

DOI:10.3969/j.issn.1672-2337.2025.01.004

基于图神经网络的多尺度特征融合雷达目标检测方法

汪翔, 王彦斌, 汪育苗, 崔国龙

(电子科技大学信息与通信工程学院, 四川成都 611731)

摘要: 本文针对复杂杂波环境下的雷达目标检测问题,提出了一种基于图神经网络的多尺度特征融合雷达目标检测方法,该方法利用多个脉冲回波之间的特征关联性检测目标。具体而言,其首先利用多个级联的特征提取模块从回波中提取多尺度特征。然后,该方法利用多尺度特征构造多个有向完全图,图中每个节点对应一个脉冲。之后,每个节点利用图神经网络的消息传播机制聚合其邻居节点的信息,以此学习脉间回波高阶相关性。进一步地,该方法融合多尺度特征以丰富对目标和杂波的特征表示。最后,对融合后特征进行非线性映射,以二分类的形式得到检测结果。基于公开雷达数据集的试验验证了所提方法的有效性。

关键词: 雷达目标检测; 杂波环境; 图神经网络; 多尺度特征融合

中图分类号: TN959.1⁺1

文献标志码: A

文章编号: 1672-2337(2025)01-0039-09

引用格式: 汪翔, 王彦斌, 汪育苗, 等. 基于图神经网络的多尺度特征融合雷达目标检测方法[J]. 雷达科学与技术, 2025, 23(1):39-47.

WANG Xiang, WANG Yanbin, WANG Yumiao, et al. Graph Neural Network Based Radar Target Detection Method with Multi-Scale Feature Fusion[J]. Radar Science and Technology, 2025, 23(1):39-47.

Graph Neural Network Based Radar Target Detection Method with Multi-Scale Feature Fusion

WANG Xiang, WANG Yanbin, WANG Yumiao, CUI Guolong

(School of Information and Communication Engineering, University of Electronic Science and Technology of China, Chengdu 61731, China)

Abstract: Aiming at the problem of radar target detection in complex clutter environment, a graph neural network-based radar target detection method with multi-scale feature fusion is proposed in this paper, which uses the feature correlations among multiple pulse echoes for the detection. Firstly, the proposed method utilizes multiple cascaded feature extraction modules to extract multi-scale features. Subsequently, it constructs multiple directed complete graphs using multi-scale features, where a node in a graph corresponds to a pulse, and the node features of each graph are the features of the corresponding scale. Then, each node can aggregate the information of its neighbors using the graph neural network, and the proposed method can therefore learn the higher-order correlation among the pulse echoes. Further, the proposed method fuses multi-scale features to enrich the feature representation of the target and the clutter. Finally, the fused features are mapped nonlinearly, and the detection results are obtained in the form of binary classification. The effectiveness of the proposed method is verified using the public radar database.

Key words: radar target detection; clutter environment; graph neural network; multi-scale feature fusion

0 引言

雷达由于其全天时全天候的工作优点被广泛用于目标探测。雷达目标检测是雷达系统应用的基本功能,是后续对目标跟踪和识别的前提任务^[1]。然而,在很多情况下,雷达接收到的回波中不止包含感兴趣的目标信号,还会包含杂波回波。

在复杂环境下,杂波的回波能量可能远大于目标能量,严重影响雷达检测性能。因此,复杂杂波环境下的雷达目标检测一直以来都是相关领域研究的重点和难点,受到研究人员的广泛关注。

传统的均值类恒虚警率(Constant False Alarm Rate, CFAR)检测器通过估计杂波的功率计算检测阈值并将其和待检测单元(Cell Under Test, CUT)

收稿日期: 2024-12-17; 修回日期: 2025-01-15

基金项目: 国家自然科学基金(No.62271126)

的功率进行对比以判断目标回波的存在性。但是,当信杂比(Signal to Clutter Ratio, SCR)不断降低时,该类方法的检测性能将显著降低^[2]。在高斯噪声背景下,典型的目标能量积累算法,如距离-多普勒处理,可以提高目标能量,增加目标检测概率。然而,在复杂杂波场景中,由于杂波的非高斯性,这些算法性能下降严重。因此,亟需提出新的检测算法来缓解传统算法的不足。

一个比较流行的方法是利用回波构建特征以区分目标和杂波。这些特征有分形特征^[3]、频率特征^[4]和极化特征^[5]等。此外,多个特征可以被组合起来用于扩大杂波和目标的差异性^[6-7]。在获取目标和杂波的典型特征后,利用凸包学习^[8]、K近邻分类器^[9]、支持向量机分类器^[10]等机器学习方法实现对杂波和目标样本的辨别。然而,该方法往往需要雷达进行长时间的观测获取相参回波,在一些雷达系统中可能不适用。此外,这些特征是基于对杂波和目标鉴别的先验知识人工设计的,开发新的特征或者多个特征的联合处理过程较为繁琐。

近年来,深度学习技术各个领域获得了令人瞩目的应用性能。目前,其已被广泛用于雷达领域^[11]。深度学习技术具有自动特征提取和不依赖数据先验知识的特点^[12]。因此,相关学者也利用深度学习技术开发雷达目标检测器,并展现出了令人鼓舞的试验结果。文献[13]基于卷积神经网络设计了一个目标检测器,并将其和典型CFAR检测器进行了性能对比,发现在一些条件下,高斯噪声背景下基于卷积神经网络的目标检测器性能优于CFAR检测器。文献[14]也有类似的结论。此外,由于深度学习技术是数据驱动的,在应用时不需要对杂波模型进行预先假设,很适合复杂杂波环境下雷达目标检测的需求。基于深度学习技术,文献[15-16]设计了海杂波环境下的弱小目标检测方法,文献[17]开发了基于地杂波环境下的目标检测器。此外,由于图神经网络能够学习信号分量之间的相互关系,文献[18-19]等基于图神经网络技术开发了海杂波环境下的目标检测器,取得了较好的检测性能。然而,这些检测器要求雷达有较长的观测时间。因此,需要探究利用较少的观测时间实现目标检测的可行性。

为此,本文提出了基于图神经网络的多尺度特征融合检测方法,旨在利用几个脉冲回波之间的特征关联性实现复杂杂波环境下的目标检测。该方法首先利用多个级联的特征提取模块从回波中提取多尺度特征。然后,将对应每个尺度的特征构造一个有向完全图,图中的每个节点对应一个脉冲,每个节点的特征为特征提取模块从该脉冲回波中提取的。基于构造的图,利用图神经网络聚合节点和邻居节点的信息,学习节点之间的高阶相互关系。之后,该方法通过融合不同图之间相同索引的节点的多尺度特征以进一步提高杂波和目标之间的鉴别度。最后,考虑到雷达目标检测本质上是个二分类任务,该方法对融合后特征进行非线性降维,以二分类的形式检测目标。基于公开的《雷达学报》对海探测数据集^[20]评估了所提方法的性能。

1 信号模型

假设雷达发射 N 个周期的线性调频(Linear Frequency Modulation, LFM)信号探测复杂杂波环境下的一个点目标,LFM信号波形为

$$s(t) = \text{rect}\left(\frac{t}{\tau}\right) \exp\left(j2\pi\left(f_0 t + \frac{1}{2} k t^2\right)\right) \quad (1)$$

式中: f_0 表示雷达工作载频; $k = \frac{B}{\tau}$ 表示调频斜率,其中 B 为信号带宽, τ 为信号脉宽。 $\text{rect}\left(\frac{t}{\tau}\right)$ 满足下式:

$$\text{rect}\left(\frac{t}{\tau}\right) = \begin{cases} 1, & \left|\frac{t}{\tau}\right| \leq \frac{1}{2} \\ 0, & \text{其他} \end{cases} \quad (2)$$

假设目标和雷达之间的径向距离为 R_0 ,目标速度为 v ,雷达发射波形的脉冲重复周期为 T ,则雷达在第 n 个脉冲重复周期接收到的基带目标回波可以表示为

$$s_r(t) = A_0 \text{rect}\left(\frac{t - 2(R_0 + nT_r v)/c}{\tau}\right) \exp\left(-j\frac{4\pi f_0 (R_0 + nT_r v)}{c}\right) \exp\left(j\pi k \left(t - \frac{2(R_0 + nT_r v)}{c}\right)^2\right) \quad (3)$$

式中, A_0 为回波幅度, c 为光速。

经过匹配滤波后, 可得雷达接收到的基带目标回波信号为

$$s_p(t) = A_1 \operatorname{sinc} \left(B \left(t - \frac{2(R_0 + nT_r v)}{c} \right) \right) \exp \left(-j \frac{4\pi f_0 (R_0 + nT_r v)}{c} \right) \quad (4)$$

式中, $\operatorname{sinc}(\cdot)$ 表示辛格函数, A_1 为匹配滤波后回波幅度。

考虑雷达接收回波中还包含杂波回波, 雷达接收回波信号为

$$s_a(t) = s_p(t) + c(t) \quad (5)$$

式中, $c(t)$ 为杂波回波信号。

对 $s_a(t)$ 进行采样和重排, 可以得到 N 个脉冲对应的回波矩阵, 记作 $\mathbf{E} \in \mathbb{C}^{N \times R}$, 其中 R 为快时间维度采样点数, 即所谓的距离单元数。本文旨在基于图神经网络构建雷达目标检测器, 利用较小 N 的回波矩阵实现复杂杂波环境下的雷达目标检测任务。

2 基于图神经网络的多尺度特征融合检测方法

为了从复杂杂波环境雷达回波中检测出包含目标回波的距离单元, 设计了一种基于图神经网络的多尺度特征融合雷达目标检测方法, 其模型结构如图1所示。

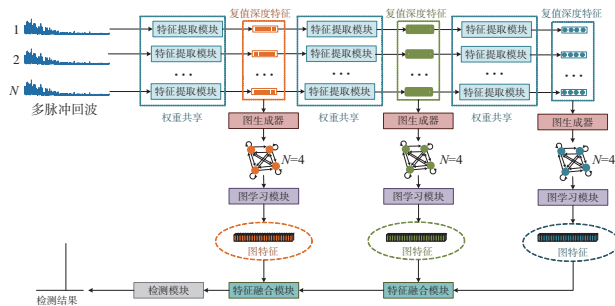


图1 基于图神经网络的多尺度特征融合雷达目标检测方法模型结构

所设计的检测模型主要由级联的特征提取模块、图生成器、图学习模块、特征融合模块以及检测模块构成。简单来说, 多个级联的特征提取模块从多脉冲回波中提取多级复值深度特征, 将回波映射到高维空间以增加目标回波和杂波回波的

可分性; 图生成器将多级复值深度特征构造多个独立的有向完全图以支撑模型后续学习脉间回波相关性; 图学习模块可学习脉间回波的相关性并从有向完全图中提取图特征; 特征融合模块将多级图特征进行融合, 以丰富对脉间回波的特征表示; 检测模块通过将融合后的图特征非线性映射到二元概率空间, 以对特征进行二分类的形式获取检测结果。下面对这些模块进行详细说明。

2.1 特征提取模块

雷达接收到的回波通常以复数形式储存并进行后续信号处理。回波的幅度能反映目标的散射强度, 而相位则能反映目标的运动信息, 因此利用复值雷达回波数据进行特征提取可以充分利用数据信息。同时, 鉴于近年来复值卷积神经网络已被实验验证其能够充分利用复数据的幅相信息实现多种雷达任务^[21-22]。因此, 所提架构中的特征提取模块是基于复值卷积神经网络构建的, 其结构为两个级联的复值卷积层、复值批归一化层和复值 ReLU 函数, 旨在从维度大小为 $1 \times N \times R$ 的多脉冲回波中提取复值深度特征, 其中3个维度依次代表: 通道数(人为扩展的)、脉冲数和距离单元数。

值得注意的是, 在图1所示的所提方法架构中包含多级特征提取模块, 每级特征提取模块提取对应尺度的复值深度特征。此外, 为了保持特征提取的稳定性, 每个相同级对应特征提取模块之间的参数是权重共享的。考虑到点目标在整段回波中只占很少的几个连续距离单元, 若在提取多级复值深度特征时像常规任务那样对回波距离维度进行下采样, 可能会造成目标特征的丢失或者目标特征和杂波特征的混淆, 因此在特征提取的时候不会对回波的距离维尺寸进行下采样。对应地, 复值卷积层的尺寸是针对目标检测任务特别设计的。具体来说, 复值卷积层的卷积核尺寸为 $(1, 3)$, 步长为 $(0, 2)$, 填充尺寸为 $(0, 1)$, 这样尺寸的复值卷积层在提取特征时不会造成回波距离维尺寸的减少, 因此不会造成目标特征的丢失。同时, 这样尺寸的复值卷积层也可以尽可能避免目标特征和杂波特征的混淆。下面我们以图解形式说明这一点。考虑一段尺寸为 1×5 的回波段,

目标回波最强点位于第 3 个距离单元,卷积过程如图 2 所示。




图 2 卷积示意图

如图 2 所示,卷积过后获得的结果里目标回波距离单元仍然为第 3 个距离单元,且卷积结果中目标回波距离单元由输入中目标主要回波单元参与计算获得,因此不会造成目标特征和杂波特征的混淆。复值批归一化层用于加速模型收敛以及防止模型过拟合。复值 ReLU 层用于为模型提供非线性映射能力,在此不做赘述。所提通过 3 个级联的特征提取模块,一共获得 3 个尺度的复值深度特征。3 个尺度的复值深度特征的尺寸大小分别为 $64 \times N \times R$, $128 \times N \times R$ 和 $256 \times N \times R$ 。

2.2 图生成器

最近,很多研究将信号建模成图,并在图域聚合数据之间的相关性以及学习数据之间的依赖性,取得了令人鼓舞的结果^[23-24]。受此启发,我们将每级特征提取模块从多脉冲回波中提取的复值深度特征建模成图。本文中,将图记为 $G = (V, E)$,其中, V 为图的节点集合,每个脉冲回波/特征对应图中的一个节点, E 为图的边集合。为了一个节点的信息能被其他节点充分感知,我们将图构建为一个带有自连接边的有向完全图,其邻接矩阵 A 为一个全 1 矩阵:

$$A = \begin{bmatrix} 1 & 1 & \cdots & 1 \\ 1 & 1 & \cdots & 1 \\ \vdots & \vdots & & \vdots \\ 1 & 1 & \cdots & 1 \end{bmatrix}_{N \times N} \quad (6)$$

以 $N = 4$ 为例,这个有向完全图的图结构如图 3 所示。

这里,将第 i 节点 $v_i \in V$ 的节点特征记作 $\mathbf{h}_i \in \mathbb{C}^{C \times 1 \times R}$, $C = 64, 128, 256$, 表示提取的第 i 脉冲回波的复值深度特征。




图 3 有向完全图图结构($N = 4$)

2.3 图学习模块

在获得有向完全图后,我们利用图学习模块提取高维图特征,对脉间回波特征表示进行精炼化。遵循图神经网络的消息传播工作模式^[25],图学习模块由两个阶段组成,分别是消息传播阶段和读出阶段。

消息传播阶段通过将一个节点邻居节点的信息传播到此节点使其感知到其他节点的信息,然后对当前节点特征表示进行更新。对于一个节点 v_i ,其消息传播阶段可通过下式表示:

$$\tilde{\mathbf{h}}_i = U(M(\mathbf{h}_i), \mathbf{h}_i) \quad (7)$$

式中, \mathbf{h}_i 表示 v_i 的特征, $M(\cdot)$ 是消息传播函数,由下式计算得到:

$$M(\mathbf{h}_i) = \sum_{v_j \in N_i} \mathbf{h}_j \quad (8)$$

$U(\cdot)$ 表示节点特征更新函数,在此,因为卷积门控循环单元(ConvGRU)可以感知数据的状态转换关系,我们利用 ConvGRU 作为 $U(\cdot)$,其过程可以表示为

$$\begin{aligned} \mathbf{z}_i &= a\left(\sigma\left(\text{Conv}\left[\mathbf{h}_i \oplus \tilde{\mathbf{h}}_i\right]\right)\right) \\ \mathbf{r}_i &= b\left(\sigma\left(\text{Conv}\left[\mathbf{h}_i \oplus \tilde{\mathbf{h}}_i\right]\right)\right) \\ \bar{\mathbf{h}}_i &= f\left(\text{Conv}\left[\left(\mathbf{r}_i \odot \mathbf{h}_i\right) \oplus \tilde{\mathbf{h}}_i\right]\right) \\ \hat{\mathbf{h}}_i &= (1 + 1j - r_i)\tilde{\mathbf{h}}_i + r_i \odot \bar{\mathbf{h}}_i \end{aligned} \quad (9)$$

式中, $\sigma(\cdot)$ 表示实部和虚部的 Sigmoid 函数, $f(\cdot)$ 表示实部和虚部的 tanh 函数, \oplus 表示通道维度的串接运算, $a(\cdot)$ 和 $b(\cdot)$ 分别表示取张量的通道维度前半部分和后半部分。

在经过消息传播阶段后,全连通图中的每个节点都感知到了其邻居节点的信息并通过边加权求和邻居节点的信息学习到了彼此的高阶相

关性。

在读出阶段中,图学习模块脉间回波特征表示进行精炼化获取图特征。读出阶段可表示为

$$g = O(\hat{h}_1, \hat{h}_2, \dots, \hat{h}_N) \quad (10)$$

式中, $O(\cdot)$ 表示读出函数。由于检测实际上是一个对距离单元回波进行0-1分类的过程,为了同时利用多个脉冲的信息对距离单元类别进行分类,本文中, $O(\cdot)$ 为通道维度的串接运算与两个 1×1 卷积运算、BN运算和ReLU运算的级联:

$$O(\hat{h}_1, \hat{h}_2, \dots, \hat{h}_N) = \text{ReLU}(\text{BN}(\text{Conv}(\text{ReLU}(\text{BN}(\text{Conv}(\hat{h}_1 \oplus \hat{h}_2 \oplus \dots \oplus \hat{h}_N)))))) \quad (11)$$

2.4 特征融合模块

在获取多级图特征后,为了丰富对目标和杂波的特征表示,我们利用特征融合模块对多级图特征从高级到低级进行融合,如图1所示。具体来说,假设有两级图特征,高级图特征 $\mathbf{G}_1 \in \mathbb{C}^{C_1 \times 1 \times R}$ 和低级图特征 $\mathbf{G}_2 \in \mathbb{C}^{C_2 \times 1 \times R}$,特征融合模块首先利用通道维串接操作串接 \mathbf{G}_1 和 \mathbf{G}_2 ,然后利用两个级联的复值卷积层+复值批归一化层+复值ReLU函数对串接后的特征进行进一步非线性特征提取。两个复值卷积层的卷积核尺寸为(1,3),步长为(1,2),填充尺寸为(0,1),输出通道数均为 C_2 。在这里,从右往左第一个特征融合模块的输出通道数为128,第二个特征融合模块的输出通道数为64。

2.5 检测模块

在获得融合特征后,利用检测模块将特征进行非线性降维并映射到二元概率分类空间,以特征二分类的形式获取检测结果。具体来说,首先利用复值卷积层+复值批归一化层+复值ReLU函数对特征进行非线性降维,复值卷积层的卷积核尺寸为(1,3),步长为(1,2),填充尺寸为(0,1)。由于二元概率空间是实数空间,所以接着利用取模运算将非线性降维后的复值特征投影到实数域,然后利用一个实值卷积运算将投影后的特征进一步非线性降维到二维空间,实值卷积层卷积核尺寸为(1,3),步长为(1,2),填充尺寸为(0,1)。实值卷积运算的输出尺寸为 $2 \times 1 \times R$,最后利用


Softmax运算,将每个距离单元的二维特征映射到二维概率空间,以获得最终的检测结果。

3 试验评估


3.1 试验设置

3.1.1 仿真目标数据集构建

构建仿真目标数据集评估所提方法性能,具体来说,利用《雷达学报》雷达对海探测数据对所提检测器检测性能进行评估。试验利用“20210106155330_01_staring”数据构建训练集,利用“20210106155432_01_staring”数据构建测试集。两个数据集均为HH极化纯杂波回波数据,两个数据集对应的幅度图如图4所示。从图中可以看到,两个数据集中不同区域的杂波强度不尽相同。给出“20210106155330_01_staring”数据集的第500、2500个距离单元回波的经验概率密度拟合结果如图5所示,可以进一步看出杂波数据的分布是非高斯的,不同区域杂波的概率分布差异很大,具有非均匀性。



(a) “20210106155330_01_staring”数据幅度图



(b) “20210106155432_01_staring”数据幅度图

图4 两个数据集幅度图




图5 经验概率密度函数拟合

向图4所示两个数据中添加具有相应SCR仿真目标回波构建所提方法所需的训练集和测试集。在本文中SCR定义如下：

$$SCR = 10 \log_{10} \left(\frac{P_t}{P_c} \right) \quad (12)$$

式中, P_t 是目标回波功率, P_c 表示杂波回波功率, 第 l 个距离单元对应的杂波功率由添加目标单元周围杂波单元的功率估计而来：

$$P_c = \frac{1}{2N} \left(\sum_{j=l-G-P}^{l-P} |\mathbf{E}(i,j)|^2 + \sum_{j=l+P}^{l+G+P} |\mathbf{E}(i,j)|^2 \right) \quad (13)$$

式中, $\mathbf{E}(i,j)$ 为第 i 个脉冲的第 j 个距离单元回波数据, P 为保护单元数目, G 为估计杂波功率的参考单元数目。

为了构建训练集,向“20210106155330_01_staring”纯杂波数据添加SCR从-12~12 dB的仿真目标回波,其中添加的SCR间隔为2 dB。对于每个SCR,添加多个目标,目标添加的距离单元位置随机。构造的训练集幅度图如图6所示。




图6 训练集幅度图(红线代表添加目标回波的位置)

为了构建测试集,向“20210106155432_01_staring”纯杂波数据添加SCR从-12~20 dB的仿真目标回波,其中添加的SCR间隔为2 dB。添加目标的距离单元位置为第2083个距离单元,每个对应的

SCR都有一个测试数据。构造的对应SCR=10 dB的测试集幅度图如图7所示。






图7 对应SCR=10 dB的测试集幅度图
(红线代表添加目标回波的位置)

3.1.2 实测目标数据集构建

构建实测目标数据集评估所提方法性能。具体来说,利用《雷达学报》雷达对海探测数据集中的“20210106150614_01_staring”数据集和“20210106150614_03_staring”数据集对所提方法进行评价。两个数据集均为HH极化回波数据,每个数据集均包含两个目标的回波,两个数据集对应的幅度图如图8所示。在试验中,利用“20210106150614_01_staring”数据集作为训练集,“20210106150614_03_staring”数据集作为测试集。



(a) “20210106150614_01_staring”数据幅度图



(b) “20210106150614_03_staring”数据幅度图

图8 两个数据集幅度图

3.1.3 模型训练设置

本文利用CPU型号为i5-12400F、显卡型号为12 GB的NVIDIA 3060电脑进行实验。所提检测器利用 $N=4$ 个脉冲回波构建的回波矩阵进行检测。损失函数为交叉熵损失函数,Adam优化器通过最小化损失函数以优化所提检测器权重,学习率设置为0.001,批大小为4。训练迭代次数设置为40次。

3.2 试验结果

3.2.1 仿真目标数据集检测性能对比

在本试验中,我们给出所提方法在仿真目标数据集中不同SCR测试集下的检测概率(P_d)以评估所提方法的有效性,并将其和CA-CFAR算法进行对比。对于所提方法,我们采用文献[26]所提方法控制虚警率。在实验中,虚警率设置为 1×10^{-5} 。试验结果如图9所示。从图中可以看到,在不同信杂比条件下,所提方法检测概率均优于CA-CFAR方法,验证了基于图神经网络的检测器仅利用较少脉冲数检测目标的可行性。

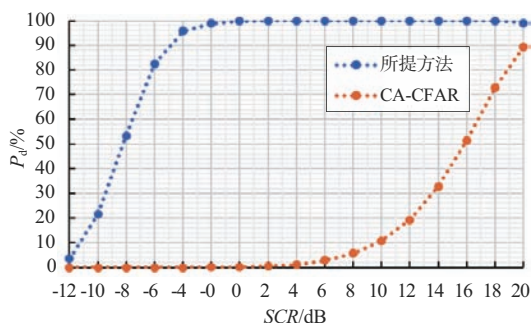



图9 所提方法和CA-CFAR方法在仿真目标数据集下的检测性能对比

此外,在添加仿真目标回波的条件下,可以看到在低SCR条件下,杂波能量显著高于目标能量时,所提方法仍然具有检测能力,说明了所提方法相比于基于能量的检测器的优势。


为直观展示所提方法和CA-CFAR方法检测结果,给出两种方法对 $SCR=10$ dB的测试集数据检测平面图如图10所示。可以看到,较CA-CFAR方法,所提方法检测概率更高,实际虚警点数更少,进一步证实所提方法的性能。

3.2.2 实测目标数据集检测性能对比

在本试验中,我们给出所提方法在实测目标



(a) 所提方法检测结果



(b) CA-CFAR检测结果

图10 所提方法和CA-CFAR方法检测平面图对比

数据集下测试集的检测概率以评估所提方法的有效性,并将其和CA-CFAR算法进行对比。对于所提方法,我们采用文献[26]所提方法控制虚警率。在实验中,虚警率设置为 1×10^{-5} 。试验结果如表1所示。

表1 所提方法和CA-CFAR方法在实测目标数据集下的检测概率对比

方法	P_d
所提方法	86.72%
CA-CFAR方法	84.73%

从表1结果可以看到,所提方法检测概率明显优于CA-CFAR方法。进一步地,我们在图11中给出两种方法在“20210106150614_03_staring.mat”数据集上的检测平面图,可以看到所提方法相比于CA-CFAR方法虚警点也更少。上述结果验证了所提方法的有效性。

3.2.3 检测实时性分析

进一步地,我们比较所提方法和CA-CFAR检




图 11 两种方法在“20210106150614_03_staring.mat”数据集上的检测平面图

测方法对图 7 所示测试集数据进行检测的所需时间,试验结果如表 2 所示。

表 2 所提方法和 CA-CFAR 方法检测时间对比

方法	时间
所提方法	142.33 s
CA-CFAR 方法	11.78 s

从表 2 可以看到,所提方法实时性比 CA-CFAR 方法差,这是由于所提方法基于神经网络技术开发的,需要的前馈运算量较大造成的。在实际应用过程中,可利用更强的算力芯片提高所提方法的实时性能。

3.2.4 虚警率控制性能分析

本实验对所提检测器的虚警率控制能力进行了分析。具体来说,设置不同的预设虚警率,统计预设虚警率和实际虚警率的 ROC 曲线,结果如图 12 所示。从图中可以看出,随着预设虚警率的增

加,实际虚警率也在增加,所提方法具有一定的虚警率控制能力。

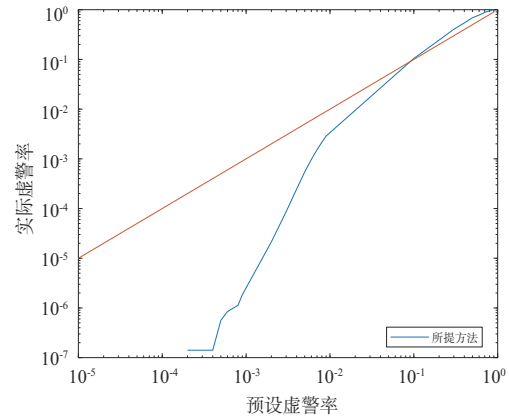


图 12 预设虚警率与实际虚警率的 ROC 曲线 (红线为预设虚警率等于实际虚警率)

4 结束语

本文提出了一种基于图神经网络的多尺度特征融合检测方法。该方法利用多个脉冲回波之间的特征相互关联性提高检测性能。首先从多个脉冲回波中提取多尺度特征,然后将对应尺度特征分别构造成图,利用图神经网络学习脉冲回波间高阶关联性。然后,融合多尺度回波以提升杂波和目标区分度。最后,对融合后的特征进行非线性映射和二分类得到检测结果。基于《雷达学报》对海探测数据集的试验表明,所提方法所需脉冲数较少,性能优于 CA-CFAR 方法且具有一定的虚警率控制能力。

参考文献:

- [1] 施端阳,林强,胡冰,等.深度学习在雷达目标检测中的应用综述[J].雷达科学与技术,2022,20(6):589-605.
- [2] 杨政,程永强,吴昊,等.基于流形变换的信息几何雷达目标检测方法[J].电子与信息学报,2024,46(11):4317-4327.
- [3] 刘允峰,索继东,柳晓鸣.改进的分形检测海面漂浮小目标方法[J].电讯技术,2016,56(9):976-981.
- [4] 关键,伍僖杰,丁昊,等.基于三维凹包学习算法的海面小目标检测方法[J].电子与信息学报,2023,45(5):1602-1610.
- [5] XU Shuwen, ZHENG Jibin, PU Jia, et al. Sea - Surface Floating Small Target Detection Based on Polarization

- Features [J]. IEEE Geoscience and Remote Sensing Letters, 2018, 15:1505-1509.
- [6] 黄胜彬,潘大鹏,陈涛.基于多维特征融合的海面目标检测[J].舰船电子对抗,2024,47(3):84-91.
- [7] 顾为亮.基于多极化特征联合的海面目标检测[D].南京:南京邮电大学,2021.
- [8] SHUI Penglang, LI Dongchen, XU Shuwen. Tri-Feature-Based Detection of Floating Small Targets in Sea Clutter [J]. IEEE Trans on Aerospace and Electronic Systems, 2014, 50(2):1416-1430.
- [9] 郭子薰,水鹏朗,白晓惠,等.海杂波中基于可控虚警K近邻的海面小目标检测[J].雷达学报,2020,9(4):654-663.
- [10] 王宏强,姜斌,黎湘,等.基于改进支持向量机的海面目标检测方法[J].信号处理,2007,23(4):598-602.
- [11] GENG Zhe, HE Yan, ZHANG Jindong, et al. Deep-Learning for Radar: A Survey [J]. IEEE Access, 2021, 9: 141800-141818.
- [12] 汪翔,汪育苗,陈星宇,等.基于深度学习的多特征融合海面目标检测方法[J].雷达学报,2024,13(3):554-564.
- [13] WANG Li, TANG Jun, LIAO Qingmin. A Study on Radar Target Detection Based on Deep Neural Networks [J]. IEEE Sensors Letters, 2019, 3(3):1-4.
- [14] YAVUZ F. Radar Target Detection with CNN [C]//2021 29th European Signal Processing Conference, Dublin, Ireland:IEEE, 2021:1581-1585.
- [15] 苏宁远,陈小龙,关键,等.基于深度学习的海上目标一维序列信号目标检测方法[J].信号处理,2020,36(12):1987-1997.
- [16] 时艳玲,陶平,许述文.基于WGAN-GP-CNN的海面小目标检测[J].信号处理,2024,40(6):1082-1097.
- [17] 孟俊彪.基于深度学习的自进化雷达目标检测算法[D].厦门:厦门大学,2018.
- [18] SU Ningyuan, CHEN Xiaolong, GUAN Jian, et al. Maritime Target Detection Based on Radar Graph Data and Graph Convolutional Network [J]. IEEE Geoscience and Remote Sensing Letters, 2022,19:1-5.
- [19] RU Hongtao, XU Shuwen, HE Qi, et al. Marine Small Floating Target Detection Method Based on Fusion Weight and Graph Dynamic Attention Mechanism [J]. IEEE Trans on Geoscience and Remote Sensing, 2023, 61:1-11.
- [20] 刘宁波,董云龙,王国庆,等.X波段雷达对海探测试验与数据获取[J].雷达学报,2019,8(5):656-667.
- [21] 汪育苗.非均匀时变杂波下雷达目标智能检测方法研究[D].成都:电子科技大学,2024.
- [22] ZHAO Dandan, ZHANG Zhe, LU Dongdong, et al. CVGG-Net: Ship Recognition for SAR Images Based on Complex-Valued Convolutional Neural Network [J]. IEEE Geoscience and Remote Sensing Letters, 2023, 20:1-5.
- [23] 黄梓峰,王洪雁,马嘉康.基于图神经网络的4D毫米波雷达目标检测方法[J/OL].计算机工程与应用,1-10 [2024-06-27].<http://kns.cnki.net/kcms/detail/11.2127.tp.20240626.1519.028.html>.
- [24] CHEN Siheng, ELDAR Y C, ZHAO Lingxiao. Graph Unrolling Networks: Interpretable Neural Networks for Graph Signal Denoising [J]. IEEE Trans on Signal Processing, 2021, 69:3699-3713.
- [25] GILMER J, SCHOENHOLZ S S, RILEY P F, et al. Neural Message Passing for Quantum Chemistry [C]// International Conference on Machine Learning, Sydney, Australia:PMLR, 2017:1263-1272.
- [26] CHEN Xiaolong, SU Ningyuan, HUANG Yong, et al. False-Alarm-Controllable Radar Detection for Marine Target Based on Multi Features Fusion via CNNs [J]. IEEE Sensors Journal, 2021, 21(7):9099-9111.

作者简介:

汪翔 男,博士研究生,主要研究方向为雷达目标检测识别和机器学习。

王彦斌 男,硕士研究生,主要研究方向为雷达智能检测、深度学习技术和增量机器学习。

汪育苗 女,博士后,主要研究方向为智能目标检测、雷达自进化和深度学习技术。

崔国龙 男,博士,教授,主要研究方向为认知雷达、阵列信号处理和MIMO雷达。