相比 UDT 算法在 AUC 分数上分别提高了 0.9% 和 0.6%, 表明单独加入 SENet 模块和特征融合模块, 对 UDT 算法在性能上都有一定的提升。同时加入 SENet 模块和特征融合模块, AUC 分数上比 UDT 算法高了 1.0%, 在 SENet 模块和特征融合模块同时引入的基础上, 加上提出的反向逐帧验证

表 1 各个模块对实验结果的影响

SE	FU	IN	AUC/%
			59.4
✓			60.3
	✓		60.0
✓	✓		60.4
✓	✓	✓	60.6

方案,比 SENet 模块和特征融合模块结合引入 UDT 算法的 AUC 分数提高了 0.4%,AUC 分数上比原 UDT 模型提高了 1.2%。表明本文提出的反向逐帧验证方案同样可以使 UDT 模型的性能有所上升,也表明引入三种优化方案的算法性能提升是最好的。

### 2.4 对比实验

本文对常用的有监督跟踪器和最近提出的无监督跟踪器进行了比较,主要基于孪生网络,并使用 ILSVRC2015 数据集进行训练。如表 2 所示,在 OTB-2015 基准下进行实验,评价指标包括 AUC 分数和速度(Speed)。测试结果表明,本文方法在不需要数据标签和提前预训练好模型的情况下,仍能达到与常用的有监督跟踪器相当的性能和效率。和无监督跟踪器 UDT 相比,在提升实时速度(Speed)的同时,还提高了 AUC 分数。

表 2 与其他算法对比结果

算法	AUC/%	Speed/(f/s)
CFNet <sup>[14]</sup>	56.8	65
DCFNet	58.0	70
SiamFC	58.2	86
DSiam <sup>[15]</sup>	60.5	25
MemTrack <sup>[16]</sup>	62.6	50
UDT	59.4	65
本文	60.6	61

为了测试实验结果,本文将所设计算法和 UDT 算法在 OTB-2015 数据集进行更加全面的比较实验。选取了 Biker 序列和 Blur Body 序列的结果进行比较。测试对比结果如图 4 所示。

Biker 序列实验结果中,图 4(a)显示 UDT 算法在第 69 帧视频帧开始丢失目标,后面的视频帧一直显示预测错误;而图 4(b)显示所设计算法在第 69 帧视频帧依旧准确预测目标以及目标位置,以及在后续帧中保持有效地跟踪目标;Blur Body 序列实验结果中,图 4(c)显示办公室人员从第 57 帧视

频帧已经开始出现模糊,UDT 算法在第 58 帧视频帧开始完全没有框到目标人员;图 4(d)显示本文算法在办公室人员出现模糊的情况下,仍然在第 58 帧视频帧以及后续帧中对办公室人员目标进行准确的检测和跟踪。可以看出本文算法对于目标甚至模糊的目标的跟踪效果更好。

### 3 结论

针对无监督学习的单目标跟踪任务准确性相对较低的不足,本文设计一种基于注意力机制的无监督单目标跟踪算法。首先,采用 DCFNet 网络作为主干网络,在其中每一层网络层提取特征,通过双线性池化调整分辨率进行像素特征融合,结合上下文信息,提高预测的位置准确性;在网络最后一层之后添加 SENet 模块,学习特征通道之间的关系,提高跟踪目标的性能;利用前向跟踪和设计的反向逐帧验证方法,实现无监督学习的跟踪,减少反向验证误判概率。实验表明,本文算法能够有效实现无监督单目标跟踪任务,在 AUC 分数和 Speed 指标对比中可以和有先进的无监督单目标跟踪算法相媲美,甚至与一些常用的有监督单目标跟踪算法相比,跟踪性能与实时性也更好。

### 参考文献

- [1] TAO R, GAVVES E, SMEULDERS A W M. Siamese instance search for tracking[J].2016 IEEE Conference on Computer Vision and Pattern Recognition(CVPR), 2016 : 1420-1429.
- [2] BERTINETTO L, VALMADRE J, HENRIQUES J F, et al. Fully-Convolutional siamese networks for object tracking[J].Computer Vision-Eccv 2016 Workshops, Pt II, 2016, 9914 : 850-865.
- [3] LI B, YAN J J, WU W, et al.High performance visual tracking with siamese region proposal network[J].2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR), 2018 : 8971-8980.
- [4] REN S Q, HE K M, GIRSHICK R, et al.Faster R-CNN : Towards real-time object detection with region proposal networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39 (6) : 1137-1149.
- [5] LI B, WU W, WANG Q, et al.SiamRPN plus plus : Evolution of siamese visual tracking with very deep networks[J].2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR 2019), 2019 :



(a) UDT 算法在 Biker 序列上的跟踪效果



(b) 本文算法在 Biker 序列上的跟踪效果



(c) UDT 算法在 Blur Body 序列上的跟踪效果



(d) 本文算法在 Blur Body 序列上的跟踪效果

图 4 目标跟踪效果对比

4277-4286.

[6] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[J]. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016: 770-778.

[7] WANG N, SONG Y B, MA C, et al. Unsupervised deep tracking[J]. 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR 2019), 2019: 1308-1317.

[8] WANG N, ZHOU W G, SONG Y B, et al. Unsupervised deep representation learning for real-time tracking[J]. International Journal of Computer Vision, 2021, 129(2): 400-418.

[9] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[J]. Advances in Neural Information Processing Systems 30 (NIPS 2017), 2017, 30.

[10] WANG Q, TENGZ, XING J L, et al. Learning attentions: Residual attentional siamese network for high performance online visual tracking[J]. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2018: 4854-4863.

[11] HE A F, LUO C, TIAN X M, et al. A twofold siamese network for real-time object tracking[J]. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2018: 4834-4843.

[12] HU J, SHEN L, SUN G. Squeeze-and-excitation net-

- works[J].2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR), 2018 : 7132–7141.
- [13] LIN T Y, ROYCHOWDHURY A, MAJI S. Bilinear CNN models for fine-grained visual recognition[J]. 2015 IEEE International Conference on Computer Vision (ICCV), 2015 : 1449–1457.
- [14] VALMADRE J, BERTINETTO L, HENRIQUES J, et al. End-to-end representation learning for correlation filter based tracking[J]. 30th IEEE Conference on Computer Vision and Pattern Recognition (CVPR 2017), 2017 : 5000–5008.
- [15] GUO Q, FENG W, ZHOU C, et al. Learning dynamic siamese network for visual object tracking[J]. 2017 IEEE International Conference on Computer Vision (ICCV), 2017 : 1781–1789.
- [16] YANG T Y, CHAN A B. Learning dynamic memory networks for object tracking[J]. Computer Vision–ECCV 2018, Pt Ix, 2018, 11213 : 153–169.

(收稿日期: 2022-02-25)

作者简介:

林志雄(1998-), 男, 硕士研究生, 主要研究方向: 计算机视觉、目标跟踪等。

吴丽君(1984-), 女, 博士, 副教授, 主要研究方向: 计算机视觉、机器学习、智能信号处理等。

陈志聪(1985-), 男, 博士, 副教授, 主要研究方向: 机器学习、智能信号处理等。

(上接第 42 页)

- [9] DEMAINE E D. C to Java: converting pointers into references[J]. Concurrency : Practice and Experience, 1998, 10(11–13) : 851–861.
- [10] DE ROSE L, PADUA D. Techniques for the translation of MATLAB programs into Fortran 90[J]. ACM Transactions on Programming Languages and Systems(TOPLAS), 1999, 21(2) : 286–323.
- [11] REIS L, BISPO J, CARDOSO J M P. SSA-based MATLAB-to-C compilation and optimization[C]//Proceedings of the 3rd ACM SIGPLAN International Workshop on Libraries, Languages, and Compilers for Array Programming, 2016 : 55–62.
- [12] 石学林, 张兆庆, 武成岗. 自动化的 Cobol 2 Java 遗产代码迁移技术[J]. 计算机工程, 2005, 31(12) : 67–69.
- [13] ZHAO H, PROCTOR I, YANG M, et al. The HipHop compiler for PHP[J]. ACM SIGPLAN Notices, 2012, 47(10) : 575–586.
- [14] PAULSEN G Y, FEINBERG J, CAI X, et al. Matlab2cpp: A Matlab-to-C++ code translator[C]//2016 11th System of Systems Engineering Conference(SoSE). IEEE, 2016 : 1–5.
- [15] BANERJEE P, SHENOY N, CHOUDHARY A, et al. A MATLAB compiler for distributed, heterogeneous, reconfigurable computing systems[C]//2000 IEEE Symposium on Field-Programmable Custom Computing Machines. IEEE, 2000 : 39–48.
- [16] MathWorks. MATLAB Coder[EB/OL]. (2022-01-31) [2022-02-25]. <https://ww2.mathworks.cn/products/matlab-coder.html>.
- [17] PARR T. The definitive ANTLR 4 reference[M]. Pragmatic Bookshelf, 2013.

(收稿日期: 2022-02-28)

作者简介:

余泽霖(1997-), 男, 硕士, 主要研究方向: 高性能计算。

徐云(1960-), 通信作者, 男, 博士, 教授, 主要研究方向: 并行计算、生物信息学、区块链技术。E-mail: xuyun@ustc.edu.cn。

# 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《信息技术与网络安全》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）、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！

《信息技术与网络安全》编辑部  
中国电子信息产业集团有限公司第六研究所