

基于 ResNet 的智能恒虚警目标检测方法

张晨¹, 叶舟², 吕宇宙², 方明², 高永婵¹

(1. 西安电子科技大学 电子工程学院, 陕西 西安 710068; 2. 上海航天电子通讯设备研究所, 上海 201109)

摘要: 传统恒虚警检测方法通常假设待测单元的杂波与训练杂波满足独立同分布, 然而在实际雷达工作环境中, 强杂波呈现出非均匀特性, 沿距离单元的杂波统计特性差异变化较大, 使得传统恒虚警目标检测方法在复杂环境下的检测性能下降。为解决该问题, 本文从杂波统计特征提取分类出发, 通过深度学习方法对杂波进行分类, 提出了一种基于残差神经网络(ResNet)的智能恒虚警目标检测方法。首先, 根据雷达实测杂波数据建立 ResNet 的训练集和测试集; 其次, 构建 ResNet 对数据进行智能特征提取, 得到杂波的统计特征, 并用训练好的网络对测试集进行测试; 最后, 以阈值可设的 Softmax 分类器对所得统计特征进行分类, 根据分类结果实现智能恒虚警目标检测。实验结果表明: 相比传统恒虚警检测方法, 本文提出的方法具有自适应能力更强、检测性能更好等优点。

关键词: 雷达目标检测; 残差神经网络; 恒虚警检测; 非均匀杂波

中图分类号: TN 957.51

文献标志码: A

DOI: 10.19328/j.cnki.2096-8655.2022.05.011

Intelligent Constant False Alarm Ratio Target Detection Method Based on ResNet

ZHANG Chen¹, YE Zhou², LYU Yuzhou², FANG Ming², GAO Yongchan¹

(1. Electronic Engineering Department, Xi'an University, Xi'an 710068, Shaanxi, China;

2. Shanghai Aerospace Electronic Technology Institute, Shanghai 201109, China)

Abstract: Conventional constant false alarm ratio (CFAR) detection method usually assumes that the clutter and training clutter of the unit to be tested are independent and distributed identically. However, in the actual radar working environment, the strong clutter shows non-uniform characteristics, and the statistical characteristics of clutter vary greatly along the range cell, which makes the detection performance of the conventional CFAR detection method decline in the complex environment. In order to solve this problem, this paper proposes an intelligent CFAR target detection method based on residual neural network (ResNet) through clutter statistical feature extraction and classification by the deep learning method. First, the training set and test set of ResNet are established based on radar clutter data. Then, the ResNet is constructed to extract intelligent features from the data, and the statistical characteristics of the clutter are obtained. The trained network is used to test the test set, and the statistical features are classified by the Softmax classifier with an adjustable threshold. Finally, according to the classification results, the intelligent CFAR target detection is realized based on the classification results. Experimental results show that compared with the conventional CFAR detection method, the proposed method has better adaptive ability and detection performance.

Key words: radar target detection; residual neural network; constant false alarm rate detection; heterogeneous clutter

0 引言

由于能提高雷达在杂波、干扰背景下检测目标的能力, 恒虚警检测技术一直是雷达信号处理理论

和应用研究的基本问题之一。FINN 等^[1]提出了单元平均恒虚警检测(Cell Average-Constant False Alarm Ratio, CA-CFAR)算法, 该算法通过计算邻

收稿日期: 2021-10-09; 修回日期: 2021-11-27

基金项目: 航天科技基金(SAST2018-098); 航空基金(20180181001); 基础研究计划领域基金(2019-JCJQ-JJ-060); 中国博士后科学基金(2019M653561、2020T130493); 陕西省青年人才托举计划(20190104)

作者简介: 张晨(1997—), 女, 硕士, 主要研究方向为雷达目标检测和杂波抑制。

通信作者: 高永婵(1985—), 女, 教授, 主要研究方向为雷达信号处理、目标检测和杂波抑制等。

近距离单元雷达杂波数据的统计平均值来估计待测单元的功率水平。CA-CFAR 检测算法要求待测单元的杂波与训练杂波数据满足独立同分布条件。然而,在实际雷达工作环境中,强杂波呈现出非均匀特性,沿距离单元的杂波统计特性差异变化较大,使得该算法的检测性能严重下降。

针对非均匀杂波环境给目标恒虚警检测带来的影响,国内外学者展开了大量研究^[1-9]。TRUNK 等^[4]提出的单元平均选小恒虚警检测(Smallest of CFAR, SO-CFAR)算法和 Hansen 等^[5]提出的单元平均选大恒虚警检测(Greatest of CFAR, GO-CFAR)算法均首先计算待测单元两边的平均功率水平,再选取其中一个作为该单元的功率水平,但这两种算法无法兼顾目标检测性能和恒虚警特性。ROHLING 等^[6]提出了排序统计恒虚警检测(Order Statistic CFAR, OS-CFAR)算法,该算法首先将邻近单元的数据按升序排序,然后按照规则选择某一个单元的数值来表示待测单元功率水平。王永良等^[8]提出了一种海杂波背景下的双参数有序统计恒虚警检测算法,该算法提高了在非均匀海杂波环境下的目标恒虚警检测性能,但同时带来了均匀杂波环境下检测性能下降和计算复杂度提高的问题。

作为一种高效的智能处理方法,深度学习能有效避免传统的复杂特征设计、具备较好的泛化能力^[10-15],目前在视频处理领域、雷达图像处理领域中取得了较好应用^[16-18]。残差神经网络(Residual Neural Network, ResNet)^[19-23]能解决随着网络加深而出现的梯度消失问题和退化问题,使网络在深层时具有更好的表达能力,具有挖掘杂波数据的高维数据特征和信息、实现雷达信号域智能处理的潜力。

因此,本文从杂波统计特征提取分类出发,提出了一种基于 ResNet 的智能恒虚警目标检测方法。首先,根据雷达实测杂波数据建立雷达回波信号样本数据库、ResNet 的训练集和测试集;其次,构建 ResNet 的智能提取杂波数据统计特征,并用该网络对测试集进行测试、实现分类;最后,根据分类结果实现基于 ResNet 的智能恒虚警目标检测。

1 传统恒虚警检测方法 & 杂波特性分析

当雷达系统在接收 K 个距离维回波数据后 $\{x_1, x_2, \dots, x_K\}$, 需检测判决待检距离单元内是否存在目标。目标检测问题可描述为以下二元检测:

$$\begin{cases} H_1: x_i = \alpha s + c_i \\ H_0: x_i = c_i \end{cases} \quad (1)$$

式中:假设 H_1 为目标存在; H_0 为目标不存在; s 为存在的目标; c_i 为第 K 个距离维的杂波数据。

经典的 CA-CFAR 检测基本原理:首先,假设训练单元内杂波与待测单元内杂波满足独立同分布条件,选取 M 个训练单元和 P 个保护单元;其次,根据训练单元和保护单元的个数设置滑动窗口大小,取滑动窗口内单元的平均值与标称因子相乘得到阈值;最后,与检测单元进行比较,如果检测单元大于阈值则判断存在目标;反之,则判断不存在目标。

杂波幅度分布特性是杂波数据统计分析的重要部分,将其作为筛选杂波样本数据的准则,能解决实际检测中面临的样本不满足独立同分布的问题,从而提高恒虚警目标检测性能。

大量实测雷达数据分析表明,在实际工作环境中,杂波幅度的距离单元呈现不同的统计分布特性,典型的分布有瑞利分布、对数正态分布、韦布尔分布和 K 分布。因此,区分不同幅度分布特性的杂波并建立服从相同分布的杂波样本数据子库是提高恒虚警目标检测性能的前提条件。

2 ResNet(RN)-CA-CFAR 算法

本文以 ResNet18 作为杂波数据预分类的网络模型。ResNet18 是一种深度残差神经网络,共有 20 层结构,其残差块的结构如图 1 所示。其卷积核大小为 3×3 , 维度为 64, 激活函数为 ReLU^[21], 且在 2 个残差块之间引入跳跃连接, 保证反向传播更新参数时不会出现梯度消失问题。




图 1 ResNet18 残差块结构

Fig. 1 Residual block structure of ResNet18

根据雷达实测杂波数据建立 ResNet 的训练集和测试集,其中训练集由某雷达对海飞行收集的杂波数据组成,测试集数据为 IPIX 雷达的海杂波测量试验中记录的杂波数据集子集。IPIX 雷达^[24-25]是一

个全相参的X波段雷达,由其得到的高分辨率雷达数据已经成为测试雷达目标检测算法的重要基准数据。利用训练集数据对ResNet18进行充分训练,并使用已有标签的测试集数据对已训练的神经网络进行性能测试,确保网络具备提取数据特征并实现准确分类的能力。

2.1 网络模型训练

根据已建的训练集,以雷达杂波数据构建ResNet,进行智能特征提取,得到杂波的统计特征。

利用海杂波雷达实测数据训练ResNet18,随机初始化网络的权重和偏置,通过随机梯度下降(Stochastic Gradient Descent, SGD)算法^[22]和交叉熵损失函数逐步迭代更新网络的参数。网络的参数设置如下:分段函数初始网络学习率 η_{0_seg} 为0.001,总迭代次数为100,类别数为4,批量大小(batchsize)为128。由于网络学习率 η 过大会导致网络不能收敛, η 过小会降低网络优化的速度,因此本文分别采用分段函数和指数衰减函数Exponential LR函数调整 η ,并比较2种 η 的调整函数对网络性能优化的影响。

Exponential LR更新 η 为

$$\eta = \eta_{0_exp} \cdot g^e \quad (2)$$

式中:指数函数初始学习率 η_{0_exp} 为0.05; g 为底数,取值为0.7; e 为训练的迭代次数。

η 随迭代次数变化如图2所示。




图2 η 变化曲线

Fig. 2 η curves

在保证其他超参数不变的情况下,将 η 分别设置为随迭代次数变化的分段函数和Exponential LR函数, η 设置情况见表1。根据表1和式(2)中 η 的设置情况充分训练网络,得到网络在训练过程中的损失函数值随训练次数变化如图3所示。

表1 η 设置情况

Tab. 1 Setting of η

迭代次数 n /次	$n < 20$	$20 \leq n < 30$	$30 \leq n < 40$	$40 \leq n < 45$	$n \geq 45$
η	0.001	0.0005	0.0002	0.0001	0.00003




图3 损失函数值变化曲线

Fig. 3 Relationship between the iteration number and the loss function

由图3可知,随着训练迭代次数的增加,网络的损失函数值逐渐减小。采用分段函数调整 η 的初始网络的损失函数值约为1.25,随着训练迭代次数的增加逐渐减少,最终近乎趋近于0。采用Exponential LR函数调整 η 的初始网络的损失函数值约为1.1,随着训练迭代次数的增加逐渐减少,最终近乎趋近于0.02,这说明网络得到较充分的训练,网络性能得到优化。

批量大小对训练精度和网络收敛速度的影响很大,不同批量大小在测试集下的网络收敛情况曲线如图4(a)所示,不同批量大小在训练集下的网络收敛情况曲线如图4(b)所示。由图4可知,随着批量大小的增大,网络分类准确率达到相同精度所需

的迭代次数增多。但批量越大,每次迭代训练的数据就越多,当训练数据量很大时,增大批量大小可缩短整个训练过程的时间,且保证网络能够收敛。




图 4 批量大小与损失函数关系曲线

Fig. 4 Relationship between the batchsize and the loss function

2.2 网络模型测试

基于所构建的 ResNet, 本节将对数据进行智能特征提取, 得到杂波的统计特征, 用训练好的网络对已知标签的测试集进行测试, 并对统计特征进行分类, 验证网络的泛化能力。

本节所用的测试集数据是 IPIX 雷达的海杂波测量试验中记录的数据子集。测试集数据与训练集数据由来自不同地点、不同时间的不同雷达采集所得。测试数据集共包含有 400 个数据, 其中杂波幅度特性满足 K 分布、对数正态分布、瑞利分布以及韦布尔分布的数据各 100 个。输入测试集数据, 经训练的 ResNet18 提取数据统计特征, 再以阈值可设的 Softmax 分类器对所得统计特征进行分类, 根据测试集数据的真实分类和经网络得到的预测分类, 分别记录 4 种杂波幅度特性数据正确分类的数据个数, 并计算 4 种杂波幅度特性分类的准确率结果见表 2。

表 2 测试集分类准确率

Tab. 2 Test set classification accuracy

项目	分段函数			
	K 分布	对数正态分布	瑞利分布	韦布尔分布
各分类总数/个	100	100	100	100
正确分类数/个	100	98	94	86
各分类准确率/%	100	98	94	86
平均准确率/%	94.50			
项目	Exponential LR 函数			
	K 分布	对数正态分布	瑞利分布	韦布尔分布
各分类总数/个	100	100	100	100
正确分类数/个	100	94	91	92
各分类准确率/%	100	94	91	92
平均准确率/%	94.25			

由表 2 可知, 分段函数调整 η 的 ResNet18 经过充分训练能以较高的准确率实现杂波幅度特性分类, 但服从韦布尔分布的杂波数据相比于服从 K 分布、对数正态分布和瑞利分布的杂波数据较少。因此, 网络关于服从韦布尔分布的杂波数据分类训练不充分, 导致分类正确率较其他三类略低。经 Exponential LR 函数调整 η 得到的分类准确率结果较为均匀, 表明自动调整 η 的训练网络能在一定程度上降低训练样本数量较少对网络性能优化产生的影响。

实验结果表明: 基于 ResNet18 的杂波幅度特性分类算法效果优良, 在后续的处理中可首先利用 ResNet18 准确对杂波数据进行预分类处理, 为剔除样本和建立杂波信号模型做了充分准备。

2.3 RN-CA-CFAR 检测

根据分类结果实现基于 ResNet 的智能恒虚警目标检测, RN-CA-CFAR 检测器结构如图 5 所示。




图 5 RN-CA-CFAR 检测器结构

Fig. 5 Structure diagram of the RN-CA-CFAR detector

RN-CA-CFAR检测的具体步骤如下:

步骤1 根据分类结果建立不同幅度特性的杂波样本数据子库 $X_r, X_w, X_{\log}$ 和 X_K ;

步骤2 根据待检单元 $x_i (i=1, 2, \dots, K, i$ 为待检距离门的总数) 服从的杂波幅度特性, 在相应的杂波样本数据子库中选取与该待检单元临近的 N 个检测单元作为训练单元集 X_N ;

步骤3 计算待检单元的背景功率 $P_i = |x_i|^2$;

步骤4 计算训练单元集 X_N 的平均值 $V_i = \frac{1}{N} \left\{ \sum_{x_i \in X_N} x_i \right\}$ 作为待检单元 x_i 的背景功率水平;

步骤5 利用门限因子计算门限 $T_{CA} = \alpha_{CA} V_i$, 其中 α_{CA} 为根据所设定的虚警概率, $\alpha_{CA} =$

$N \left(P_{fa}^{-\frac{1}{N}} - 1 \right)$, 虚警概率 P_{fa} 和训练单元个数 N 确定的门限因子;

步骤6 重复步骤2~步骤5, 直到计算出所有 K 个待检单元的检测统计量为止;

步骤7 根据自适应判决准则判定是否存在目标, 自适应判决准则如下:

$$\begin{matrix} H_1 \\ P_i > T_{CA} \\ H_0 \end{matrix} \quad (3)$$

式中: H_1 为存在目标; H_0 为不存在目标。

根据以上过程, 本文提出的 RN-CA-CFAR 检测方法的算法总体实现框如图6所示。




图6 RN-CA-CFAR检测方法总体实现框

Fig. 6 Realization process of the RN-CA-CFAR detection method

3 实验结果及分析

本节所用数据是IPIX雷达的海杂波测量试验中记录的数据集子集: 总共包含34个距离单元, 每个距离单元的采样点数为60 000个, 每个实验使用全部距离单元的前12 544个采样点, $P_{fa} = 10^{-6}$, 训

练单元个数 N 为6, 试验参数为目标的信杂噪比 (Signal Clutter Noise Ratio, SCNR)。实验分为2组, 该实验数据不含目标, 因此在实验1中插入2个仿真目标, 在实验2中插入3个仿真目标, 目标信息见表3、表4。加入目标后的距离-脉冲如图7所示。

表3 实验中各大目标的参数

Tab. 3 Parameters of each big target in Experiment 1 and 2

参数	实验1		实验2		
	目标1	目标2	目标1	目标2	目标3
SCNR/dB	40	20	40	20	20
所在距离单元	6	14	6	14	23

表4 实验中各小目标的参数

Tab. 4 Parameters of each small targets in Experiment 1 and 2

参数	实验1		实验2		
	目标1	目标2	目标1	目标2	目标3
SCNR/dB	20	10	20	10	10
所在距离单元	6	14	6	14	23




图 7 距离-脉冲回波

Fig. 7 Range-pulse echo pattern

3.1 实验 1 结果及分析

含 2 个目标的回波数据分别在 2 组不同 SCNR 下的恒虚警检测结果如图 8 所示。




图 8 存在 2 个目标的恒虚警检测

Fig. 8 Schematic diagram of CFAR detection with 2 targets

其中,图 8(a)的第 6 个距离单元目标的 SCNR 为 20 dB,第 14 个距离单元目标的 SCNR 为 10 dB;图 8(b)的第 6 个距离单元目标的 SCNR 为 40 dB,第 14 个距离单元目标的 SCNR 为 20 dB。

图 8 为分别使用 CA-CFAR、OS-CFAR 和 RN-CA-CFAR 检测器对回波数据进行目标检测的阈值曲线示意图。

由图 8(b)可知,当目标具有较大的 SCNR 时,由于目标功率较强,3 种检测器均表现出良好的检测性能;由图 8(a)可知,当目标具有较小的 SCNR 时,CA-CFAR 检测器和 OS-CFAR 检测器均不能有效检测第 6 和 14 个距离单元是否存在目标,而本文提出的 RN-CA-CFAR 检测器则对目标具有较小的 SCNR 表现出良好的检测性能。因此,本文提出的 RN-CA-CFAR 检测器有效提高了在复杂海杂波背景下对弱小目标的检测性能,自适应能力更强。

3.2 实验 2 结果及分析

含 3 个目标的回波数据分别在两组不同 SCNR 下的恒虚警检测结果如图 9 所示。




图9 存在3个目标的恒虚警检测

Fig. 9 Schematic diagram of CFAR detection with 3 targets

其中:图9(a)的第6个距离单元目标的SCNR为20 dB,第14个距离单元目标的SCNR为10 dB,第23个距离单元目标的SCNR为10 dB;图9(b)的第6个距离单元目标的SCNR为40 dB,第14个距离单元目标的SCNR为20 dB,第23个距离单元目标的SCNR为20 dB。

由图9(b)可知,对于目标功率较强的情况,3种恒虚警检测器均能检测到目标信号,其中CA-CFAR对20 dB目标的检测性能较弱;由图9(a)可知,对于目标具有较小的SCNR=10 dB,CA-CFAR检测器和OS-CFAR检测器不能在第16个和第23个距离单元有效检测出是否存在目标,而本文提出的RN-CA-CFAR检测器则表现出良好的检测性能。因此,本文提出的RN-CA-CFAR检测器相比于传统恒虚警检测器性能更优。

4 结束语

由于观测环境、雷达平台以及雷达参数等因素影响,通常导致获取的雷达回波数据不满足独立同分布条件,使得传统恒虚警检测器性能不理想。针对该问题,本文提出了一种基于ResNet的智能恒虚警目标检测方法。该方法通过雷达实测杂波数据构建ResNet提取杂波统计特征,再通过测试数据进

行分类,进而实现智能恒虚警目标检测。实验结果表明,相比传统恒虚警目标检测方法,本文方法具有以下优点:①引入深度学习思想,准确高效地完成了杂波数据分类和样本筛选,获得服从独立同分布的杂波训练数据;②自适应能力更强,在实际非均匀杂波环境下检测性能更好。

参考文献

- [1] FINN H M, JOHNSON R S. Adaptive detection mode with threshold control as a function of spatially sampled clutter-level estimates [J]. Rca Review, 1968, 29: 414-464.
- [2] 何友,关键,孟祥伟,等.雷达目标检测与恒虚警处理[M].2版.北京:清华大学出版社,2002.
- [3] 何友,关键,彭应宁.雷达自动检测和CFAR处理方法综述[C]//第七届全国雷达学术年会论文集.南京:中国电子学会无线电定位技术分会,1999:329-334.
- [4] TRUNK G V. Range resolution of targets using automatic detectors[J]. IEEE Transactions on Aerospace and Electronic Systems, 1978, 14(5):750-755.
- [5] HANSEN V G, SAWYERS J H. Detectability loss due to "greatest of" selection in a cell-averaging CFAR [J]. IEEE Transactions on Aerospace and Electronic Systems, 1980, 16(1):115-118.
- [6] ROHLING H. Radar CFAR thresholding in clutter and multiple target situations [J]. IEEE Transactions on Aerospace and Electronic Systems, 1983, 19(4):608-621.
- [7] 韩超全,杨志伟,田敏,等.基于海杂波稀疏性与非均匀度的样本挑选方法[J].上海航天(中英文),2018,35(5):25-31.
- [8] 杜鹏飞,王永良.海杂波背景中的一种恒虚警率检测方法[J].国防科技大学学报,2005,27(3):54-57.
- [9] 郝程鹏,刘斌,闫晟,等.基于有序统计和自动删除平均的最大选择恒虚警检测器[J].信号处理,2008(4): 578-581.
- [10] KRIZHEVSKY, A, SUTSKEVER, I, HINTON G E. ImageNet classification with deep convolutional neural networks [J]. Communications of the ACM, 2017, 60(6): 84-90.
- [11] 陈潜,陆满君,宋柯,等.相控阵雷达导引头技术现状及发展趋势[J].上海航天(中英文),2021,38(3):157-162,177.
- [12] ZEILER M D, FERGUS R. Visualizing and understanding convolutional neural networks [C]// European Conference on Computer Vision. New York: Springer, 2014:818-833.
- [13] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with

- convolutions [C]// 2015 IEEE Conference on Computer Vision and Pattern Recognition. Boston, MA: IEEE, 2015: 15523970.
- [14] 戴维·阿兰·格里尔, 孙晓明. 深度学习[J]. 中国计算机学会通讯, 2018, 14(3): 72-73.
- [15] LECUN Y, BENGIO Y, HINTON G. Deep learning [J]. Nature, 2015, 521(7553): 436.
- [16] LI D, LIANG Q H, LIU H Q, et al. A novel multidimensional domain deep learning network for SAR ship detection [J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1-13.
- [17] 徐丰, 王海鹏, 金亚秋. 深度学习在 SAR 目标识别与地物分类中的应用[J]. 雷达学报, 2017, 6(2): 136-148.
- [18] 张晓玲, 张天文, 师君, 等. 基于深度分离卷积神经网络的高速高精度 SAR 舰船检测[J]. 雷达学报, 2019, 8(6): 841-851.
- [19] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C]// 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, NV: IEEE, 2016: 16541111.
- [20] HE K, ZHANG X, REN S, et al. Identity mappings in deep residual networks [EB/OL]. (2016-05-16) [2021-06-20]. <https://arxiv.org/abs/1603.05027>.
- [21] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [EB/OL]. (2014-09-04) [2021-06-20]. <https://arxiv.org/abs/1409.1556>.
- [22] BOTTOU L, BOUSQUET O. The tradeoffs of large scale learning [EB/OL]. (2017-12-03) [2021-06-20]. <https://papers.nips.cc/paper/3323-the-tradeoffs-of-large-scale-learning.pdf>.
- [23] 苏宁远, 陈小龙, 关键, 等. 基于卷积神经网络的海上微动目标检测与分类方法[J]. 雷达学报, 2018, 7(5): 565-574.
- [24] 邓泽怀. 基于实测数据的海杂波统计建模[D]. 西安: 西安电子科技大学, 2014.
- [25] 梅孝安. IPIX 雷达海尖峰统计特性研究[J]. 飞行器测控学报, 2007, 26(2): 19-23.

欢迎关注本刊微信公众号

为了加强《上海航天(中英文)》数字化、网络化建设以及信息化管理, 扩大刊物宣传力度, 本刊现已开通微信公众平台。关注微信公众号后, 读者可查阅期刊发表论文, 进行文章检索; 作者可随时查询自己稿件的处理状态, 了解期刊最新发展动态; 编辑部能更便捷地加强编者、作者和读者之间的交流, 促进学术沟通, 创建学术共同体, 扩大《上海航天(中英文)》期刊的学术影响力。

