

基于旋转不变 Faster R-CNN 的低空装甲目标检测

曹宇剑¹, 徐国明^{1,2*}, 史国川¹

¹中国人民解放军陆军炮兵防空兵学院, 安徽 合肥 230031;

²安徽新华学院信息工程学院, 安徽 合肥 230088

摘要 对机动变换的装甲目标进行快速精确检测是低空无人机的一项重要性能要求,但目前主流检测方法自身的旋转不变性不能有效应对这一挑战。结合深度卷积神经网络(CNN)提出基于旋转不变 Faster R-CNN 的低空装甲目标检测方法,该方法在 Faster R-CNN 框架的基础上引入旋转不变层,通过在模型的目标函数上增加正则化约束条件来加强目标 CNN 特征旋转前后的不变性。实验选取三种典型的装甲目标缩比模型,在室内外模拟不同场景条件下的低空侦察环境,利用偏振高光谱相机获取目标的侦察模拟图像作为样本数据用于模型验证。在多模型对比实验中,改进模型的平均检测准确率提升了 2.4%,取得了最好的检测效果,初步验证了改进方法的有效性。

关键词 图像处理; 目标检测; 旋转不变; 卷积神经网络; 装甲目标; 无人机

中图分类号 TP391; TN911.73

文献标识码 A

doi: 10.3788/LOP55.101501

Low Altitude Armored Target Detection Based on Rotation Invariant Faster R-CNN

Cao Yujian¹, Xu Guoming^{1,2*}, Shi Guochuan¹

¹Army Artillery and Air Defense Forces Academy of PLA, Hefei, Anhui 230031, China;

²Institute of Information Engineering, Anhui Xinhua University, Hefei, Anhui 230088, China

Abstract Fast and accurate detection of maneuvering armored targets is an important performance requirement for low altitude unmanned aerial vehicles, but the rotation invariance of the current mainstream detection methods is not enough to deal with the challenge effectively. Combined with deep convolution neural network (CNN), we propose a low altitude armored target detection method based on rotation invariant Faster R-CNN. This method introduces the rotation invariant layer on the basis of the original frame of Faster R-CNN to strengthen the invariance of the target's CNN feature before and after rotation by adding regularization constraints on the objective function of the model. In the experiment, three typical models of armored target are selected to simulate the low altitude reconnaissance environment under different scenes indoors and outdoors, reconnaissance simulated images of the targets are used as sample data for model verification, which are obtained by using a polarizing hyperspectral camera. In the multi model comparison test, the improved model increases the mean average precision by 2.4% on the original basis and achieves the best test result, which preliminary verifies the effectiveness of the improved method.

Key words image processing; target detection; rotation invariance; convolution neural network; armored target; unmanned aerial vehicle

OCIS codes 100.4996; 100.3008; 100.5010

收稿日期: 2018-03-19; 修回日期: 2018-04-16; 录用日期: 2018-04-23

基金项目: 国家自然科学基金(61379105)、中国博士后科学基金(2016M592961)、安徽省自然科学基金(1608085MF140)

* E-mail: xgm121@163.com

1 引言

无人机因成本相对较低、无人员伤亡风险、生存能力强、机动性能好、使用方便等优点,开始广泛应用于军事侦察领域,多种集侦察打击于一体的无人机相继投入实战运用^[1]。在无人机侦察和攻击的目标中,装甲目标占了很大比重。对装甲目标进行快速自动检测并根据检测结果合理分配武器进行攻击,能够显著提高无人机的作战效能,因此对相应目标的检测方法进行研究和改进有着积极意义。

装甲目标主要包括坦克、输送车(AT)、突击车(AAV)、自行火炮(SPA)等类型。无人机在抵近战场执行低空侦察和打击任务时,这些高机动性目标会呈现出各种旋转角度,需要让检测方法学习到一个更强大的特征表示,即获得一个对目标的旋转不敏感的检测模型。近十几年来,国际上目标检测领域研究取得了长足的进步;Dalal等^[2]在2005年提出了方向梯度直方图(HOG)方法用于行人检测,并拓展到其他物体检测领域;Felzenszwalb等^[3]在2010年结合HOG特征提出可变形组建模型(DPM),取得了更好的检测效果,并获得了多次PASCAL VOC^[4]挑战大赛的冠军。此后,基于深度学习的目标检测方法取得了重大突破,Krizhevsky等^[5]于2012年构建深度卷积神经网络(CNN)在大规模图像分类问题上超越了传统DPM方法,取得了巨大成功,基于深度CNN发展而来的R-CNNs^[6-11]也成为目前国际领先的目标检测方法。在此基础上,国内也出现了多方面的应用研究,刘峰等^[12]利用多波段图像数据库进行CNN模型的融合训练,用于舰船检测;蔡玉柱等^[13]通过对CNN中相关层的卷积特征进行主成分分析,结合分类器来实现对目标的长期跟踪;魏湧明等^[14]建立显著地物数据集训练改进的CNN模型,用于解决无人机航拍图像的定位问题;邹焱飏等^[15]将CNN引入到焊缝检测和跟踪系统研究中,用于从噪声污染时序图像中精确焊缝位置;等等。

在之前的工作中,已初步将R-CNNs中具有代表性的Faster R-CNN^[9]和高对比度的偏振高光谱目标图像^[16]相结合,用于无人机低空目标检测任务,并在零旋转角的目标检测实验中取得了91%的最高平均检测准确率(mAP)。相比于HOG和尺度不变特征变换(SIFT)^[17]等手工提取特征方法,深度CNN能够提取更丰富的高层目标特征,在检测准确率和速度上均有很大优势,但这些高层特征仍

然不能彻底解决旋转目标的检测问题,这是因为CNN自身有限的旋转不变性是基于最大池化实现的。通常被激活的某些区域在旋转一定角度之后,仍然会受到最大池化层作用,在相同的位置产生激活区域,最大池化的尺度越大,保持特征不变性的旋转角度就越大。这种方法易导致模型过拟合,并且旋转不变性受一定的角度控制,也是检测错误的重要来源。

针对这一问题,本文以坦克等模型作为目标样例,进一步对Faster R-CNN框架进行改进,提出基于旋转不变Faster R-CNN的目标检测方法,参考文献^[18],在原框架的兴趣区域(RoI)池化层后添加旋转不变层来加强图像特征的旋转不变性,从而达到完善模型的目的。

2 目标检测框架

如图1所示,目标检测框架由数据采集、数据增强、模型训练、样本检测等阶段组成。第一阶段,利用低空目标检测模拟平台,获得目标在多场景下的偏振高光谱样本集,每个样本中含有一个目标;第二阶段,通过设置旋转角度实现数据增强,从已有数据中创造一批“新”数据来扩大样本集规模;第三阶段,结合训练样本集进行模型训练;第四阶段,利用训练好的模型结合测试样本完成目标类别判定,得到检测结果。

3 旋转不变 Faster R-CNN

Faster R-CNN采用具有平移不变性的“anchor”^[9]机制解决目标的平移和尺度变换问题,即对于图像的每一个位置,预测9个(3种尺度和3个长宽比)可能的候选窗口,这些窗口被称为anchors,这9个anchors对于任意输入的图像都是相同的,所以只需要计算一次。这种机制减小了模型参数的大小,在小数据集上降低了过拟合的风险,但对目标旋转问题并没有直接给出解决方法,因此,本文结合旋转不变层对模型的目标函数进行优化。

3.1 旋转不变目标函数

相较于最大池化层只在一定程度上兼顾目标旋转问题,旋转不变层是从问题本身进行考虑的,其作用在于通过该层的正则约束项平衡零度目标和旋转目标对模型参数的影响,确保旋转前后的样本之间能够共享相似的特征,改善模型在训练中易出现的过拟合问题,降低旋转敏感性。Cheng等^[18]通过正则约束项将旋转目标的检测正确率提高了0.7%。

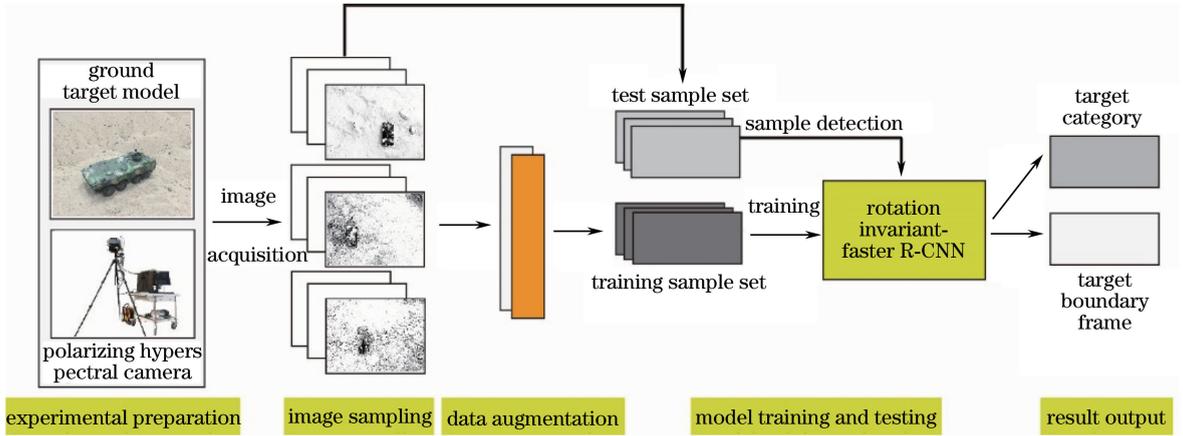


图1 目标检测框架

Fig. 1 Framework of target detection

为进一步加强检测方法的旋转不变性,在 Faster R-CNN 模型中引入一个新的旋转不变层,该层位于 RoI 层与分类器层之间,采用全连接的方式进行特征传递,如图 2 所示。

Faster R-CNN 由区域建议网络(RPN)和 Fast R-CNN^[8]结合而成,RPN 利用反向传播和随机梯度下降法^[19]进行端到端学习,并和 Fast R-CNN 一起通过交替优化来学习共享特征并训练参数。改进模型沿用了原模型的多任务损失函数,包括分类损失和边界框回归损失两个初始项,正则约束项通过新加层被整合到该函数中,形成新的目标函数,通过三个计算因子来共同完成模型参数的调节任务。现结合正则约束项对改进的目标函数加以说明。对于每一张图像,目标函数定义如下:

$$L(\{p_i\}, \{t_i\}, \{r_j\}) = \frac{1}{N_{\text{cls}}} \sum L_{\text{cls}}(p_i, p_i^*) + \frac{\lambda_1}{N_{\text{reg}}} \sum p_i^* L_{\text{reg}}(t_i, t_i^*) + \lambda_2 L_{\text{rot}}(x_j, T_{\varphi} x_j), \quad (1)$$

式中: i 是图像中 anchor 的序号; j 为初始非旋转样本图像的序号; p_i 为图像中第 i 个 anchor 是某类目标的预测概率; p_i^* 为对应的实际边界框(GT)的预测概率,如果第 i 个 anchor 边框与 GT 间的召回率(IoU)大于设定阈值上限,则将该 anchor 归为目标,即 $p_i^* = 1$,反之 IoU 低于阈值下限时,将该 anchor 归为背景,即 $p_i^* = 0$,IoU 介于阈值之间的 anchor 不参与训练; t_i 是一个向量,表示预测边界框的 4 个参数化坐标,具体为 $t_i = \{t_x, t_y, t_w, t_h\}$,前两项是边界框中心的坐标,后两项是边界框的宽和高; t_i^* 是与 anchor 对应 GT 的坐标向量; N_{cls} 和 N_{reg} 为损失项的归一化参数; λ_1 和 λ_2 是控制公式中三个因子的权衡参数。 $L_{\text{cls}}(p_i, p_i^*)$ 为类别的对数损失,计算

如下:

$$L_{\text{cls}}(p_i, p_i^*) = -\log_2 [p_i^* p_i + (1 - p_i^*)(1 - p_i)]. \quad (2)$$

$L_{\text{reg}}(t_i, t_i^*)$ 为边界框回归损失,计算如下:

$$L_{\text{reg}}(t_i, t_i^*) = R(t_i - t_i^*), \quad (3)$$

式中 R 是具有稳健性的损失函数(smooth L_1)^[8]。

$$\text{smooth } L_1(x) = \begin{cases} 0.5x^2, & \text{if } |x| < 1 \\ |x| - 0.5, & \text{otherwise} \end{cases}. \quad (4)$$

$L_{\text{rot}}(x_j, T_{\varphi} x_j)$ 为正则约束项,即图像的旋转损失,计算如下:

$$L_{\text{rot}}(x_j, T_{\varphi} x_j) = \frac{1}{2} \|O_a(x_j) - \overline{O_a(T_{\varphi} x_j)}\|_2^2, \quad (5)$$

式中 $T_{\varphi} = \{T_{\varphi_1}, T_{\varphi_2}, \dots, T_{\varphi_K}\}$ 为按角度 φ_K 进行旋转操作的集合, K 为每个图像的旋转总次数,拓展后的样本表示为 $X_{\text{RI}} = \{X, T_{\varphi} X\}$,对应的标签为 $Y_{\text{RI}} = \{y_{x_i} | x_i \in X_{\text{RI}}\}$ 。旋转不变层用 FC_r 表示, $O_a(x_j)$ 是 FC_r 层的输出,对应的参数为 (W_a, B_a) ; FC_a 层的输入层为 FC_m , $O_m(x_j)$ 是 FC_m 层的输出, m 是 Fast R-CNN 模块中 FC_r 之前所有层的数目。 $O_a(x_j)$ 通过下式计算:

$$O_a(x_j) = \kappa [W_a O_m(x_j) + B_a]. \quad (6)$$

$O_a(x_j)$ 作为训练样本 x_j 的旋转不变特征, $\overline{O_a(T_{\varphi} x_j)}$ 表示的是 x_j 旋转变体的平均旋转不变特征:

$$\overline{O_a(T_{\varphi} x_j)} = \frac{1}{K} \sum_{n=1}^K O_a(T_{\varphi_n} x_j). \quad (7)$$

在(5)式中,该项强制每个训练样本的特征更接近于它的旋转变体的平均特征表示,如果输出的是小值,则该特征表示近似于旋转变换。最后将(2)式、(3)式和(5)式代入(1)式中,得到(8)式,新定义

的目标函数不仅减少了分类损失和边界框回归的损失,还引入了正则化约束加强旋转不变性。

$$L(\{p_i\}, \{t_i\}, \{r_j\}) = -\frac{1}{N_{\text{cls}}} \sum_i \log[p_i^* p_i + (1 - p_i^*)(1 - p_i)] + \frac{\lambda_1}{N_{\text{reg}}} \sum_i p_i^* R(t_i - t_i^*) + \frac{\lambda_2}{2} \|O_a(x_j) - \overline{O_a(T_\varphi x_j)}\|_2^2. \quad (8)$$

3.2 模型检测过程

检测过程如图 2 所示。首先使用一组基础卷积/池化层提取图像的特征图,该特征图被后续 RPN 和全连接层共享,RPN 用于生成区域建议(RP),通过 softmax 分类器对参考窗口 anchors 进行二分类,判断

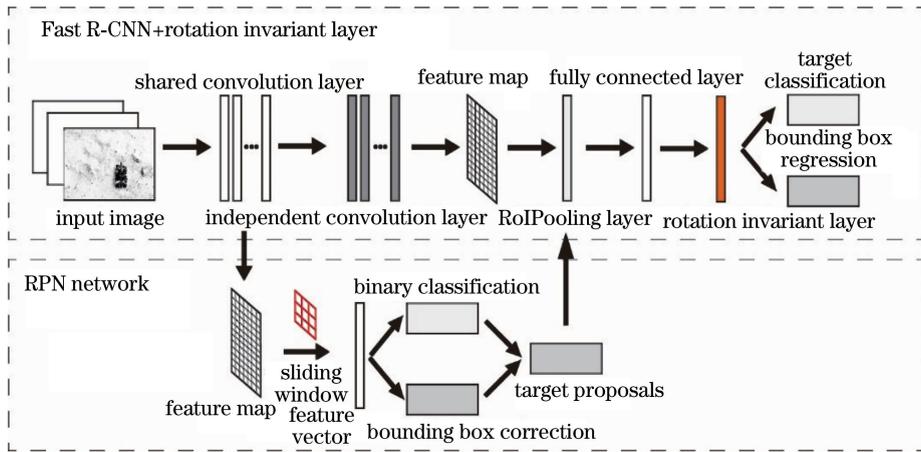


图 2 模型检测过程

Fig. 2 Model detection process

模型训练部分。输入训练样本 $X_{\text{RI}} = \{X, T_\varphi X\}$ 和 $Y_{\text{RI}} = \{y_{x_i} | x_i \in X_{\text{RI}}\}$ 之后,通过预训练的模型进行参数初始化,经过两轮训练完成参数更新。每一轮步骤相同:1) 先训练 RPN 网络;2) 通过 RPN 网络获取 RP;3) 结合 RP 第一次训练 Fast R-CNN 模块;4) 计算(8)式目标函数;5) 更新模型参数;在未达到停止标准前,重复 3)~5)的操作。两轮训练完成后输出模型参数。

目标检测部分。首先,输入地面目标样本的偏振高光谱图像;然后,通过一个包括基础的卷积、修正线性单元(ReLU)和池化层的组合来提取目标图像的特征图,通过 RPN 网络生成 RP,结合 RP 对特征图进行 RoI 池化操作,修正建议特征图,将建议特征传递给旋转不变层,判定目标类别,并通过边界框回归计算目标边界框的位置;最后,输出目标类别和边界框。

其属于目标或者背景,再利用边界框回归修正 anchors 获得精确的区域建议。RoI 池化层收集输入的特征图和区域建议,综合这些信息提取建议特征图,送入后续的旋转不变层,再经全连接层传递给 softmax 分类器,由分类器计算建议的类别,同时再次进行边界框回归,获得检测框最终的精确位置。

3.3 目标检测算法

目标检测框架由模型训练和模型检测两部分组成。模型首先在数据集 ImageNet^[20] 上进行预训练,预训练网络为 ZF^[21],然后使用本文数据集进行参数微调;模型训练完成后,使用样本图像进行目标检测,通过网络模型提取建议特征进行分析并得到结果,包括图像中目标的类型和位置。结合模型检测过程将改进模型的相关算法描述如下。

4 实验测试

4.1 实验说明

实验在全场景仿真实验室内模拟某型无人机对地面装甲目标进行低空侦察,获得数据样本后进行模型训练。图像采集设备和车辆模型如图 3 所示。检测模型最终大小约 12 GB,参数数量约 6240 万,训练时间约 10 h,内存需求 16 GB,显存需求 3 GB。根据模型规模需求,选取戴尔 Precision Tower 5810 工作站搭建训练平台,主要参数:Inter(R) Xeon(R) E5-1660 v4 3.2 GHz,32.0 GB RAM,8 GB SGRAM,两台 Quadro P4000(8 GB GPU 内存),模型训练环境为 Visual Studio 2013 + Cuda6.5 + MatLab(R2016a),训练过程中的部分参数设置如表 1 所示。

4.2 实验数据准备

图像采集工作在草地、土地、沙漠等模拟场景中

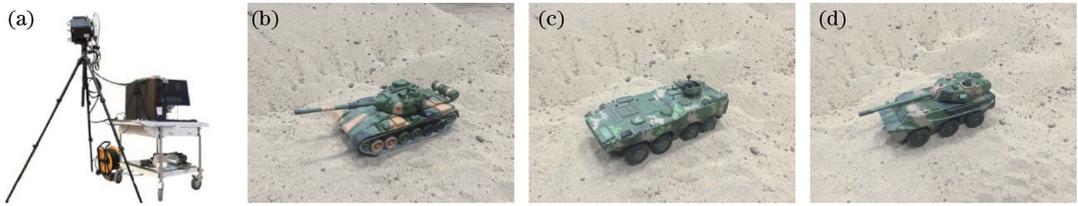


图3 图像采集设备和车辆模型。(a)偏振高光谱相机;(b)坦克;(c)输送车;(d)突击车

Fig. 3 Image acquisition equipment and vehicle models. (a) Polarizing hyperspectral camera; (b) tank; (c) AT; (d) AAV

表1 模型训练参数设置

Table 1 Parameter setting of model training

Model parameter	Parameter value
Mini-batch	256
Maximum threshold	0.7
Minimum threshold	0.3
Rotation invariant layer learning rate	0.01
Network tuning learning rate	0.0001
Network momentum	0.9
Weight decay	0.0005
λ_1	1
λ_2	0.001

进行,并参照 VOC 格式制作数据集样本。为降低数据规模,首先选取较为单一的姿态,即零旋转角度采集图像,获得不同场景下的 3600 个训练样本,测试样本为 600 个任意角度下获取的目标图像。通过数据增强的方法进行训练集扩充,对每个训练样本按照 $\varphi = \{\pm 20^\circ, \pm 45^\circ, \pm 60^\circ\}$ 进行 6 次旋转变换,旋转操作采用函数编码对图像进行指定角度的旋转批处理。同时为去除旋转后出现的黑色三角区块,对每个三角区块利用其对应的矩形区中另一半的背景中值进行填充,改善样本效果,如图 4 所示。

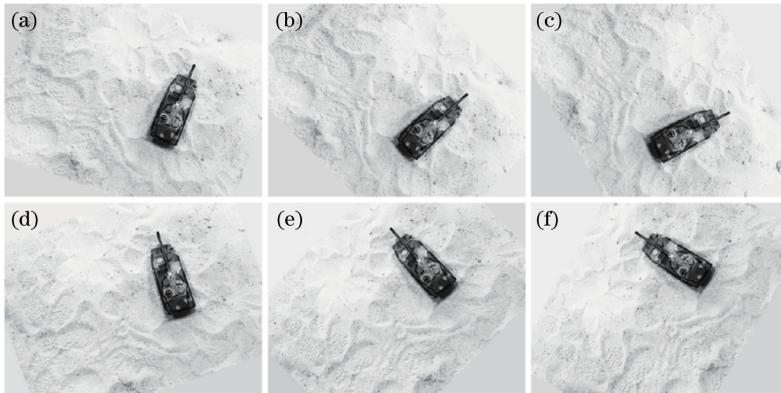


图4 样本多角度旋转扩充。(a) 20°;(b) 45°;(c) 60°;(d) -20°;(e) -45°;(f) -60°

Fig. 4 Multi angle rotation expansion of sample. (a) 20°; (b) 45°; (c) 60°; (d) -20°; (e) -45°; (f) -60°

4.3 实验结果比较和分析

与初始模型相比,本文方法在 VOC 2007 标准数据集中将 mAP 提升了 1.1%。在偏振高光谱数据集中,采用纵向和横向对比相结合的方法对本文方法的性能进行更具体的验证。纵向对比,由 Faster R-CNN 和改进模型分别对旋转目标进行检测;横向对比,将相同的目标样本运用于其他模型方法,包括 R-CNN、Fast R-CNN、R-FCN 等同类主流检测模型。每一组实验中,每类目标分 10 组,每组 20 个样本依次进行检测。如图 5 所示,图 5(a)~(e)分别对应 5 组模型方法的检测结果。

表 2 汇总了各模型在本次实验中的正确率。纵

向对比中,在对旋转的目标进行检测时,本文方法的 mAP 较 Faster R-CNN 模型提升了 2.4%,并且边界框的标定效果更好,说明单靠 CNN 模型自身的旋转不变性不能完全满足需要,增加的旋转不变层进一步巩固了模型对目标旋转的稳健性。横向对比中,R-CNN、Fast R-CNN、R-FCN 模型对旋转目标的检测分别取得了 82.1%、87.9%、89.6% 的 mAP,相比之下,本文方法取得了最好的结果,表明与其他模型相比,本文方法对旋转目标具有更好的检测性能。

5 结论

将人工智能引入到无人机侦察打击领域,是未

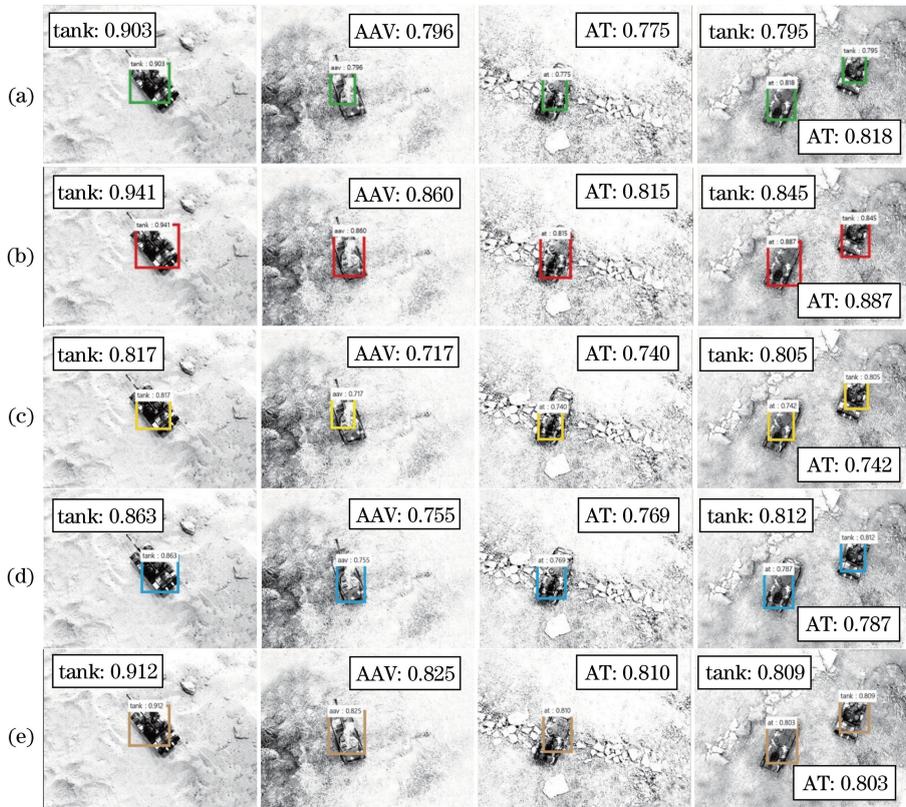


图5 不同方法的检测效果对比。(a) Faster R-CNN;(b)本文方法;(c) R-CNN;(d) Fast R-CNN;(e) R-FCN

Fig. 5 Comparison of detection results by different methods. (a) Faster R-CNN; (b) proposed method; (c) R-CNN; (d) Fast R-CNN; (e) R-FCN

表2 不同方法的检测准确率

Table 2 Detection precision of different methods

Model	Tank	AT	AAV	mAP
Rotating target+Faster R-CNN	89.9%	87.9%	88.5%	88.7%
Rotating target+proposed method	92.3%	89.5%	91.1%	91.1%
Rotating target+R-CNN	82.3%	81.5%	82.4%	82.1%
Rotating target+fast R-CNN	87.8%	86.9%	89.1%	87.9%
Rotating target+R-FCN	90.1%	88.9%	89.7%	89.6%

来无人作战样式的发展趋势之一。在不断变化的战场环境中对各种形态的装甲目标进行快速识别和攻击是无人机目标检测的重要性能指标。本文在早期实验的基础上通过引入旋转不变层对 Faster R-CNN 进行改进,在对选取的三类典型装甲目标的检测中初步验证了改进方法的有效性。需要指出的是,深度学习模型的使用需要大量的训练数据支持,在不增加数据规模的情况下,通过更充分地利用目标的多维度特征进一步提升检测效果,有助于减小样本数据规模和提升准确率,相关工作正在进行中。

参 考 文 献

[1] Jiang C S. Key technologies for integrated

reconnaissance and attack system of UAVs [J]. *Electronics Optics & Control*, 2011, 18(2): 1-7.
姜长生. 无人机侦察/打击一体化的关键技术[J]. *电光与控制*, 2011, 18(2): 1-7.

[2] Dalal N, Triggs B. Histograms of oriented gradients for human detection [C] // *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2005: 886-893.

[3] Felzenszwalb P, Mcallester D, Ramanan D. A discriminatively trained, multiscale, deformable part model [C] // *IEEE Conference on Computer Vision and Pattern Recognition*. IEEE, 2008:1-8.

[4] Everingham M, van Gool L, Williams C K I, *et al.* The pascal visual object classes (VOC) challenge[J]. *International Journal of Computer Vision*, 2010, 88

- (2): 303-338.
- [5] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks [C] // Advances in Neural Information Processing Systems, 2012: 1097-1105.
- [6] Girshick R, Donahue J, Darrell T, *et al.* Rich feature hierarchies for accurate object detection and semantic segmentation [C] // IEEE Conference on Computer Vision and Pattern Recognition, 2014: 580-587.
- [7] He K M, Zhang X Y, Ren S Q, *et al.* Spatial pyramid pooling in deep convolutional networks for visual recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37(9): 1904-1916.
- [8] Girshick R. Fast R-CNN [C] // IEEE International Conference on Computer Vision, 2015: 1440-1448.
- [9] 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.
- [10] Dai J F, Li Y, He K M, *et al.* R-FCN: object detection via region-based fully convolutional networks [C] // Advances in Neural Information Processing Systems, 2016: 379-387.
- [11] He K, Gkioxari G, Dollár P, *et al.* Mask R-CNN [C] // IEEE International Conference on Computer Vision, 2017: 2980-2988.
- [12] Liu F, Shen T S, Ma X X. Convolutional neural network based multi-band ship target recognition with feature fusion[J]. Acta Optica Sinica, 2017, 37(10): 1015002.
刘峰, 沈同圣, 马新星. 特征融合的卷积神经网络多波段舰船目标识别[J]. 光学学报, 2017, 37(10): 1015002.
- [13] Cai Y Z, Yang D D, Mao N, *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.
- [14] Wei Y M, Quan J C, Hou Y Q Y. Aerial image location of unmanned aerial vehicle based on YOLO v2[J]. Laser & Optoelectronics Progress, 2017, 54(11): 111002.
魏湧明, 全吉成, 侯宇青阳. 基于 YOLO v2 的无人机航拍图像定位研究 [J]. 激光与光电子学进展, 2017, 54(11): 111002.
- [15] Zou Y B, Zhou W L, Chen X Z. Research of laser vision seam detection and tracking system based on depth hierarchical feature [J]. Chinese Journal of Lasers, 2017, 44(4): 0402009.
邹焱飏, 周卫林, 陈向志. 基于深度分层特征的激光视觉焊缝检测与跟踪系统研究 [J]. 中国激光, 2017, 44(4): 0402009.
- [16] Ma W J. Research on multi-dimensional information extraction and object detection algorithms of polarized hyperspectral images [D]. Harbin: Harbin Institute of Technology, 2014.
马文静. 偏振高光谱图像多维度信息提取及目标检测算法研究 [D]. 哈尔滨: 哈尔滨工业大学, 2014.
- [17] Lowe D G. Distinctive image features from scale-invariant keypoints [J]. International Journal of Computer Vision, 2004, 60(2): 91-110.
- [18] Cheng G, Zhou P C, Han J W. RIFD-CNN: Rotation-invariant and Fisher discriminative convolutional neural networks for object detection[C]//IEEE Conference on Computer Vision and Pattern Recognition, 2016: 2884-2893.
- [19] LeCun Y, Boser B, Denker J S, *et al.* Backpropagation applied to handwritten zip code recognition[J]. Neural Computation, 1989, 1(4): 541-551.
- [20] Deng J, Dong W, Socher R, *et al.* ImageNet: a large-scale hierarchical image database [C] // IEEE Conference on Computer Vision and Pattern Recognition, 2009: 248-255.
- [21] Zeiler M D, Fergus R. Visualizing and understanding convolutional networks[C]//European Conference on Computer Vision, 2014: 818-833.