

基于雷达信号目标检测的深度学习算法综述

张道洋¹, 刘思岐^{2*}, 刘晓璐¹, 韩 畅¹, 徐仁豪²

¹北京遥感设备研究所毫米波遥感技术重点实验室, 北京

²上海理工大学机械工程学院, 上海

收稿日期: 2025年2月24日; 录用日期: 2025年3月16日; 发布日期: 2025年3月25日

摘 要

随着工业进入4.0时代和人工智能的发展, 基于雷达信号的目标检测在工厂自动化、航空航天、自动驾驶等领域中日益成为关键技术。本文综述了雷达目标检测的技术发展及其面临的挑战。介绍了机器学习算法与深度学习算法在雷达目标检测中的应用, 其中包括卷积神经网络、递归神经网络、生成对抗网络等模型的应用。这些数据驱动算法能够通过大量数据训练好的模型, 实现自动学习特征提取和分类, 提高检测精度和处理速度。最后总结了目前雷达信号目标检测技术所具备的优势和面临的挑战, 并展望了其未来的发展方向, 介绍了如何更好地融合传统方法和数据驱动技术。

关键词

雷达信号, 目标检测, 机器学习, 深度学习

Review of Deep Learning Algorithms Based on Radar Signal Target Detection

Xiaoyang Zhang¹, Siqi Liu^{2*}, Xiaolu Liu¹, Chang Han¹, Renhao Xu²

¹Science and Technology on Millimeter-Wave Laboratory, Beijing Institute of Remote-Sensing Equipment, Beijing

²School of Mechanical Engineering, University of Shanghai for Science and Technology, Shanghai

Received: Feb. 24th, 2025; accepted: Mar. 16th, 2025; published: Mar. 25th, 2025

Abstract

As industry enters the 4.0 era and artificial intelligence develops, radar signal-based object detection has increasingly become a key technology in factory automation, aerospace, autonomous driving and other fields. This paper reviews the technical development and challenges of radar target detection. This paper introduces the application of machine learning algorithms and deep learning

*通讯作者。

文章引用: 张道洋, 刘思岐, 刘晓璐, 韩畅, 徐仁豪. 基于雷达信号目标检测的深度学习算法综述[J]. 图像与信号处理, 2025, 14(2): 139-148. DOI: 10.12677/jisp.2025.142014

algorithms in radar target detection, including convolutional neural networks, recurrent neural networks, generative adversarial networks and other models. These data-driven algorithms can automatically learn feature extraction and classification through models trained with a large amount of data, improving detection accuracy and processing speed. Finally, the advantages and challenges of the current radar signal target detection technology are summarized, and its future development direction prospects and how to better integrate traditional methods and data-driven technologies are introduced.

Keywords

Radar Signal, Target Detection, Machine Learning, Deep Learning

Copyright © 2025 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 雷达目标检测技术的挑战

现如今,雷达目标检测作为一种关键的技术,不仅在现代工业和军事应用中扮演着至关重要的角色,而且逐步成为工业自动化和智能化的重要组成部分[1]。雷达目标检测的主要目的是利用雷达信号来探测、识别和跟踪空中、地面或水下的目标物体。这些目标物体可以是飞行器、车辆、船只或其他工业设备,其检测与跟踪对于军事侦察、民用监测和交通管理具有重要意义[2][3]。目前雷达技术领域已经发展出多种算法来解决这一问题。其中包括自适应波形设计[4]、自适应信号处理[5]、融合多传感器数据[6]以及高分辨率成像技术[7]等。这些算法提高了雷达系统在复杂背景下的目标探测能力、抗干扰能力和目标定位精度,为各类监测与防御任务提供了重要支持。

首先,本文介绍了常见的目标检测算法,以及基于机器学习和深度学习的新兴算法在雷达目标检测中的应用,验证说明了这些算法能够提高目标检测的准确性和鲁棒性。最后,本文总结当前雷达目标检测技术面临的挑战和未来的发展方向。通过本文的综述,读者将对雷达目标检测的基础知识、最新技术和未来发展趋势有一个全面的了解,并且能够将其作为相关领域研究的理论指导和实际应用的参考。

2. 数据驱动的目标检测算法

在复杂环境中(如低信噪比、多目标、高杂波等),传统方法检测精度下降,易出现漏检或虚警,同时高计算资源需求限制其实时检测能力,且对动态环境适应性较差。随着机器学习和深度学习的发展,基于数据驱动的目标检测方法逐渐兴起,通过大数据训练和优化模型,成为研究热点。机器学习方法分为传统特征提取结合分类器的方法和基于深度学习的方法,后者通过卷积神经网络(CNN)等技术自动学习特征,显著提升检测性能和适应性。

2.1. 机器学习的目标检测算法

基于机器学习的雷达目标检测是雷达技术发展的重要方向。其流程包括信号预处理(如滤波、去噪)、特征提取,并将特征向量输入训练好的模型进行分类和目标识别。常用模型有支持向量机(SVM)和随机森林(RF)。检测框架如图1所示。

近年来,无人机的广泛应用带来了安全威胁,为此,研究者们利用机器学习算法在雷达目标检测领域取得了显著进展。Luc 等[8]在雷达系统中获得的无人机和鸟类轨迹的实验数据,通过分析无人机与鸟

类轨迹特征,提出了一种基于人工智能技术识别空中目标的算法,证明了 SVM 和 KNN 对小型空中目标识别效果最佳。Xiao 等[9]针对标准反向传播神经网络在雷达干扰有效性评价模型下对网络训练的影响,提出了一种基于遗传算法(GA)优化 BP 神经网络初始权重和阈值的方法,从而提高了雷达干扰效能评估的精度。Marino 等[10]开发了一种针对多平台雷达网络的三维定位算法,该算法利用单基地传感器辐射方向图特征,并通过施加角度约束来限制目标的方位角仰角位置,结果证实了新算法的有效性在低信噪比条件下实现了更低的均方根误差(RMSE)。Pak 等[11]基于人工神经网络(ANN)通过估计信号的到达时间差进行目标定位,结果表明该方法在低信噪比条件下性能优越,适用于多基地无源雷达系统。Song 等[12]探讨了在复杂电磁环境下雷达目标轨迹预测的方法,提出了一种基于反向传播(BP)神经网络的雷达轨迹预测方法。该方法利用雷达目标的历史轨迹数据,通过 BP 神经网络对其运动规律进行建模,预测目标的未来轨迹。Zhao 等[13]提出了一种基于松弛能量函数的神经网络(RNFNN)方法用于分布式多输入多输出(MIMO)雷达的目标定位。证明了 RNFNN 在更宽的信噪比范围内实现了计算效率方面优于现有方法。

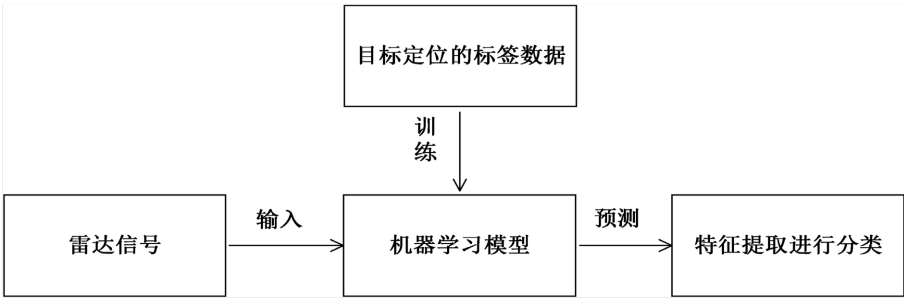


Figure 1. Schematic framework diagram of machine learning
图 1. 机器学习的目标检测原理框图

综上基于机器学习的雷达信号目标检测技术在当前雷达技术的发展中具有重要意义。通过对不同的机器学习算法不断研究,如支持向量机(SVM)、K 近邻(KNN)、反向传播神经网络(BP)、遗传算法(GA)优化的 BP 神经网络、人工神经网络(ANN)和松弛能量函数神经网络(RNFNN)等,研究者在无人机识别、雷达干扰效能评估、目标定位和轨迹预测等方面取得了显著进展。这些方法在低信噪比条件下表现出色,并且在复杂电磁环境下展现出优越的性能,为雷达技术在实际应用中的有效性和可靠性提供了有力支持。未来,随着机器学习技术的不断发展和完善,雷达信号处理和目标检测技术将迎来更加广阔的应用前景和发展空间。

2.2. 深度学习的目标检测算法

传统的目标检测方法通常依赖于信号处理技术和特征工程,这些方法通过人工设计特征提取规则来识别目标。然而,在复杂环境中,尤其是面对海量数据时,传统方法的性能和效率往往受到限制,且难以应对环境的动态变化和数据的不确定性。特别是在雷达信号目标检测领域,传统方法在处理复杂场景和高噪声环境下,往往表现出较低的鲁棒性和适应性。

与之相比,深度学习方法通过自动学习数据中的深层次特征,显著提升了雷达信号目标检测的性能。深度学习方法无需手工设计特征,而是通过多层网络结构从原始数据中自动学习并提取复杂的特征,从而提高了目标识别的准确性和效率。深度学习模型能够从大量的训练数据中捕捉到目标的微小特征,这使得其在各种复杂环境下的表现要优于传统方法。

深度学习目标检测原理如图 2 所示。本节将重点介绍几种常见的深度学习算法在雷达信号目标检测中的应用。




Figure 2. Schematic framework diagram of deep learning object detection

图 2. 深度学习目标检测原理框架图

2.2.1. 卷积神经网络(CNN)

卷积神经网络在图像处理领域的优异表现,卷积神经网络(CNN)因其在图像处理中的卓越性能,被广泛应用于雷达信号目标检测。其基本原理通过卷积层、池化层和全连接层提取信号的多层次特征。在低信噪比条件下,Guo 等[14]提出了一种特征金字塔融合轻量级卷积神经网络,通过将多尺度空间理论与深度卷积神经网络相结合,提高了低信噪比条件下雷达目标识别的准确性和鲁棒性。Akula 等[15]通过对比 AlexNet 和 VGG19 从不同层提取特征来评估多个深度特征提取器,证明了基于 CNN 的深度特征提取器表现出鲁棒性,在两个 FLIR 热红外数据集上,VGG19 架构展示了卓越性能。Ding 等[16]为军事目标识别领域构建了一个包含十种目标的战场军事目标识别数据集,研究评估了三种经典的卷积神经网络模型(AlexNet、VGGNet 和 ResNet)以及两种学习策略(Drop Out 和 Data Augmentation)。在相同的数据集条件和超参数设置下,对不同模型的性能进行了呈现和分析。证明了 ResNet 和 VGGNet 的平均精度优于 AlexNet,同时,Drop Out 和 Data Augmentation 策略对性能的提升起到了很大的作用。针对 SAR 系统目标识别,Zhang 等[17]提出了一种创新的特征融合框架(FEC),提出了一种改进的 VGGNet,用于从振幅图像中提取强大且准确的特征。为进一步增强特征融合效果,FEC 框架引入了判别相关性分析(DCA),通过最大化 CNN 和 ASC 特征之间的相关性,并去除每个特征集中不同类别之间的相关性。证明了在 MSTAR 数据集上,所提出的 FEC 框架在目标分类(SOCs)和目标识别(EOCs)任务中展现了优异的有效性和鲁棒性。Guo 等[18]针对高速机动目标回波信号的非平稳特性,提出了结合时间-频率分析和 AlexNet 的雷达移动目标检测方法,以实现雷达在嘈杂环境下的自动检测。通过仿真实验,结果显示,在噪声环境下,该方法能有效增强回波信号的时频特性,具有更好的检测精度和噪声鲁棒性。Li 等[19]提出了一种基于区域的卷积神经网络(R-CNN)框架,用于 SAR 图像中的船舶检测。该方法结合了 ResNet-50 的优势,并设计了一种轻量级的基础网络,该网络包括特征中继放大和多尺度特征跳跃连接结构,从而有效改进了检测的精度和速度。Zhang 等[20]提出了一种基于 Faster R-CNN 的小目标检测算法,旨在解决小目标导致的漏检问题,并提高小目标检测的精度。为了克服过深网络带来的梯度消失和梯度爆炸问题,使用了残差网络 ResNet50 代替传统的 VGG16 骨干特征提取网络。Zheng 等[21]使用 AlexNet、VGG16、GoogLeNet 和 ResNet-50 进行预训练的 CNN 模型的过程分析,验证了这些模型在 SAR 图像目标识别中的适应性。

通过文献的引用分析,我们展示了 CNN 在不同场景下的优异表现。表 1 展示了不同改进 CNN 方法的性能对比,进一步说明了其在多种复杂场景下的优势,表 1 为一些改进的卷积神经网络的方法对比。

然而 CNN 在雷达信号目标检测中仍面临挑战,如梯度消失、过拟合导致的稳定性和泛化能力不足,以及受限于数据集规模和质量的性能瓶颈。此外,小目标检测和漏检问题也需进一步优化。未来研究可通过改进网络结构(如使用 ResNet 解决梯度问题)以及扩大和优化数据集规模与质量,提升 CNN 的鲁棒性和性能。

2.2.2. 循环神经网络(RNN)和长短期记忆网络(LSTM)

在低信噪比条件下,雷达信号具有显著时序特性,传统 CNN 在处理时存在局限,循环神经网络(RNN)和长短期记忆网络(LSTM)凭借出色的时间序列建模能力,成为雷达信号处理的理想选择。LSTM 通过引入记忆单元和门机制解决了梯度消失问题,更适合处理长时间依赖数据。

Table 1. Convolutional neural network (CNN) methods in radar signal target detection are compared
表 1. 卷积神经网络(CNN)在雷达信号目标检测中的方法对比总结

算法	发展历程	关键参数	改进特点	应用场景
特征金字塔融合轻量级卷积神经网络	基于多尺度空间理论与轻量级网络的结合,增强了对低信噪比条件下目标特征的提取能力。	特征金字塔融合策略,多尺度卷积核,轻量化参数优化设计。	在保证轻量化的前提下提升识别鲁棒性,适合资源受限环境,支持高效处理多尺度特征。	适用于低信噪比的雷达目标识别场景
预训练的CNN模型 VGG19	从 AlexNet 演进而来,通过更深的层数和更宽的卷积核提升特征提取能力,增强模型适配性。	19 层网络深度, 3×3 卷积核, Relu 激活函数,包含超过 144 M 的权重参数。	在多个层次上提取深度特征,尤其适合热红外图像中的目标检测,尽管模型复杂度较高,但效果显著。	热红外数据集及需要深度特征提取的应用场景。
结合 VGGNet 和特征融合	融合 VGGNet 基础架构与判别相关性分析(DCA)框架,着力增强特征间的相关性和辨别能力。	判别相关性分析(DCA),振幅特征和散射中心特征联合建模,深层特征融合参数优化。	最大化多特征之间的互补信息,并减少类别间的冗余信息,提升目标识别和分类的准确性。	SAR 系统目标识别,尤其是在复杂操作条件下
结合时间-频率分析和 AlexNet	针对雷达信号非平稳性,结合时间-频率分析方法与 AlexNet 的深度网络特性,优化了噪声环境下的目标特征提取性能。	时间频域分析采用二阶同步提取变换(SET2)转换为时频图像,5 层卷积架构,3 个全连接层,Relu 激活,Softmax 分类层。	通过强调信号的时频特性增强目标检测效果,在低信噪比条件下保持较强鲁棒性,同时显著提升分类精度。	嘈杂环境下的雷达移动目标检测。
(R-CNN)检测框架	从 Faster R-CNN 演化而来,结合轻量级特征中继网络与多尺度跳跃连接结构,增强目标特征提取能力。	ResNet-50 作为骨干网络,轻量化模块中加入特征跳跃连接,采用区域建议网络(RPN)生成候选框。	提升了目标检测的效率与精度,特别适合快速变化的动态目标识别任务。	SAR 图像中的船舶检测。
Faster R-CNN 的小目标检测算法	为解决小目标漏检问题,对传统 Faster R-CNN 框架进行优化,通过引入 ResNet-50 克服梯度消失及网络过深问题。	使用残差网络 ResNet-50 作为骨干特征提取网络,ROI 池化层优化区域定位。	针对小目标设计的检测算法,能够有效提升小目标的检测精度,同时通过浅层特征优化减轻过深网络带来的负担。	需要高精度小目标检测的场景。
预训练的CNN模型 VGG19	从 AlexNet 演进而来,通过更深的层数和更宽的卷积核提升特征提取能力,增强模型适配性。	19 层网络深度, 3×3 卷积核, Relu 激活函数,包含超过 144 M 的权重参数。	在多个层次上提取深度特征,尤其适合热红外图像中的目标检测,尽管模型复杂度较高,但效果显著。	热红外数据集及需要深度特征提取的应用场景。

Sehgal 等[22]提出基于 RNN 和 LSTM 的自动雷达目标识别(ARTI),当雷达的电磁波照射目标时,目标表面会产生表面电流,从而导致入射能量的散射。雷达接收到的散射信号被用作目标的雷达信号。其中,雷达散射截面(RCS)是从雷达信号中提取的重要特征,用于目标识别。Wang 等[23]结合堆叠 RNN 和 LSTM 网络,结合雷达数据的频谱图和时变多普勒、微多普勒特征,实现了基于雷达的人体运动识别。由于当今的电磁环境异常复杂,导致分布脉冲流不均匀。为了使分类过程更加准确,需要分离出有用的信息并去除噪声。Li 等[24]通过注意力机制结合 RNN 进行雷达发射器分类,在复杂电磁环境中表现出色。Tang 等[25]使用 RNN 分类微多普勒特征,证明其在目标识别中的重要性。Wang 等[26]提出 TCN 和双向 LSTM 并行融合结构,用于识别相控阵雷达的工作模式。Qu 等[27]基于循环神经网络开展了脉冲重复间隔(PRI)调制模式的识别研究。为解决循环神经网络中梯度消失和梯度爆炸的问题,提出了一种基于长短时记忆网络的 PRI 调制模式识别方法。RNN 和 LSTM 展现出强大的时序建模能力,它们通过处理雷达信

号的时序特性, 能够有效地捕捉到时间依赖性和长期记忆。这使得他们二者成为处理雷达信号的理想选择, 并在自动雷达目标识别、目标分类、人体运动识别等领域取得了显著的成果。然而, 面临着梯度消失或爆炸的问题以及数据集规模和质量挑战。未来的研究可以关注不同类型的循环神经网络结构, 结合注意力机制、卷积神经网络等技术, 提高算法的鲁棒性和泛化能力。

2.2.3. 生成对抗网络(GAN)

生成对抗网络(GAN)在雷达信号目标检测中的应用日益增多, 通过生成逼真的雷达数据增强训练数据的多样性, 提升模型泛化能力。Kong 等[28]提出利用 GAN 解决 SAR 目标识别中数据不足的问题。Carr 等[29]研究了使用 GAN 进行雷达目标检测的方法。相比于当前主流的 CNN 方法, 大多数 GAN 方法不需要标记数据, 因此可以用于无监督学习下的雷达目标检测。Pu 等[30]提出了一种基于自编码器分离的随机 GAN 方法来实现 SAR 图像中运动目标和静止目标的分离。该算法利用静止目标和模糊运动目标之间的相互独立性来创建对抗约束, 并采用完全无监督的方式进行操作, 无需使用包含混合和分离 SAR 图像的样本集, 实现了 SAR 图像中运动目标和静止目标的分离。Akçali 等[31]通过使用 GAN 增强数据集, 采用增强后的模拟数据集训练了 Faster R-CNN 结构, 并在模拟数据集和真实数据集上进行了测试, 解决了探地雷达(GPR)图像中的杂波问题, 并在目标检测任务中取得了显著的性能提升。Du 等[32]为解决在 SAR 自动目标识别(ATR)应用中难以获得高质量训练数据集的问题, 提出了多约束 GAN(MCGAN)方法, 提供了一种有效的数据增强方法, 可以生成高质量的多类别 SAR 图像, 从而提高目标识别的性能。由于采集和验证 GPR 数据的高昂成本, 获取足够的标记数据可能是困难的。为了解决这个问题。Zhao 等[33]提出了一种基于 GAN 的 GPR 数据增强方法-WAEGAN, 该方法利用 GAN 模型, 包括编码器 E、联合生成器 G 和判别器 D, 来生成新的数据。预训练分类器 C 对生成的数据施加目标类别约束, 同时使用 Wasserstein 损失函数来稳定训练过程, 实验结果验证了所提方法的优越性。该方法能够同时生成多个目标类别的数据, 并生成符合实际情况的探地雷达数据。Xiong 等[34]提出了一种名为 GPR-GAN 的结构自适应探地雷达(GPR)GAN, 用于生成探地雷达缺陷数据。GPR-GAN 采用双重归一化方法来稳定参数和卷积输出, 利用自适应判别器增强(ADA)模块来提高小数据集训练的稳定性, 并使用改进的自注意力(MSA)模块来生成具有复杂特征的探地雷达缺陷, 并展示了其在生成探地雷达缺陷数据方面的优越性能。

GAN 在雷达信号目标检测领域的应用不断增加, 并取得了显著的成果。它通过解决训练数据不足的问题, 实现了数据增强和模型泛化能力的提升。在 SAR 目标识别方面, 研究表明使用 GAN 进行数据增强可以提高目标识别的准确性。同时, 在 GPR 数据增强方面, WAEGAN 和 GPR-GAN 等基于 GAN 的方法能够生成符合实际情况的 GPR 数据, 从而提高数据解释和目标检测的性能。然而, 使用 GAN 也面临一些挑战和不足。首先, GAN 的训练过程相对复杂, 需要仔细调整超参数和优化算法, 以获得稳定且高质量的生成结果。此外, GAN 在生成数据时可能会出现模式崩溃或模式塌陷等问题, 导致生成的数据缺乏多样性和真实性。另外, 选择合适的损失函数和评估指标也是一个挑战, 因为在雷达信号目标检测中很难定义准确且可靠的评估指标。

2.2.4. YOLO 算法

YOLO 是一种高效的目标检测算法, 以实时性强、检测速度快为优势, 在雷达信号目标检测中表现突出。研究者通过优化 YOLO 结构, 提高了其对小目标、复杂背景及多尺度目标的检测性能。Ju 等[35]提出了一种改进的 YOLOv3 多尺度目标检测算法, 基于交并数(IOU)的数学推导方法, 用于选择合适数量和纵横比的候选锚框, 以提升不同尺度目标的检测效果; 将 YOLOv3 的检测尺度从 3 个扩展到 4 个, 特别针对小目标的检测性能进行优化; 此外, 为避免梯度衰减、增强特征复用性, 将输出层前的六个卷积层整合为两个残差单元, 证明了所提方法比其他最先进的目标检测算法获得了更好的性能。Kim 等[36]提

出了一种基于深度学习模型(YOLO)的方法,通过处理汽车雷达信号来同时检测和分类物体,打破了传统方法将检测与分类分为两个连续阶段的局限,在所提出的方法中,这两个环节被有效整合为一个整体。Xu 等[37]针对遥感目标检测中存在的尺度差异、分布密集和背景复杂等挑战,提出了一种基于 YOLOV3 的新模型。YOLOv3 是 YOLO 系列的最新版本,但在遥感目标检测中表现不佳。为了解决这一问题,引入了 DenseNet (以增强特征提取能力,并将检测量表增加至 4 个,以提升对不同尺度目标的检测性能)。Tang 等[38]提出了一种新颖的 YOLO 网络用于双波束 SAR 中的慢速移动目标检测,通过 YOLO 网络在强杂波环境下进行目标检测与分类,并排除静止目标。Kong 等[39]针对复杂环境下传统检测算法表现不佳的问题,通过深度学习实现了军事目标的自动检测,并提出了一种改进的 YOLOv3 模型——YOLO-G,在 YOLOv3 网络结构中引入了轻量级卷积神经网络 GhostNet 作为特征提取网络。此外,通过引入基于坐标注意力块的注意力机制,增强了目标特征的代表能力,有效抑制了干扰,提高了检测精度,并结合了 DIOU 损失函数和 Focal loss 函数,从而提升了模型对军事目标的检测精度。Zhong 等[40]针对雷达运动目标在快时间维度下的多普勒频移特性,提出了一种基于 YOLOv5s 的雷达运动目标智能检测与识别方法,通过构建数据集并对接收的目标回波信号进行处理,实现了运动目标多普勒频移特征的检测和分类。

尽管 YOLO 在雷达目标检测中表现优异,但仍存在小目标召回率低、复杂背景干扰、计算资源需求高及多目标密集场景下性能下降等挑战。未来改进将集中于优化模型结构、增强泛化能力及应对复杂应用场景。

2.3. 机器学习算法与深度学习算法对比分析

雷达目标检测中,基于机器学习算法和基于深度学习的算法各有优缺点(见表 2)。机器学习适合小数据且特征明确场景,深度学习在大数据和复杂环境下表现更优。未来研究可以探索结合两者的优势,通过引入混合模型或迁移学习等方法来优化检测算法。例如,可以在初期利用机器学习算法提取关键特征,在后续步骤中结合深度学习模型进行进一步优化分析,以弥补单一方法的不足。同时,加强对深度学习模型的压缩与优化,使其在计算资源有限的环境中依然具有较好的适应性。通过这类方法的探索,未来的雷达目标检测算法有望在提高检测精度的同时,进一步增强其鲁棒性与泛化能力,以应对更为复杂

Table 2. Comparison of machine learning algorithms and deep learning algorithms
表 2. 机器学习算法和深度学习算法对比

算法	发展历程	关键参数	优点	缺点
机器学习算法	从统计学和优化理论发展而来,包含支持向量机(SVM)、K 近邻(KNN)、决策树等传统方法,强调特征工程和可解释性。	超参数如 SVM 中的核函数选择、KNN 的邻居数设置,特征选择及维度大小等	1. 能够处理较小规模的数据集,适合初始数据较少的情况。 2. 传统方法如支持向量机(SVM)、K 近邻(KNN)具有较好的理论基础和可解释性。 3. 通常计算复杂度较低,训练和推理速度较快。	1. 需要手动设计和选择特征,特征工程过程复杂。 2. 在复杂环境和大规模数据下,性能和泛化能力有限。 3. 难以处理高维数据和复杂非线性关系。
深度学习算法	基于神经网络的发展,包括从初期的前馈神经网络(FNN)、卷积神经网络(CNN)到生成对抗网络(GAN)和变分自编码器(VAE)等现代框架。	层数(如 ResNet 的 50 层或 101 层)、学习率、优化算法(如 Adam、SGD)、激活函数(如 ReLU、Leaky ReLU)等。	1. 能够自动学习数据中的深层次特征,减少了手动特征工程的需求。 2. 在处理大规模数据和复杂非线性关系时表现优异。 3. 具有强大的建模能力,适用于多种目标检测任务。	1. 需要大量标注数据和计算资源进行训练。 2. 训练过程复杂,超参数调整困难。

多变的实际应用场景。

3. 雷达目标检测技术面临的发展趋势

雷达目标检测发展趋势有以下几个方面：

(1) 实时处理能力的提升。针对雷达系统对实时性的高要求，未来的发展将侧重于提升算法和硬件的实时处理能力。通过算法优化和并行计算等技术，提高信号处理和目标检测的速度。

(2) 自适应和智能化。未来的雷达目标检测系统将向自适应和智能化方向发展。通过引入自适应算法，系统可以根据环境变化和目标特性，动态调整检测参数和策略，从而提高检测性能。

(3) 资源受限下的高效算法。在资源受限的环境中，如无人机、小型移动平台等，发展高效、轻量化的目标检测算法将成为重要趋势。

4. 结束语

本文全面回顾了深度学习算法在雷达信号目标检测领域的研究进展与应用现状。我们首先分析了雷达目标检测的基本挑战，特别是在复杂环境和大规模数据背景下传统方法的局限性。为应对这些问题，深度学习技术的引入为该领域带来了新的发展机遇。详细讨论了包括卷积神经网络(CNN)、循环神经网络(RNN)、长短时记忆网络(LSTM)、生成对抗网络(GAN)以及 YOLO 等方法在雷达信号目标检测中的应用，这些技术凭借自动特征提取能力和处理海量数据的高效性，大幅提升了检测性能。

未来研究应重点关注深度学习算法的优化，以进一步提升其鲁棒性、实时性和在复杂应用环境中的适应能力。同时，多传感器数据融合和算法轻量化也是值得探索的方向，有望进一步提高目标检测的准确性和应用范围。希望为研究人员提供有价值的参考，推动深度学习在雷达信号目标检测领域的持续发展与创新。

参考文献

- [1] 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.
- [2] 陈小龙, 关键, 黄勇, 等. 雷达低可观测目标探测技术[J]. 科技导报, 2017, 35(11): 30-38.
- [3] 陈小龙, 关键, 黄勇, 等. 雷达低可观测目标精细化处理及应用[J]. 科技导报, 2017, 35(20): 19-27.
- [4] 董军. 认知雷达自适应波形与博弈波形设计算法研究[D]: [硕士学位论文]. 烟台: 烟台大学, 2024.
- [5] 王佩, 仇兆炀, 祝俊, 等. 雷达侦收自适应信号处理架构研究[J]. 现代雷达, 2017, 39(11): 39-44+52.
- [6] 蒲文浩, 刘锡祥, 陈昊, 等. 多传感器融合的激光雷达点云矫正与定位方法[J]. 激光与光电子学进展, 2023, 60(24): 275-282.
- [7] 张瀚夫. 单光子激光雷达测距与成像技术研究[D]: [硕士学位论文]. 北京: 中国科学院大学(中国科学院长春光学精密机械与物理研究所), 2024.
- [8] Luc, D.V., Konovalov, A.A. and Hoang, L.M. (2023) Algorithm for Recognition of Small Air Targets by Trajectory Features in Passive Bistatic Radar. *Journal of the Russian Universities. Radioelectronics*, **26**, 76-88. <https://doi.org/10.32603/1993-8985-2023-26-5-76-88>
- [9] Xiao, J., Li, C. and Yang, Q. (2023) Advanced BP Neural Network Algorithm on Radar Jamming Effectiveness Evaluation. 2023 *IEEE 3rd International Conference on Information Technology, Big Data and Artificial Intelligence (ICIBA)*, Vol. 3, 1421-1424. <https://doi.org/10.1109/iciba56860.2023.10165362>
- [10] Marino, A., Aubry, A., De Maio, A., Braca, P., Gagliione, D. and Willett, P. (2021) Constrained Target Localization for Multiplatform Radar Systems. *MILCOM 2021-2021 IEEE Military Communications Conference (MILCOM)*, San Diego, 29 November-2 December 2021, 635-640. <https://doi.org/10.1109/milcom52596.2021.9653089>
- [11] Pak, S., Chalise, B.K. and Himed, B. (2019) Target Localization in Multi-Static Passive Radar Systems with Artificial Neural Networks. 2019 *International Radar Conference (RADAR)*, Toulon, 23-27 September 2019, 1-5. <https://doi.org/10.1109/radar41533.2019.171252>
- [12] Song, L., Shengli, W. and Dingbao, X. (2019) Radar Track Prediction Method Based on BP Neural Network. *The Journal*

- of Engineering, **2019**, 8051-8055. <https://doi.org/10.1049/joe.2019.0655>
- [13] Zhao, X., Li, J. and Guo, Q. (2022) A Relaxed Energy Function Based Analog Neural Network Approach to Target Localization in Distributed MIMO Radar. *IEEE Transactions on Vehicular Technology*, **71**, 11160-11173. <https://doi.org/10.1109/tvt.2022.3188546>
- [14] Guo, C., Wang, H., Jian, T., He, Y. and Zhang, X. (2019) Radar Target Recognition Based on Feature Pyramid Fusion Lightweight CNN. *IEEE Access*, **7**, 51140-51149. <https://doi.org/10.1109/access.2019.2909348>
- [15] Akula, A. and Sardana, H.K. (2019) Deep CNN-Based Feature Extractor for Target Recognition in Thermal Images. *TENCON 2019-2019 IEEE Region 10 Conference (TENCON)*, Kochi, 17-20 October 2019, 2370-2375. <https://doi.org/10.1109/tencon.2019.8929697>
- [16] Ding, X., Xing, L., Lin, T., Wang, J., Li, Y. and Miao, Z. (2019) Evaluating CNNs for Military Target Recognition. *15th International Conference, ICIC 2019*, Nanchang, 3-6 August 2019, 628-638. https://doi.org/10.1007/978-3-030-26969-2_59
- [17] Zhang, J., Xing, M. and Xie, Y. (2021) FEC: A Feature Fusion Framework for SAR Target Recognition Based on Electromagnetic Scattering Features and Deep CNN Features. *IEEE Transactions on Geoscience and Remote Sensing*, **59**, 2174-2187. <https://doi.org/10.1109/tgrs.2020.3003264>
- [18] Guo, Y. and Yang, L. (2022) Radar Moving Target Detection Method Based on SET2 and AlexNet. *Mathematical Problems in Engineering*, **2022**, Article ID: 3359871. <https://doi.org/10.1155/2022/3359871>
- [19] Li, Y., Zhang, S. and Wang, W. (2022) A Lightweight Faster R-CNN for Ship Detection in SAR Images. *IEEE Geoscience and Remote Sensing Letters*, **19**, Article ID: 4006105. <https://doi.org/10.1109/lgrs.2020.3038901>
- [20] Zhang, M., Su, Y. and Hu, X. (2023) Small Target Detection Based on Faster R-CNN. *3rd International Conference on Computer Vision and Data Mining (ICCVDM 2022)*, Hulun Buir, 19-21 August. <https://doi.org/10.1117/12.2660388>
- [21] Zheng, T., Li, J., Tian, H. and Wu, Q. (2023) The Process Analysis Method of SAR Target Recognition in Pre-Trained CNN Models. *Sensors*, **23**, Article No. 6461. <https://doi.org/10.3390/s23146461>
- [22] Sehgal, B., Shekhawat, H.S. and Jana, S.K. (2019) Automatic Target Recognition Using Recurrent Neural Networks. *2019 International Conference on Range Technology (ICORT)*, Balasore, 15-17 February 2019, 1-5. <https://doi.org/10.1109/icort46471.2019.9069656>
- [23] Wang, M., Zhang, Y.D. and Cui, G. (2019) Human Motion Recognition Exploiting Radar with Stacked Recurrent Neural Network. *Digital Signal Processing*, **87**, 125-131. <https://doi.org/10.1016/j.dsp.2019.01.013>
- [24] Li, X., Liu, Z., Huang, Z. and Liu, W. (2020) Radar Emitter Classification with Attention-Based Multi-RNNs. *IEEE Communications Letters*, **24**, 2000-2004. <https://doi.org/10.1109/lcomm.2020.2995842>
- [25] Tang, T., Wang, C. and Gao, M. (2021) Radar Target Recognition Based on Micro-Doppler Signatures Using Recurrent Neural Network. *2021 IEEE 4th International Conference on Electronics Technology (ICET)*, Chengdu, 7-10 May 2021, 189-194. <https://doi.org/10.1109/icet51757.2021.9450934>
- [26] Wang, H., Jiang, Z. and Ding, L. (2023) Working Modes Recognition Method of Phased Array Radar Based on TCN-BiLSTM Parallel Processing. *3rd International Conference on Artificial Intelligence and Computer Engineering (ICAICE 2022)*, Wuhan, 4-6 November 2022. <https://doi.org/10.1117/12.2671073>
- [27] Qu, W., Yao, G. and Meng, L. (2023) Research on Radar PRI Modulation Pattern Recognition Based on Recurrent Neural Network. *2023 4th International Conference on Computer Vision, Image and Deep Learning (CVIDL)*, Zhuhai, 12-14 May 2023, 250-254. <https://doi.org/10.1109/cvidl58838.2023.10166809>
- [28] Kong, J. and Zhang, F. (2021) SAR Target Recognition with Generative Adversarial Network (GAN)-Based Data Augmentation. *2021 13th International Conference on Advanced Infocomm Technology (ICAIT)*, Yanji, 15-17 October 2021, 215-218. <https://doi.org/10.1109/icaity2638.2021.9701974>
- [29] Carr, C., Dang, B. and Metcalf, J. (2021) RADGAN: Applying Adversarial Machine Learning to Track-before-Detect Radar. *2021 IEEE Radar Conference (RadarConf21)*, Atlanta, 8-14 May 2021, 1-6. <https://doi.org/10.1109/radarconf2147009.2021.9455179>
- [30] Pu, W. (2022) Shuffle GAN with Autoencoder: A Deep Learning Approach to Separate Moving and Stationary Targets in SAR Imagery. *IEEE Transactions on Neural Networks and Learning Systems*, **33**, 4770-4784. <https://doi.org/10.1109/tnnls.2021.3060747>
- [31] Akcali, S. and Erden, F. (2021) Support of Data Augmentation with GAN on Faster R-CNN Based Buried Target Detection. *2021 29th Signal Processing and Communications Applications Conference (SIU)*, Istanbul, 9-11 June 2021, 1-4. <https://doi.org/10.1109/siu53274.2021.9477828>
- [32] Du, S., Hong, J., Wang, Y. and Qi, Y. (2022) A High-Quality Multicategory SAR Images Generation Method with Multiconstraint GAN for ATR. *IEEE Geoscience and Remote Sensing Letters*, **19**, Article ID: 4011005. <https://doi.org/10.1109/lgrs.2021.3065682>

-
- [33] Zhao, D., Guo, G., Ni, Z., Pan, J., Yan, K. and Fang, G. (2023) WAEGAN: A Gans-Based Data Augmentation Method for GPR Data. *IEEE Geoscience and Remote Sensing Letters*, **20**, Article ID: 3509005. <https://doi.org/10.1109/lgrs.2023.3323981>
 - [34] Xiong, H., Li, J., Li, Z. and Zhang, Z. (2024) GPR-GAN: A Ground-Penetrating Radar Data Generative Adversarial Network. *IEEE Transactions on Geoscience and Remote Sensing*, **62**, Article ID: 5200114. <https://doi.org/10.1109/tgrs.2023.3337172>
 - [35] Ju, M., Luo, H., Wang, Z., Hui, B. and Chang, Z. (2019) The Application of Improved YOLO V3 in Multi-Scale Target Detection. *Applied Sciences*, **9**, Article No. 3775. <https://doi.org/10.3390/app9183775>
 - [36] Kim, W., Cho, H., Kim, J., Kim, B. and Lee, S. (2020) Yolo-Based Simultaneous Target Detection and Classification in Automotive FMCW Radar Systems. *Sensors*, **20**, Article No. 2897. <https://doi.org/10.3390/s20102897>
 - [37] Xu, D. and Wu, Y. (2020) Improved YOLO-V3 with Densenet for Multi-Scale Remote Sensing Target Detection. *Sensors*, **20**, Article No. 4276. <https://doi.org/10.3390/s20154276>
 - [38] Tang, X., Zhang, X., Shi, J. and Wei, S. (2021) A Moving Target Detection Method Based on Yolo for Dual-Beam Sar. 2021 *IEEE International Geoscience and Remote Sensing Symposium IGARSS*, Brussels, 11-16 July 2021, 5315-5318. <https://doi.org/10.1109/igarss47720.2021.9554604>
 - [39] Kong, L., Wang, J. and Zhao, P. (2022) YOLO-G: A Lightweight Network Model for Improving the Performance of Military Targets Detection. *IEEE Access*, **10**, 55546-55564. <https://doi.org/10.1109/access.2022.3177628>
 - [40] Zhong, N., Bao, Q. and Yan, J. (2023) Intelligent Detection and Identification Method of Radar Moving Target. *3rd International Conference on Advanced Algorithms and Signal Image Processing (AASIP 2023)*, Kuala Lumpur, 30 June-2 July 2023. <https://doi.org/10.1117/12.3006011>