

深度学习技术在雷达目标检测中的研究进展



宋婷^{1,*}, 贺丰收^{1,2}, 程宇峰¹

1. 航空工业雷华电子技术研究所 航空电子系统射频综合仿真航空科技重点实验室, 江苏 无锡 214063

2. 西北工业大学, 陕西 西安 710129

摘要: 随着对航空科技水平需求的不断提升, 人工智能技术为该领域突破发展提供了可能。其中, 深度学习作为一种人工智能的技术方法, 在诸多方面展现出巨大的优势而受到广泛研究和关注。针对雷达目标检测而言, 深度学习方法是数据驱动的方式, 建立端对端网络, 避免人工提取特征表达力不足, 实现优越检测的性能, 因此在雷达领域受到越来越多的关注和研究。本文首先介绍了雷达目标检测领域相关知识, 指出传统检测方法的局限性; 然后对目前深度神经网络检测经典方法进行了分析和归纳, 重点介绍了深度神经网络在雷达目标检测中的研究现状; 最后对深度学习在雷达目标检测领域应用中存在的技术挑战进行了分析, 并就未来相关技术的发展趋势进行了展望。

关键词: 深度学习; 雷达目标检测; 深度神经网络; 时序信号检测; 时频域信号检测

中图分类号: TN953

文献标识码: A

DOI: 10.19452/j.issn1007-5453.2020.10.003

雷达具有全天候、全天时、作用距离远等特点, 可以对环境和目标进行监测。雷达工作在探测模式下, 可对照射区域的回波进行分析处理, 从杂波、干扰、噪声等信号中检测到目标信息, 并确定其距离、速度、角度等信息^[1]。由于雷达检测技术跟任务和应用场景紧密相关, 以机载雷达为例, 目前机载雷达主要采用脉冲多普勒体制, 能够适应对空、对海和对地探测任务, 完成目标检测处理, 提取目标信息。当机载雷达执行对空目标探测时, 主要通过相参积累提高目标信杂噪比后, 再进行恒虚警(CFAR)检测; 当执行对海搜索任务时, 可通过非相参积累实现目标检测; 当执行对地观测任务时, 通过宽带成像功能的雷达还可以获取目标高分辨距离像(HRRP)数据和合成孔径雷达(SAR)成像, 针对HRRP和SAR图像实现目标检测功能。

近年来, 雷达目标检测技术日臻成熟。现有的目标检测主要采用目标先积累后检测的方法和杂波抑制后检测的方法。仅积累目标能量后检测方法适用于均匀杂波、噪声

场景, 然而, 针对复杂杂波场景下目标检测方法^[2-3], 往往需要先估计杂波分布特性, 如空时二维自适应处理(STAP), 获取待测距离单元杂波同分布特性的杂波样本, 通过空、时域加权在待测目标通道形成杂波凹口实现杂波抑制。但由于目前杂波环境复杂性, 传统杂波协方差估计难以获取足够独立同分布样本, 使得复杂杂波抑制效果欠佳, 目标检测能力受限。

2012年, 在ImageNet竞赛上, 深度学习方法以绝对优势获得冠军, 其中, 卷积神经网络(CNN)由于其强大的特征提取能力受到广泛关注。1998年, Y. Lecun^[4]等提出LeNet-5网络作为CNN最经典的网络结构实现文本识别, 而后发展到2015年Ross B. Grishick提出的Faster R-CNN^[5]两阶段检测网络, 以较高的准确率实现自动目标检测。2018年, Joseph Redmon提出的YOLOV3^[6]端到端检测模型, 以其出色的实时检测速度成为目前开源主流检测算法之一。除此之外, 还有基于针对数据重构的自编码器(AE)^[7]系列、基于

收稿日期: 2020-07-23; 退修日期: 2020-08-25; 录用日期: 2020-09-21

基金项目: 航空科学基金(20172007002)

*通信作者: Tel.: 15261597156 E-mail: tiansongting@163.com

引用格式: Song Ting, He Fengshou, Cheng Yufeng. Research progress of deep learning technology in radar target detection[J]. Aeronautical Science & Technology, 2020, 31(10): 12-20. 宋婷, 贺丰收, 程宇峰. 深度学习技术在雷达目标检测中的研究进展[J]. 航空科学技术, 2020, 31(10): 12-20.

概率生成模型的深度置信网络(DBN)^[8]等,在序列信号处理领域有着广泛的应用。随着深度学习技术在图像识别、语音处理、优化决策领域的卓越表现,目前许多研究学者利用深度学习技术在雷达中展开研究,主要的研究领域包括:采用卷积神经网络等进行自动目标识别(ATR)^[9-12],采用深度神经网络(deep neural network, DNN)进行微动多普勒分类^[13],采用深度学习方法进行雷达对抗环境下的作战意图分析^[14-15]等。基于深度学习的雷达目标检测方法是数据驱动的形式,利用深层神经网络对特征的高维空间表达提取有效信息,建立从输入数据到输出检测结果的端对端网络,避免了人工提取特征和建模方法表达力不足的问题,在有效训练数据充足的前提下,网络在定位、分类等问题上的准确性能相比传统网络有着显著提升。本文主要利用深度学习技术解决雷达目标检测的问题。

1 目标检测现状

雷达目标检测任务可以分解为两个部分:雷达目标分类和目标定位。雷达目标分类需要判断输入数据是目标还是杂波、干扰,目标定位需要解算输入数据的位置。以空探测为例,雷达目标检测会在雷达多普勒-距离维回波中标注出目标所在距离门和频率门,同时将目标功率、信噪比、雷达截面积(RCS)、角度、速度等信息存储在目标列表中,便于后续进行目标跟踪、识别。

1.1 传统雷达目标检测方法

以相控阵雷达目标检测^[1]为例,针对相控阵雷达的回波数据,先对其进行相参/非相参积累和相关滤波处理,尽可能滤除噪声,抑制杂波,然后根据某些准则(如奈曼-皮尔逊准则),对每帧回波设置固定或自适应检测门限,将超过检测门限的数据输出得到检测结果,如图1所示。



图1 传统雷达目标检测处理流程

Fig.1 Traditional radar target detection process

近年来,隐身、高机动目标的出现,给传统雷达检测带来了巨大的挑战,同时传统检测方法在处理经典应用场景(如对海探测等)时,相关的性能输出指标已经逼近技术上限,存在明显的瓶颈,亟待突破。主要表现在:(1)现代雷达信号理论基本还是遵循平稳信号的处理模型,在非平稳信号(杂波)场景下的应用存在技术瓶颈;(2)只利用单个频率和距离单元的孤立处理方法,如经典的恒虚警检测技术,并

未涉及目标高机动时速度变化和距离门走动等。

针对雷达高速弱小复杂环境下的目标检测,非平稳现象对目标积累带来的影响会严重影响传统方法的检测性能。

当前机载雷达对海面目标检测方法主要针对海杂波分布模型假设,用统计模型描述海杂波分布进行检测。基于分布模型的方法核心在于以实际数据和假设模型高拟合度为前提^[16]。但受实际海情影响,模型方法对数据描述精确度不够,限制了对海目标检测性能的提升。

1.2 基于深度学习的目标检测方法

基于深度学习(deep learning)的目标检测流程如图2所示。

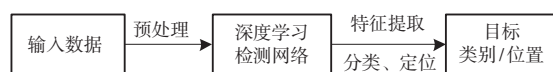


图2 基于深度学习的目标检测流程

Fig.2 Radar target detection process based on deep learning

深度学习是基于人类大脑的认知结构发展出来的一种机器学习方法,相比于传统的机器学习算法(浅层学习),其算法通过多层的非线性变换,能够由低层到高层逐层提取越来越抽象的特征,从而能够通过大量的训练数据学到高层的可分特征。深度学习检测网络则是利用多隐层神经元,对输入数据进行特征学习,用以区分目标和背景信息的深层网络结构,可实现复杂的检测任务。深度堆叠自动编码器的深层网络结构如图3所示,其中包含多个隐藏层结构 h_1, h_2, h_3 ,可以逐层提取输入信息 x 的抽象隐式特征。




图3 深度自动编码器结构示意图

Fig.3 SAE networks' structure

在复杂非平稳环境中,以复杂海况下的目标检测为例,传统基于海杂波分布模型的假设不成立,传统目标检测方法性能受限,采用深度学习的目标检测方法,不基于固定模

式下的海杂波分布,而是从海面目标和背景数据差异性出发,借助充足的不同海况下的标记数据作为网络输入,构建最大化区分背景和目标的代价函数,利用深层神经网络对数据进行学习,每一层得到非显性的数据特征表达;同时利用监督训练的方法,将误差反向传递实现网络权值的调优,使得网络输出与期望值更加接近。

通过对网络框架、层级结构、代价函数、网络训练、调优方法等的确立,在大量数据样本的支撑下,深度神经网络可实现对复杂海情海况数据下目标信息和背景杂波的高层特征抽象表达,输出为目标有无,如果检测出目标还将进一步给出目标位置信息。

基于自动特征提取的深度学习方法为复杂环境中的目标检测提供了全新的思路。深度学习基于大数据,利用深层感知网络构建模型,充分提取输入信息的深层抽象特征,避免了过度依赖人工经验手动提取特征,可以对数据中潜在特征进行挖掘。因此,本节针对现有典型的深度学习目标检测模型进行归纳介绍。

目前基于目标检测的深度网络模型可以分为基于CNN及其变体的目标检测网络,如根据回归方法的YOLO^[17]—阶段系列检测网络,根据分类方法的R-CNN^[18]二阶段系列检测网络;基于数据重构的自编码器(AE)网络;基于概率生成模型的深度置信网络(DBN)等。由于目标检测问题可以转化为目标和背景的二分类问题,因此采用深度学习分类模型也可在一定问题场景下实现目标检测的功能。

1.2.1 CNN检测模型

CNN网络作为主流的检测算法,可以达到较高的检测准确率。传统CNN网络是LeCun提出的LeNet-5模型,如图4所示,网络一共有7层,主要包含输入层、卷积层、池化层、全连接层以及输出层。卷积层主要用来提取特征,通过多个卷积核实现不同特征的映射图,其中参数共享机制减少了网络的模型复杂度,使网络更容易训练;池化层采用最大池化或平均池化方法,对输出特征图进行降维操作,使得

网络具有更好的鲁棒性;通过激活函数使得网络具有非线性逼近能力,更容易学习到高维抽象特征,因而具有良好的分类能力。

以卷积为核心发展起来的深度检测网络,其中具有代表性算法为基于候选窗口的卷积神经网络方法RCNN^[18],以RCNN为基础又发展出了faster-RCNN,如图5所示。Ren等提出Faster-RCNN^[15]实现了区域候选框和CNN网络分类的端到端目标检测模型,在VOC07上的mAP=73.2%,在COCO上mAP=42.7%。




图5 Faster-RCNN目标检测网络

Fig.5 Faster-RCNN target detection networks

RCNN系列方法在目标检测中可以得到较高的检测准确度,但是计算速度慢,缺乏实时性。基于One-Stage的YOLO目标检测框架、SSD检测框架在输入图像上直接得到该位置的目标边框和目标类别。R.Joseph于2015年提出YOLO^[17]网络模型,通过将图像分割成多个网格,每个网格对应多个边界框,通过回归预测每个网格的边界框位置和类别位置,以及目标置信度分数,采用非极大值抑制(NMS)设置阈值得到最终的检测结果。W. Liu^[19]等提出了SSD网络,使用多尺寸特征图提取特征和多个anchor boxes进行边界框坐标偏差和类别置信度预测,比YOLOV系列^[20-21]更适合检测多种尺寸的目标,SSD方法检测性能与FasterRCNN相当但速度比YOLO更快,在VOC07数据集上的mAP=76.8%。

1.2.2 AE检测模型

自编码器(AE)是一种无监督学习方法,通过用于提取特征的编码器结构和用于重构的解码器组成。输入数据经过隐含层特征学习,然后经过解码器得到网络输出,自编码器通过学习一个恒等映射,让输出逼近输入实现对数据内部隐藏特征的学习。2006年,Hilton对自动编码器进行改进,提出深度自编码器^[22],先用无监督逐层贪心训练算法完成对隐含层的预训练,然后采用BP算法对整个




图4 LeNet-5网络结构

Fig.4 LeNet-5 networks' structure

神经网络进行参数优化调整,有效改善了BP算法容易陷入局部最优的问题。稀疏自编码器^[23]核心是采用最少的隐藏单元表示输入层的特征,采用KL距离设置稀疏代价函数,使得隐藏单元平均激活值接近于0,通过压缩原始信号的维度得到输入特征的稀疏表示。降噪自编码器^[24]一定程度解决了自编码器原始数据重构的敏感性,又对训练数据不够敏感,可以略微破坏输入数据,但仍维持未损坏的数据维作为目标输出。通过在训练过程中增加噪声提升模型的抗噪性能。

通过对深度神经网络CNN和其变体网络、AE系列等检测模型的分析 and 梳理,可对雷达时间维-频率维-空间维的数据进行分析,以便于针对雷达数据的特点,对网络进行优化或改进,使其适合于对雷达序列数据、雷达时域-频域数据、雷达图像数据等的处理。

2 基于深度学习的雷达检测应用

上一节对目前典型的深度学习目标检测网络的处理过程进行了介绍,在此基础上分析了深度学习相关算法在雷达目标检测上的应用,通过与传统方法相比,深度学习目标检测性能有着显著的优势。

不同于光学图像处理过程,基于深度学习的雷达目标检测方法,需要对雷达信号进行解析,利用雷达信号在空间域、时间域、频率域的特性,针对不同雷达应用场景构建合适的深度神经网络实现雷达目标检测。雷达目标检测从检测环境上可以分为均匀环境,如噪声中的目标检测和复杂环境如非均匀杂波下的目标检测;从研究对象上可以为针对二维图像(如SAR图像、时域-频域(R-D)图等)以及一维序列信号(如单一频率维信号、目标高分辨距离像HRRP信号)下的检测。本节从研究对象输入角度出发,结合雷达处理流程,对深度学习针对雷达目标检测的可行性、应用情况和与传统方法结果对比等方面进行介绍。

2.1 雷达时域-频域(R-D)上的检测

雷达回波在快时间域经过脉压后,可获得目标距离维信息,再通过对各距离单元慢时间域FFT处理,可以得到回波的多普勒域信息,即目标在距离-多普勒域的能量分布情况,可称为R-D谱。可针对雷达R-D谱图开展目标检测研究。

雷达目标检测问题可以当成是目标和杂波(噪声)背景的二分类问题。Wang等^[25]在此基础上进行深度神经网络的雷达检测。作者利用R-D图中包含目标回波和不含目标回波的差异性,网络输入是雷达R-D谱域的切片,分为

包含目标和噪声的切片和不包含目标的噪声切片,切片以图像形式输入,大小根据滑窗尺寸决定,根据一致性检测理论,输入数据层级数跟相关脉冲串的数量相同。设置CNN网络结构包含两个卷积层、两个Relu层、两个最大池化层和两个全连接层。最后一层的全连接层采用softmax得到目标二分类结果,代表输入目标切片中包含目标与否。利用CNN网络实现有目标回波和无目标回波的二分类,可以替代完成CFAR的功能。最后通过仿真数据对试验提出模型进行验证,发射信号为线性调频信号,幅度为0均值高斯随机噪声环境,检测结果优于传统CFAR检测结果。

参考文献[26]通过构造卷积层、池化层和全连接层,采用CNN实现人的检测和人的动作识别。检测网络可实现对人、动物、车等目标进行分类,从而检测人是否存在,检测概率97.6%。

Su^[27]等提出采用深度学习进行海面目标分类,也是将目标检测问题转化成分类问题。由于海面目标运动体现在雷达回波的多普勒谱中,可由平动分量和多普勒微动分量构成,而微动分量的谱特性可以对目标进行分类。因此,通过构建非均匀平动、三坐标下的转动等目标运动模型,对雷达回波时-频谱信息进行分析,将雷达回波谱作为输入图像,利用LeNet等深度神经网络有效提取目标微动特性,在威布尔杂波环境下实现目标分类。检测结果受目标信杂噪比的影响较大,当杂波强度较大时,需要采用一些杂波抑制方法才能提升检测性能,一定程度上解决了杂波环境的海面目标检测问题。

Rodrigo等^[28]提出一种采用YOLO网络进行检测识别一体化的方法。先对激光雷达回波数据转换为距离-多普勒谱信息,将功率谱取dB后转化为灰度图作为输入;再利用OSCA-CFAR检测器在速度维对目标进行标注,同时,目标先验框的位置标注是通过摄像机和激光雷达融合自动标注后投影至雷达谱上得到的;通过对目标在不同物理位置的数据,输入YOLOV3深度检测网络中进行训练,最终在城市交通复杂环境下完成对行人、汽车、自行车的实现检测和识别,当IoU=0.5时mAP性能为70%左右。

上述文献在噪声、杂波等环境中实现了R-D域目标图像的检测,将检测问题转化为分类问题,为雷达在信号级的检测进行了一定程度的探索。针对均匀环境下的目标检测,受信噪比影响较低,可通过深度学习对样本之间相关性的学习额外获得略优于传统检测方法的性能。然而在实际雷达工作环境中,情况可能较为复杂。如非均匀杂波环境下,离散杂波容易过门限而造成虚警,甚至当散射区域杂波

强度较大时,目标很容易被杂波淹没,这种情况下传统方法难以有效检测。可以利用深度学习方法对数据中隐含特征的提取,从目标和杂波回波信号可分性方面入手,探索低信杂噪比环境下目标检测问题;同时,可对雷达R-D谱域数据划分为目标、杂波、干扰、噪声等切片,并利用领域知识进行数据标记,采用深度分类网络可实现对雷达复杂环境中的精细化检测。因此,如何在复杂强杂波环境中进行目标检测仍需要进一步研究难题。

2.2 SAR检测技术

涂松^[29]利用深度SAE网络实现大尺寸SAR图像目标的快速提取。先针对大尺寸SAR图像进行显著性区域检测,得到目标和背景杂波,然后构建三层深度自编码器实现对背景下车辆的检测。Wang^[30]等构建CNN网络,对海面多个场景进行学习和特征提取,测试阶段从海杂波场景下检测出舰船目标。由于缺少不同姿态下的舰船数据,因此CNN网络针对不同姿态的海面目标检测能力还需要进一步提升。

由于缺少有效的带标签数据,针对城市变化检测问题很难通过目前的监督学习方法实现。De^[31]等通过SAE网络小样本数据情况下,相比传统方法,在降低虚警率的前提下,检测概率达到92%左右。Jiao^[32]等针对多场景下SAR舰船数据,采用特征映射和高分辨率特征融合的方法,构建基于Faster RCNN的多尺度密集网络实现舰船检测。Zhao^[33]等基于Faster RCNN提出目标检测网络,在多尺度特征图基础上提取目标候选区域,可针对不同尺寸的目标实现有效检测。杜兰^[34]等利用迁移学习的思想,结合数据扩充技术,提出一种基于Faster RCNN的目标检测方法。利用完备数据集训练得到的卷积神经网络模型参数,迁移到Faster RCNN网络中,在miniSAR公开数据集上可获得比传统CFAR更好的检测性能。Yang^[35]等针对舰船目标检测算法检测精度易受斑点噪声影响,且只能提取底层特征及其泛化性较差的问题,提出了一种基于深度卷积神经网络的SAR图像舰船目标检测算法,相比于原始的SSD检测算法,所提出的方法不仅提高了目标检测精度,同时也保证了算法的检测效率。Liu^[36]等基于SSD模型的目标检测方法,在复杂场景中获得比Faster RCNN更好的检测性能。图6为强杂波背景下的目标检测。

Wang^[37]通过迁移学习解决SAR训练数据有限的问题,通过构建类似于SSD网络的深度学习框架,采用多尺度特征图和卷积网络进行船舶目标检测。Cui^[38]等针对大场景下SAR检测问题,结合YOLO深度学习检测思路,先在大



图6 强杂波背景下的目标检测

Fig.6 Target detection in the background of strong clutter

场景上进行滑动分割得到多个区域,再进行区域间的非极大值抑制方法优化目标候选区域,最终输出最佳目标的定位,有效实现大场景下的目标快速检测问题。Khan^[39]、Chang^[40]等针对SAR图像舰船目标检测,利用YOLOV2深度学习网络,达到较好的检测效果。Hu^[41]等针对复杂目标背景下舰船目标检测难题,重新设计残差网络单元,提出了改进特征金字塔网络结构的方法,并引入平衡因子优化损失函数中的小目标权重。试验结果相比原始YOLOV3方法在公开数据集上提升了F1值,并可实现实时SAR目标检测问题。

2.3 雷达一维序列上检测

Liu等^[42]采用卷积神经网络对雷达一维序列信号进行处理,通过对雷达背景的分类为雷达自动检测提供基础。与目前针对雷达SAR图像,雷达R-D域图像开展的检测研究相比,针对一维雷达信号处理来提升目标自动检测性能的研究相对较少。作者针对雷达的杂波和噪声背景进行分析,说明了LeNet网络在一维序列信号中对杂波和噪声分辨的可行性,通过分别构建雷达杂波、噪声在时域回波幅度,频域的谱幅度对应的一维信号数据集,采用卷积神经网络对杂波、噪声数据进行分类,讨论了数据预处理方式、输入时序信号的长度、网络参数设置对场景分类的影响。通过对雷达杂波、噪声的一维序列数据进行分类,后续可对目标场景杂波进行精细化研究,设置不同的杂波抑制方法以实现目标高效检测。

各类针对雷达回波域的深度学习目标检测方法,主要通过噪声、杂波、复杂场景中对雷达海面、地面、空中目标进行检测,通过对雷达数据进行预处理,使深度神经网络能够对输入数据进行特征学习,并通过优化网络结构获知雷达目标、杂波、噪声之间的差异,说明了深度学习在雷达检测领域的可行性和有效性。

3 面临挑战和发展展望

(1) 雷达数据自动标注

雷达数据由于与光学数据存在较大差异,光学数据已经有较为成熟的自动化标注软件,并且有公开的数据集可以对网络进行初始化训练。然而针对雷达领域而言,目标数据的标注还大量依赖专业信号信息处理领域从业者,并且雷达目标数据与发射的极化方式、照射场景环境、目标姿态信息等相关性较大,因此,如何针对数据进行自动化标注,是提升深度学习应用的基础。

针对该问题,利用深度学习的初步检测结果,是否可实现对数据的粗标注,再利用人工对标注结果进行错误纠偏和筛查,借助深度学习工具实现数据标注到检测的互优化,值得进一步研究。

(2) 小样本条件下的稳健检测

军事领域非合作目标获取存在一定难度,本质上和合作目标散射特性差异不大,但是相关数据样本缺乏。所以在雷达军事领域面临自动标注和小样本数据的难题。

针对该难题,一方面通过对目标和环境特性的研究,可以利用仿真数据弥补训练样本的不足,一定程度上可以缓解小样本问题;另一方面,迁移学习方法,通过领域知识,找出源数据集目标数据集之间在特征空间的相关性,针对源域任务的知识来提升目标域函数的求解性能。

(3) 复杂作战环境下目标检测

由于作战样式、作战环境的改变,雷达目标检测在复杂作战环境下检测难度大大提升。如目标大机动时探测盲区的稳定检测跟踪、主瓣干扰存在下的目标检测等,都是亟待解决的现实雷达检测处理难题。

针对该难题,利用深度学习对目标运动轨迹特征进行分析,可尝试针对有限目标机动模型下,采用网络进行数据推演和分析,开展复杂环境下基于目标运动特性的检测跟踪一体化研究。

(4) 面向深度学习的雷达处理软硬件架构实现

当前基于深度学习等人工智能处理技术在雷达检测、识别等方面的应用还停留在仿真和试飞数据分析与离线处理验证阶段,公开报道中,缺乏基于工程化雷达软硬件应处理出开展的实时处理或者离线数据回放处理验证过程,距离深度学习等人工处理技术在雷达中的工程化应用还有很长一段的距离。

因此,在进行充分的理论建模和试验数据离线分析的基础上,以基于GPU和开放式软件架构,推进深度学习等人工处理技术的工程化演示验证,同时,积极规划雷达专用

AI处理芯片的架构研究和设计,不断推进技术成熟度迈向新的台阶。

4 结束语

雷达担负着为各类战机在复杂战场条件下提供稳定的目标检测、跟踪和识别能力的技术要求。随着近年来,各类战机作战任务、作战对象和作战目标的逐步扩展,传统雷达目标检测技术已经难以适应新的作战需求,面临明显的技术瓶颈和制约。近年来,随着深度学习技术的日臻成熟,基于深度学习的目标检测技术成为新的研究热点。本文通过对目前深度学习目标检测研究领域典型算法进行梳理和分析,并对其在雷达中的初步应用进行探讨,对未来深度学习在雷达目标检测领域工程化应用存在的问题和可能发展的方向进行探索。通过分析发现,深度学习技术为雷达检测领域带来了新的思路和方法,未来将会有更多智能算法在雷达领域进一步应用,值得深入学习和研究。 **AST**

参考文献

- [1] 罗钉. 机载有源相控阵火控雷达技术[M]. 北京:航空工业出版社, 2018.
- [2] Luo Ding. Airborne AESA fire-control radar[M]. Beijing: Aviation Industry Press, 2018. (in Chinese)
- [3] Guerci J R, Goldstein J S. Optimal and adaptive reduced-rank STAP[J]. IEEE Transactions on Aerospace & Electronic Systems, 2000, 36(2): 647-663.
- [4] 段克清, 谢文冲, 王永良. 非均匀环境下机载雷达STAP方法[J]. 数据采集与处理, 2010, 25(5): 648-654.
- [5] Duan Keqing, Xie Wenchong, Wang Yongliang. STAP method for airborne radar in nonhomogeneous environment[J]. Journal of Data Acquisition & Processing, 2010, 25(5): 648-654. (in Chinese)
- [6] Lecun Y, Bottou L. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11): 2278-2324.
- [7] Ren S, He K, Girshick R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 39(6): 1137-1149.
- [8] Redmon J, Farhadi A. YOLOV3: an incremental improvement [EB/OL]. (2018-11-02). <http://arxiv.org/pdf/1804.02767v1.pdf>.

- [7] Bengio Y. Learning deep architectures for AI[J]. Foundations and Trends in Machine Learning, 2009, 2(1):1-131.
- [8] Hinton G E. Deep belief networks[J]. Scholarpedia, 2009, 4(6):5947.
- [9] Cagli E, Cécile D, Prouff E. Convolutional neural networks with data augmentation against jitter-based countermeasures [C]// International Conference on Cryptographic Hardware and Embedded Systems, 2017:45-68.
- [10] Geng J, Fan J, Wang H, et al. High-resolution SAR image classification via deep convolutional autoencoders[J]. IEEE Geoscience & Remote Sensing Letters, 2015, 12(11):1-5.
- [11] Nguyen H, Ngo D, Do V. Deep learning for radar pulse detection[C]// 8th International Conference on Pattern Recognition Applications and Methods, 2019.
- [12] Jokanovic B, Amin M. Fall detection using deep learning in range-doppler radars[J]. IEEE Transactions on Aerospace and Electronic Systems, 2017, 54(1):180-189.
- [13] Mehmet S S, Sevgi Z G. Deep neural network initialization methods for micro-doppler classification with low training sample support[J]. IEEE Geoscience & Remote Sensing Letters, 2017, 14(12):2462-2466.
- [14] 欧微, 柳少军, 贺筱媛, 等. 基于时序特征编码的目标战术意图识别算法[J]. 指挥控制与仿真, 2016, 38(6):36-41.
Ou Wei, Liu Shaojun, He Xiaoyuan, et al. Tactical intension recognition algorithm based on encoded temporal features[J]. Command Control & Simulation, 2016, 38(6): 36-41. (in Chinese)
- [15] 张晓海, 操新文, 耿松涛, 等. 基于深度学习的军事辅助决策智能化研究[J]. 兵器装备工程学报, 2018, 39(10):168-173.
Zhang Xiaohai, Cao Xinwen, Geng Songtao, et al. Research on Intelligence of military auxiliary decision-making system based on deep learning[J]. Journal of Ordnance Equipment Engineering, 2018, 39(10):168-173. (in Chinese)
- [16] 苏宁远, 陈小龙, 陈宝欣, 等. 雷达海上目标双通道卷积神经网络特征融合智能检测方法[J]. 现代雷达, 2019, 41(10):47-52.
Su Ningyuan, Chen Xiaolong, Chen Baoxin, et al. Dual-channel convolutional neural networks feature fusion method for radar maritime target intelligent detection[J]. Modern Radar, 2019, 41(10):47-52. (in Chinese)
- [17] Redmon J, Divvala S, Girshick R, et al. You only look once: unified, real-time object detection[C]//The 2016 IEEE Conference on Computer Vision and Pattern recognition, 2016: 779-788.
- [18] Girshick R, Donahue J, Darrell T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]// IEEE Conference on Computer Vision & Pattern Recognition. IEEE Computer Society, 2014:580-587.
- [19] Liu W, Anguelov D, Erhan D, et al. SSD: single shot multibox detector[C]//The 14th European Conference on Computer Vision, 2016:21-37.
- [20] Redmon J, Farhadi A. YOLO9000: better, faster, stronger [C]// IEEE Conference on Computer Vision & Pattern Recognition. IEEE, 2017:6517-6525.
- [21] Alexey B, Wang Chienyao, Mark Liao Hongyuan. YOLOV4: optimal speed and accuracy of object detection [EB/OL]. (2020-04-23).<http://arxiv.org/pdf/2004.10934v1.pdf>.
- [22] Hinton G E, Salakhutdinov R R. Reducing the dimensionality of data with neural networks. [J]. Science, 2006, 313(5786): 504-511.
- [23] Zhang S, Wang J, Tao X, et al. Constructing deep sparse coding network for image classification[J]. Journal of the Pattern Recognition Society, 2017, 64(11):130-140.
- [24] Yan Huaqing, Zhang Zenghui, Xiong Gang, et al. Radar HRRP recognition based on sparse denoising autoencoder and multi-layer perceptron deep model[C]// Proceedings of the 4th International Conference on Ubiquitous Positioning, Indoor Navigation and Location Based Services, 2016:283-288.
- [25] Wang L, Tang J, Liao Q. A study on radar target detection based on deep neural networks[J]. IEEE Sensors Letters, 2019, 3(3):1-4.
- [26] Peibei C, Weijie X, Ming Y, et al. Radar-ID: human identification based on radar micro-Doppler signatures using deep convolutional neural networks[J]. IET Radar Sonar & Navigation, 2018, 12(7):729-734.
- [27] Su N Y, Chen X L, Mou X, et al. A deep learning method of moving target classification in clutter background[C]// International Conference in Communications, Signal Processing, and Systems, 2018:303-311.
- [28] Rodrigo P, Schubert F, Rasshofer R H, et al. Deep learning

- radar object detection and classification for urban automotive scenarios[C]// 2019 Kleinheubach Conference, 2019.
- [29] 涂松. 高分辨率SAR图像目标快速提取算法研究[D]. 长沙: 国防科学技术大学, 2016.
- Tu Song. Fast and accurate target extraction for high-resolution SAR imagery[D]. Changsha: National University of Defense Technology, 2016. (in Chinese)
- [30] Wang C, Zhang H, Wu F, et al. Ship classification with deep learning using COSMO-SkyMed SAR data[C]// IGARSS 2017-2017 IEEE International Geoscience and Remote Sensing Symposium. IEEE, 2017.
- [31] De S, Pirrone D, Bovolo F, et al. A novel change detection framework based on deep learning for the analysis of multi-temporal polarimetric SAR images[C]// IGARSS 2017—2017 IEEE International Geoscience and Remote Sensing Symposium. IEEE, 2017.
- [32] Jiao J, Zhang Y, Sun H, et al. A densely connected end-to-end neural network for multiscale and multiscene SAR ship detection[J]. IEEE Access, 2018(6):20881-20892.
- [33] Zhao J, Guo W, Zhang Z, et al. A coupled convolutional neural network for small and densely clustered ship detection in SAR images[J]. Science China (Information Sciences), 2019, 62(4):42301.
- [34] 杜兰, 刘彬, 王燕, 等. 基于卷积神经网络的SAR图像目标检测算法[J]. 电子与信息学报, 2016, 38(12):3018-3025.
- Du Lan, Liu Bin, Wang Yan, et al. Target detection method based on convolutional neural networks for SAR Image[J]. Journal of Electronics & Information Technology, 2016, 38(12):3018-3025. (in Chinese)
- [35] 杨龙, 苏娟, 李响. 基于深度卷积神经网络的SAR舰船目标检测[J]. 系统工程与电子技术, 2019, 41(9):1990-1997.
- Yang Long, Su Juan, Li Xiang. Ship detection in SAR image based on deep convolutional neural network[J]. Systems Engineering and Electronics, 2019, 41(9): 1990-1997. (in Chinese)
- [36] Liu B, Yang D, Wang Z, et al. SAR target detection based on SSD with data augmentation and transfer learning[J]. IEEE Geoscience and Remote Sensing Letters, 2019, 16(1): 150-154.
- [37] Wang Y, Wang C, Zhang H, et al. Combining single shot multibox detector with transfer learning for ship detection using Chinese Gaofen-3 images[C]// 2017 Progress in Electromagnetics Research Symposium-Fall (PIERS-FALL). IEEE, 2017.
- [38] Zongyong C, Sihang D, Zongjie C, et al. SAR target recognition in large scene images via region-based convolutional neural networks[J]. Remote Sensing, 2018, 10(5):776.
- [39] Khan H M, Yunze C. Ship detection in SAR Image using YOLOv2[C]// 2018 37th Chinese Control Conference (CCC), 2018.
- [40] Chang Y L, Anagaw A, Chang L, et al. Ship detection based on YOLOV2 for SAR imagery[J]. Remote Sensing, 2019, 11(7):784-786.
- [41] 胡昌华, 陈辰, 何川, 等. 基于深度卷积神经网络的SAR图像目标舰船小目标检测[J]. 中国惯性技术学报, 2019, 27(3): 397-406.
- Hu Changhua, Chen Chen, He Chuan, et al. SAR detection for small target ship based on deep convolutional neural network [J]. Journal of Chinese Inertial Technology, 2019, 27(3): 397-406. (in Chinese)
- [42] Liu Ningbo, Xu Yanan, Tian Yonghua, et al. Background classification method based on deep learning for intelligent automotive radar target detection[J]. Future Generation Computer Systems, 2019, 94(5):524-535.

(责任编辑 陈东晓)

作者简介

宋婷(1991-)女, 硕士, 工程师。主要研究方向: 雷达智能化探测、认知雷达等。

Tel: 15261597156 E-mail: tinasongting@163.com

贺丰收(1979-)男, 博士, 高级工程师。主要研究方向: 多源信号融合、信号检测、雷达数据处理等。

程宇峰(1973-)男, 研究员。主要研究方向: 智能化雷达、雷达系统等。

Research Progress of Deep Learning Technology in Radar Target Detection

Song Ting^{1,*}, He Fengshou^{1,2}, Cheng Yufeng¹

1. Aviation Key Laboratory of Science and Technology on AISSS, AVIC Leihua Electronic Technology Research Institute, Wuxi 214063, China

2. Northwestern Polytechnical University, Xi'an 710129, China

Abstract: The detection of interesting targets is the basic task for radar. Target detection technology is one of the key technologies in the field of radar signal processing. Since deep learning methods establish an end-to-end network to avoid the lack of artificial feature expression and achieve superior detection performance, it has received more and more attention in the radar field. This paper first introduces the relevant knowledge in target detection and points out the limitation of traditional detection methods; then analyze the current classic methods of deep neural network detection, mainly focuses on the research status of deep learning techniques in radar target detection. Finally, the technical challenges of the application towards deep learning methods in targets detection are analyzed, and the development trend of related technology in the future is prospected.

Key Words: deep learning; radar target detection technology; deep neural network; sequence signal detection; time-frequency domain detection

Received: 2020-07-23; **Revised:** 2020-08-25; **Accepted:** 2020-09-21

Foundation item: Aeronautical Science Foundation of China (20172007002)

***Corresponding author.** Tel. : 15261597156 **E-mail:** tinasongting@163.com