

基于无监督图互信息最大化的海面小目标异常检测

许述文* 何 绮 茹宏涛

(西安电子科技大学雷达信号处理国家重点实验室 西安 710071)

摘要: 受到复杂海洋环境的影响, 雷达对海面慢速小目标难以实现高性能检测。对于这类目标, 传统的基于能量的统计检测方法存在着严重的性能损失。针对这一问题, 该文提出了基于互信息最大化框架下的海面小目标检测方法, 实现海杂波背景下的无监督目标异常检测任务。首先, 考虑到高分辨雷达回波不满足传统神经网络对样本独立同分布的假设, 该文从图的角度重新建模数据, 利用回波的空时相关特性来构建图拓扑结构。该文提出相对最大节点度并联合7个已有特征作为节点的初始表示向量。接下来, 采用图注意力网络作为互信息最大化框架中的编码器学习节点表示向量。最后, 使用异常检测算法进行目标检测, 并实现虚警可控。经实测数据验证, 使用快速凸包学习算法时, 相比三特征检测器, 所提检测器性能提升了9.2%; 相比时频三特征检测器, 性能提升了7.9%。当网络输出更高维的表示向量时, 使用孤立森林算法的检测器的性能提升了27.4%。

关键词: 海杂波; 目标检测; 图神经网络; 无监督学习

中图分类号: TN957.51

文献标识码: A

文章编号: 1009-5896(2024)00-0001-09

DOI: 10.11999/JEIT230887

Anomaly Detection of Small Targets on Sea Surface Based on Deep Graph Infomax

XU Shuwen HE Qi RU Hongtao

(National Laboratory of Radar Signal Processing, Xidian University, Xi'an 710071, China)

Abstract: Due to the complex marine environment, it is difficult for a maritime radar to achieve high-performance detection of slow and small targets on the sea surface. For such targets, the traditional energy-based statistical detection algorithms suffer from serious performance loss. Confronted with this problem, a detection algorithm of small targets based on Deep Graph Infomax framework is proposed to realize unsupervised target anomaly detection in the background of sea clutter. In the traditional neural networks, there is an assumption that the samples are independent and identically distributed, which, however, the high-resolution radar echo does not meet. Therefore, this paper re-models the data from the perspective of graph and constructs the graph topological structure according to the correlation characteristics of the echo. Moreover, this paper puts forward the relative maximum node degree, and combines it with the relative average amplitude and the relative Doppler vector entropy to be the initial representation vectors of the graph nodes. With the graph modeling done, the graph attention network is used as the encoder in the Deep Graph Infomax framework to learn representation vectors. Finally, the anomaly detection algorithm is used to detect the targets, and the false alarm can be controlled. The detection result on the measured datasets shows that the performance of the proposed detector is improved by 9.2% compared to the three-feature detector when using the fast convex hull learning algorithm. Compared to the time-frequency three-feature detector, the performance is improved by 7.9%. When the network outputs a higher-dimensional representation vectors, the performance of the detector using the isolated forest algorithm is improved by 27.4%.

Key words: Sea clutter; Target detection; Graph Neural Network; Unsupervised learning

收稿日期: 2023-08-11; 改回日期: 2024-xx-xx

*通信作者: 许述文 swxu@mail_xidian.edu.cn

基金项目: 国家自然科学基金(61871303, 62071346), 高等学校学科创新引智计划(111计划)(B18039)

Foundation Items: The National Natural Science Foundation of China (61871303,62071346), The Fund for Foreign Scholars in University Research and Teaching Programs (The 111 Project) (B18039)

1 前言

海面慢速小目标(如浮标、游艇等民用目标,以及武装蛙人、潜望镜等高价目标)的检测性能提升一直是对海目标检测领域的重点和难点。这类目标雷达散射截面积低、回波能量弱,常采用高分辨率雷达降低杂波水平从而提升信杂比。但分辨率的提高使得海杂波特性更加复杂。同时,小目标受到海浪的影响,出现严重的雷达截面积起伏和多普勒调制现象^[1]。综上,目标回波和海杂波均很难被有效建模,依赖统计模型的传统检测方法出现性能瓶颈。针对该问题,国内外学者提出了特征检测方法,将小目标检测问题变成目标在杂波背景下的异常检测问题。在早期的特征检测方法研究中,分形特征^[2]、时频特征^[3]等相继被提出。随着特征检测的发展、特征类型的增多,Shui等人^[3,4]提出基于快速凸包学习算法的检测器,实现三特征联合检测。由于特征间的互补效应,该检测器检测性能优越。这说明联合多特征是实现高检测性能的有效途径。受限于计算能力,凸包算法无法应用于高维特征空间。因此,研究人员将支持向量机(Support Vector Machine, SVM)^[5]、K-近邻(K Nearest Neighbors, KNN)^[6]等浅层机器学习和目标检测问题结合,解决了高维空间下的特征检测问题。

随着人工智能的发展,神经网络受到广泛关注。目标常见的网络模型,如多层感知机(Multi-layer Perceptron, MLP)、卷积神经网络(Convolutional Neural Network, CNN)和循环神经网络(Recurrent Neural Network, RNN)等已被应用于海上目标检测任务^[7,8]。但在其应用过程中存在两个问题:(1)传统神经网络以样本独立同分布作为前提假设,而海杂波呈现出明显的空时依赖关系;(2)雷达目标检测任务中,含目标的回波数量远远小于杂波数量,对网络的训练造成困难。

针对问题(1),本文提出一种基于图神经网络的海面目标检测方法。图是一种典型非网格数据,可以实现任意数据和数据内在联系的联合建模。近些年来,已经有学者基于图做了一些前沿的研究工作。Yan等人^[9]和Shi等人^[10]分别根据雷达回波在时域和频域上的幅度构建邻接矩阵并提取特征,反映幅度的变化趋势。在相关工作的基础上,文献^[11]基于频域多通道图建模提出新的特征。上述方法初步实现了对雷达回波的图特征提取,但依然建立在传统特征检测方法的基础上。Su等人^[12]利用图拓扑结果表现回波空时相关性,并引入图卷积网络(Graph Convolution Network, GCN)捕捉抽象特征,进行杂波目标分类。实验结果证明,该检测方

法能有效提高检测概率,降低纯杂波上的虚警。随后Chen等人^[13]又采用可视图的方式,通过图分类实现目标检测。但上述方法在目标和杂波标签数据均完备的情况下进行有监督的二分类,而实际海面目标检测对于非合作目标很难收集到充足的数据进行有监督的学习^[1]。

本文另辟蹊径,通过互信息最大化(Deep Graph Infomax, DGI)^[14]框架实现图上的无监督学习。这种图节点表示学习方式不需要预先获知节点类别标签就可使节点学习到有利于分类的表示向量。首先通过回波在多个维度上的关联性构建图,作为神经网络的输入。由于本文实验部分选择驻留模式下的回波数据集,这里的多个维度代指脉冲维和距离维。来自一个距离单元的累积脉冲联合作为图的一个节点,并提取脉冲序列上的多个特征作为节点的初始表示向量。在本文中提出了相对最大节点度(Relative Maximum Degree, RMD),并联合已有的7个特征,共8个特征。其次,将图输入到DGI框架中进行学习。考虑到GCN网络在应用时需要计算拉普拉斯矩阵,是一种典型的传导学习方式,因此本文采用图注意力网络(Graph Attention Network, GAT)^[15]作为无监督框架下的编码器,提取特征作为节点表示向量。最后,在下游采用恰当的机器学习算法作检测器,对DGI输出的节点表示集进行分类。由于海面小目标检测是典型的异常检测问题,在输出表示向量维度不超过3维时,可以采用快速凸包算法;在输出表示向量维度高于3维时,采用孤立森林。

综上,本文创新点有以下3点:(1)提出一种新的特征作为节点初始表示向量之一,以增加节点初始表示向量的可分性;(2)引入图结构建立回波时空的联系,学习到信息丰富的节点表示向量,有利于下游的分类任务;(3)采用无监督学习方法,避免标签不完备和样本不均衡情况带来的影响。

2 图建模

雷达接收机通过I/Q两路通道接收海表面散射回来的回波信号,并以复信号的形式存储。假设接收的回波序列长度为 N ,则海面小目标的检测可以被描述为如式(1)所示二元假设检验:

$$\begin{cases} H_0 : \begin{cases} x(n) = c(n), n = 1, 2, \dots, N \\ x_p(n) = c_p(n), p = 1, 2, \dots, P \end{cases} \\ H_1 : \begin{cases} x(n) = c(n) + s(n), n = 1, 2, \dots, N \\ x_p(n) = c_p(n), n = 1, 2, \dots, P \end{cases} \end{cases} \quad (1)$$

其中, $x(n)$ 和 $x_p(n)$ 分别表示待检测单元和参考单元的雷达回波, $c(n)$ 和 $s(n)$ 分别表示海杂波和目标

回波, P 表示参考单元数目。 H_0 假设下, 待检测单元为纯海杂波信号; H_1 假设下, 待检测单元为海杂波和目标回波的叠加。

2.1 图的定义

图由节点集 V 和边集 E 组成, 记为 $G = (V, E)$ 。其中, $V = \{v_1, v_2, \dots, v_N\}$, $E = \{(v_i, v_j) | i, j = 1, \dots, N\}$, N 表示节点数目。

邻接矩阵 $A \in R^{N \times N}$ 可以表示图, 满足

$$a_{ij} = \begin{cases} 1, & (v_i, v_j) \in E \\ 0, & \text{其他} \end{cases} \quad (2)$$

其中 a_{ij} 表示邻接矩阵第 i 行第 j 列的元素。此外, a_{ij} 的值也可以采用任意非负实数, 代表节点之间的关联强度。

节点度反映了与节点相连的边的数目, 由邻接矩阵 A 可直接计算度矩阵 D

$$d_i = \sum_{j=1}^N a_{ij} \\ D = \text{diag}(d_1, d_2, \dots, d_N) \quad (3)$$

其中 d_i 表示节点 i 的度, $\text{diag}(\cdot)$ 表示由节点度构成的对角矩阵。拉普拉斯矩阵由对角矩阵和邻接矩阵构成, 为了保证节点数目的统一和特征表示的归一化, GCN 中一般采用对称归一化拉普拉斯矩阵。

$$L_{sym} = I - D^{-1/2} A D^{-1/2} \quad (4)$$

2.2 基于回波数据相关性的图建模

工作在驻留模式下的雷达, 其接收到的回波经过处理表现为距离维和脉冲维上的2维杂波图。本文基于传统特征检测方法和杂波图, 对雷达回波进行图建模。假设距离单元数目为 P , 每个距离单元包含长度为 N 的脉冲序列。累积长度为 L 的脉冲作为图上的一个节点。因此, 图上节点数为 $P \times (N/L)$ 。

不同距离单元的不同脉冲、同一距离单元的不同脉冲之间都具有一定的相关性。在雷达工作方式不变的情况下, 海面小目标表现出强的时间相关性, 脉冲维上相关时间达到亚秒级或秒级; 而海杂波受到海况和气象条件的影响, 去相关时间在几十

毫秒左右。距离维上, 邻近距离单元回波往往表现出相似的特性, 较远距离单元回波可视为统计独立。因此, 对于图上的一个节点, 连接其与相同时间的 n 邻近距离单元代表的节点, 以及相同距离单元 m 历史时间代表的节点, 如图1所示

$$a_{ij} = \begin{cases} 1, & j \in N_i \\ 0, & \text{其他} \end{cases} \quad (5)$$

其中, N_i 表示节点 v_i 的邻居节点。显然, N_i 中至多有 $m + 2n$ 节点。根据雷达工作模式和目标类型的不同可以设置不同的 N_i 。当累积脉冲序列满足 H_1 假设, 认为节点属于目标; 否则节点属于杂波。

2.3 节点初始特征向量提取

不同类型节点的初始表示向量需要在一定程度上的区分性, 其分离性影响后续神经网络的训练能力。本文从RPH特征出发, 基于可视图技术^[6]提出了相对最大节点度(Relative Maximum Degree, RMD)。同时结合来自时域、频域、时频域的7个特征^[2-4], 一共8个特征作为节点的初始表示向量。多个特征的结合能从多域描述回波, 从而加强检测能力。

2.3.1 7特征概述

本文使用的已有的7特征包括归一化Hurst指数^[2]、相对多普勒幅度(Relative Average Amplitude, RAA)、相对多普勒峰高(Relative Doppler Peak Height, RPH)、相对多普勒向量熵(Relative Vector Entropy, RVE)^[3]、脊累积(Ridge Integration, RI)、连通区域数目(Number of Connected Regions, NR)和最大连通区域尺寸(Maximal Size of Connected Regions, MS)^[4], 节点初始表示向量中按照此顺序排列。其中, RAA和NHE从累积脉冲的时域提取得到, RAA描述序列的能量强弱, NHE描述回波的分形程度。对于纯杂波, RAA和NHE的值较小。RPH和RVE提取自多普勒域, 两者都可以描述多普勒域上能量的集中情况。当目标存在时, 能量相对集中, 使多普勒域上出现明显峰值, 因此RPH较大, RVE较小。但是当目标信杂比(Signal-to-Clutter Ratio, SCR)非常低, 多普勒域上目标回波落在海杂波的主杂波区内, 这四个特征将失去




图1 图建模示意图(红色表示根节点, 黄色表示与根节点相连接的节点)

检测能力。因此,进一步加入3个时频特征。其中,RI是时频图上脊的能量累积,MS和NR是二值化的时频图上的最大连通区域尺寸和连通区域数目。当雷达回波满足 H_1 假设,RI和MS的取值较大,而NR的取值较小。

2.3.2 相对最大节点度

在多普勒域上,长时观测使慢速小目标的回波和海杂波的差异体现出来。由于目标速度低,其能量会比海杂波更加集中,多普勒谱上出现明显峰值。RPH反应了杂波和目标在多普勒谱上的峰高的相对差异。对于长度为 L 的脉冲序列,其多普勒谱如下

$$X(f_d) = \frac{1}{\sqrt{N}} \left| \sum_{n=1}^N x(n) \exp(-j2\pi f_d n T_r) \right|, \quad -\frac{1}{2T_r} \leq f_d \leq \frac{1}{2T_r} \quad (6)$$

其中 f_d 为多普勒频率, T_r 为脉冲重复周期。多普勒峰谱上的相对峰高定义为

$$\text{PH}(\mathbf{x}) \equiv \frac{\text{peak}(\mathbf{x})}{\frac{1}{\#\Delta} \sum_{f_d \in f_d^{\max}(\mathbf{x}) + \Delta} X(f_d)} \quad (7)$$

其中 $\text{peak}(\mathbf{x})$ 和 $f_d^{\max}(\mathbf{x})$ 表示多普勒谱峰高和对应的多普勒偏移; $\Delta = [-\delta_1, -\delta_2] \cup [\delta_2, \delta_1]$,表示多普勒通道上杂波区域的集合,是根据经验得出的峰高所在单元周围海杂波带宽的范围。

海杂波会随着距离单元变化,因此采用相对处理使特征具有一定的恒虚警特性

$$\text{RPH}(\mathbf{x}) = \frac{\text{PH}(\mathbf{x})}{\frac{1}{P} \sum_{p=1}^P \text{PH}(\mathbf{x}_p)} \quad (8)$$

为了充分利用多普勒峰值这一特征,本文在RPH计算的基础上,提出了RMD。同样地,首先计算多普勒谱上的峰高 $\text{peak}(\mathbf{x})$,获取 $f_d^{\max}(\mathbf{x}) + \Delta$ 区间上的多普勒谱幅度序列 $\mathbf{x}'(n)$ 。然后采用可视图算法,将幅度序列 $\mathbf{x}'(n)$ 转换成对应的图。可视图算

法是2008年Lacasa提出的一种时间序列复杂网络建模方法^[16]。该算法不依赖任何参数,在保留原始信息的基础上,将任意时间序列中的数据直接定义为图节点,并根据可视准则建立图结构。对于任意给定的时间序列,任意两点 (a, t_a) 、 (b, t_b) 对位于两点中间的点 (c, t_c) 都满足条件

$$\frac{x_a - x_c}{t_c - t_a} > \frac{x_a - x_b}{t_b - t_a} \quad (9)$$

则认为两点可视,即在图中存在边,由此建立拓扑结构。如图2所示,通过可视图算法将离散序列转换为图,其中峰值最高的节点4可以认为是该图中的枢纽节点。

在 $\mathbf{x}'(n)$ 形成的拓扑图 G 上,选择序列上两点之间的斜率的绝对值作为两点的边权值,加强尖峰对应的枢纽节点对全图节点度的影响。

$$a_{ij} = \begin{cases} |(x_i - x_j) / (t_i - t_j)|, & j \in N_i \\ 0, & \text{其他} \end{cases} \quad (10)$$

根据式(3)得到图 G 的最大节点度

$$\text{MD}(\mathbf{x}) = \max_i (d_i) \quad (11)$$

同样的,对最大节点度进行相对处理

$$\text{RMD}(\mathbf{x}) = \frac{\text{MD}(\mathbf{x})}{\frac{1}{P} \sum_{p=1}^P \text{MD}(\mathbf{x}_p)} \quad (12)$$

该特征反映了多普勒谱上目标造成的尖峰和剧烈幅度起伏现象。图3绘制了一组数据集中目标回




图2 可视图技术示意




图3 RMD和RPH特征的分离度

波和纯杂波的RMD和RPH两个特征的分直方图。可以看见目标和杂波的RMD特征重叠区域相比RPH更低。这一特性使RMD具有更高的检测能力。

3 基于互信息最大化的海上目标检测器

将神经网络方法应用于雷达海上目标检测需要解决的问题是如何避免标记数据不精确、正负样本不均衡带来的检测性能下降。在大量海杂波数据的背景下无监督地实现目标的异常检测是解决该问题的途径之一。本章在回波数据完成图建模的基础上, 首先采用DGI框架无监督地学习节点表示向量, 紧接着采用异常检测算法作为下游检测器, 解决了标签不完备和样本不均衡下的训练问题。

3.1 图卷积网络

在图像处理、自然语言处理等方面, CNN具有举足轻重的地位, 但是卷积、池化等操作只适用于规则的欧式空间数据。由于图数据具有节点不均匀性、排列不变性以及边属性等特性, CNN不能被应用。为了拓展CNN在图上的应用, Bruna等人^[17]基于图信号分析和图谱理论定义了谱域图卷积。但该卷积方式具有高计算复杂度、低泛化能力的局限性。进一步地, ChebNet^[18]和GCN^[19]对卷积核进行参数化以达到降低计算复杂度的目标。其中, GCN将卷积操作直接定义在节点上

$$\mathbf{h}_i^{l+1} = \sigma \left(\sum_{j \in \mathcal{N}_i} \tilde{\mathbf{L}}_{\text{sym}}[i, j] \mathbf{W}^l \mathbf{h}_j^l \right) \quad (13)$$

其中, \mathbf{h}^l 表示第 l 层卷积层输出的节点表示, \mathbf{W}^l 表示第 l 层卷积层对应的卷积核, σ 则表示非线性变换。 $\tilde{\mathbf{L}}_{\text{sym}}$ 是对称归一化的拉普拉斯矩阵, 满足 $\tilde{\mathbf{L}}_{\text{sym}} = \tilde{\mathbf{D}}^{-1/2} \tilde{\mathbf{A}} \tilde{\mathbf{D}}^{-1/2}$ 。其中, $\tilde{\mathbf{A}} = \mathbf{I} + \mathbf{A}$ 为加入自循环的邻接矩阵, 实现节点自身和邻接节点信息的聚合, $\tilde{\mathbf{D}}$ 表示其度矩阵。

3.2 图注意力网络

GCN网络中需要拉普拉斯矩阵实现卷积操作, 但拉普拉斯矩阵的计算要求一次性输入整个图。因此GCN灵活性和拓展能力差, 属于传导学习。为了跳出拉普拉斯矩阵的限制, 研究人员引入注意力机制逐点计算节点之间的注意力系数作为信息聚合的权重, 提出了GAT^[15]。其卷积操作定义类似于式(13)

$$\mathbf{h}_i^{l+1} = \sigma \left(\sum_{j \in \mathcal{N}_i} \alpha_{ij} \mathbf{W}^l \mathbf{h}_j^l \right) \quad (14)$$

其中, α_{ij} 为节点之间的权重, 通过计算两节点表示向量的相似性得到

$$e_{ij} = \text{LeakyReLU} \left(\mathbf{a}^T [\mathbf{W} \mathbf{h}_i \parallel \mathbf{W} \mathbf{h}_j] \right) \quad (15)$$

$$\alpha_{ij} = \text{softmax}(e_{ij}) = \frac{\exp(e_{ij})}{\sum_{j \in \mathcal{N}_i} \exp(e_{ij})} \quad (16)$$

其中, e_{ij} 是节点之间的注意力系数, \mathbf{a} 和 \mathbf{W} 是需要训练的参数, \parallel 表示拼接操作。经过SoftMax操作后, 节点 v_i 和其邻居节点之间的权重和为1。

注意力机制的引入使GAT中的卷积操作实现了更好的权重分配, 节点表示向量的相关性被融入模型中。在实验中, 还可以通过多头注意力机制增强网络的拟合能力

$$\mathbf{h}_i = \sigma \left(\frac{1}{K} \sum_{k=1}^K \mathbf{h}_i^k \right) \quad (17)$$

其中 K 表示多个相互独立的注意力通道, 可以有效防止网络陷入局部最优。

3.3 互信息最大化

互信息是概率论和信息论中的一个重要概率, 用于度量两个随机变量间的相关程度。可表示为两个变量的联合分布和其边缘分布乘积的相对熵

$$\mathbf{I}(X; Y) = \sum_{x \in X} \sum_{y \in Y} p(x, y) \log \frac{p(x, y)}{p(x)p(y)} \quad (18)$$

互信息越大, 变量间的相关性越大。在特征选择中, 常作为特征与标签依赖程度的度量。DGI是图神经网络中一种经典的无监督表示学习框架, 通过最大化节点表示向量和全局表示向量之间的互信息来学习新的表示向量。如图4所示, 包括4个部分: 负样本生成器、编码器、读出函数和判决器。

首先输入来自海杂波和目标的原始数据, 也称正样本。通过对正样本进行打乱、腐蚀等扰动, 负样本生成器负样本用于对比学习。正负样本会被送入相同的编码器, 获得节点表示集 \mathbf{H} , $\tilde{\mathbf{H}}$ 。这里编码器可以采用GCN, GAT等网络。读出函数对正样本的节点表示集 \mathbf{H} 进行整合, 获得图级别的全局表示 \mathbf{s} 。读出函数可以是任意映射函数满足 $\mathbf{R}^{N \times F} \rightarrow \mathbf{R}^F$, 而本文采用如下的均值函数

$$\mathbf{R}(\tilde{\mathbf{H}}) = \mathbf{s} = \sigma \left(\frac{1}{N} \sum_{i=1}^N \mathbf{h}_i \right) \quad (19)$$

其中, N 表示节点数量, F 是表示向量维度。随后, 判决器会根据全局表示 \mathbf{s} 对集合 \mathbf{H} , $\tilde{\mathbf{H}}$ 中的每




图4 DGI框架

一个节点表示打分, 通过对正样本打高分、负样本打低分的过程来进行最终的表示向量的学习。这是一种典型的对比学习, 其目标函数如下

$$L = \frac{1}{N+M} \left(\sum_{i=1}^N E_{(\mathbf{X}, \mathbf{A})} [\log D(\mathbf{h}_i, \mathbf{s})] + \sum_{i=1}^M E_{(\tilde{\mathbf{X}}, \tilde{\mathbf{A}})} [\log(1 - D(\tilde{\mathbf{h}}_i, \mathbf{s}))] \right) \quad (20)$$

其中, N 和 M 分布表示正负样本的数量, $E(\cdot)$ 表示期望函数。该函数固定来自正样本的全局表示向量, 通过负样本的对比学习, 实现正样本的局部-全局互信息最大化, 以及负样本的局部-全局互信息最小化。这样的处理为后续正样本的节点分类任务提供便利。

3.4 孤立森林算法

孤立森林是一种经典的无监督异常检测算法, 在不需要任何标签的情况下可以实现对特征空间中稀疏的离群点的检测^[20]。在孤立森林中, 数据集采样后根据特征进行随机切割, 形成二叉搜索树。在这种策略下, 异常点由于离群特性会被较早的切割出来; 相反, 非异常的点需要多次分割。数据集中的样本点在二叉树上的路径长度就可以作为异常的判决依据, 路径长度越小越可能是异常点。这种方法可以应用于高维空间中的异常检测^[21]。

在海面目标检测的问题中, 由于海杂波的数目远远大于目标的数目, 全局表示 \mathbf{s} 中包含更多来自海杂波的信息。经过DGI框架下的表示学习后, \mathbf{H} 中实现了不同类型节点的初步划分。节点的初始表示向量集是从不同变换域上提取的特征, 而 \mathbf{H} 同样可以视为根据回波中的信息提取的差异性特征。使用孤立森林作为检测器时, 首先对两者进行拼接后得到 $\tilde{\mathbf{H}}$ 。图5是基于孤立森林的检测器, 具体计算过程如下:

- 1、选择节点表示向量 $\tilde{\mathbf{H}}$ 中属于海杂波的集合 $\tilde{\mathbf{H}}_{clutter}$ 作为训练集;
- 2、在 $\tilde{\mathbf{H}}_{clutter}$ 中随机抽取 φ 个样本点构成子集生成孤立树, 重复这一过程生成孤立森林;
- 3、遍历孤立森林中的每一棵树, 计算 $\tilde{\mathbf{H}}_{clutter}$ 中每个样本点的异常分数, 从小到大排序得到 $\{l_1, l_2, \dots, l_n\}$, 根据虚警概率 P_{FA} 确定检测门限 $\eta_{P_{FA}}$

$$\begin{aligned} index &= \#\tilde{\mathbf{H}}_{clutter} * P_{FA} \\ \eta_{P_{FA}} &= l_{index} \end{aligned} \quad (21)$$

其中 $\#\tilde{\mathbf{H}}_{clutter}$ 表示集合中样本点的数目。

- 4、遍历孤立森林获取全部节点表示向量集 $\tilde{\mathbf{H}}$ 的异常分数 $\{l_i\}$, 当 l_i 低于门限, 则对应的节点

满足 H_1 假设, 目标存在; 如果 l_i 低于门限, 则节点满足 H_0 假设, 目标不存在。

$$l_i \underset{H_0}{\overset{H_1}{\geq}} \eta_{P_{FA}} \quad (22)$$

4 实验与分析

4.1 实测数据说明与参数设置

本文进行的实验基于20组驻留模式下的IPIX雷达数据集。该数据由加拿大麦克马斯特大学(McMaster University)进行采集和维护。雷达工作在X波段, 脉冲重复周期为1000Hz, 采集HH, HV, VH和VV4个极化通道的雷达回波。其中, 前10组数据于1993年采集, 雷达架高30m, 合作目标为直径约1m的塑料球, 由14个距离单元组成, 每个距离单元序列长度为 2^{17} ; 后10组数据于1998年采集, 雷达架高20m, 合作目标是低速运动的小船, 由28个距离单元组成(部分是34个距离单元), 每个距离单元序列长度为60 000。各极化通道上, 20组数据的平均信杂比如图6所示。

在实验中, 图节点累积的脉冲长度 $L = 256$, 即每个检测单元的观测时间为0.256s。为了使杂波节点数满足虚警概率为0.001时检测概率估计的需求^[22], 相邻时间上的两个节点的累积脉冲具有128脉冲的重叠。对于93年的雷达数据, 生成的图中含有14324个节点; 对于98年的雷达数据, 有13 086个节点。DGI的编码器采用多通道的GAT网络, $K = 8$ 。训练过程中迭代次数设置为2000, 学习率为0.005, 并采用早停防止过拟合。检测流程如图7所示, 主




图5 基于孤立森林的检测器

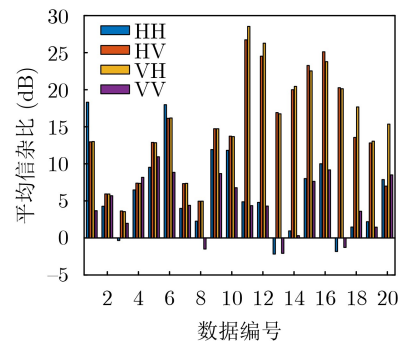


图6 IPIX数据集中20组数据的平均信杂比

要包括图建模、DGI框架下表示向量的学习和异常检测3个部分。本文实验部分使用快速凸包算法^[3,4]和孤立森林作为异常检测器。值得注意的是，当采用快速凸包算法时，DGI框架下输出的表示向量维度为3；采用孤立森林时，DGI框架的输出维度是一个超参数。

4.2 超参数选择

对雷达回波进行图建模时，节点之间的连接关系影响图的拓扑结构，进而影响整个检测器的检测性能。由于漂浮小目标速度较低，目标常长时间停留在同一个距离单元。但目标的存在对周围距离单元将产生一定影响，因此式(5)中的 N_i 设置 $n = 1$ 。而 m 表示当前节点和历史数据中多少个节点相连，显然， m 越大，采用的历史数据越多。使用快速凸包算法作为下游检测器，图8给出了图建模中 m 对最终检测概率的影响。检测概率和 m 呈现正相关， m 增大，检测概率呈上升趋势。在传统雷达海面小目标检测任务中，目标容易被淹没在海浪中，回波中SCR降低。而图建模使检测单元能联合历史数据作为先验信息，提升检测能力。但 m 越高意味着雷达需要存储越多的历史数据。综合考量后设置 $m = 3$ 。

当下游的检测器采用孤立森林时，DGI输出的节点表示向量维度可以是任意的。如图9，多组数据下孤立森林检测器的平均检测概率随DGI输出节点表示向量维度变化。由于孤立森林算法本身的随机性，平均检测概率具有明显起伏，但在4维达到最高检测概率，之后随着维度升高总体呈现下降趋

势。维度过高会使表示向量中掺杂冗余特征，不利于检测。后续实验中设置输出向量维度为4。

4.3 性能分析

本实验中采用两种异常检测算法作为检测器：快速凸包算法和孤立森林，并使用4种极化方式下的20组数据进行实验。当采用快速凸包算法时，受限于算力，DGI输出的表示维度为3维。实验结果如图10所示，并和同样采用快速凸包算法的三特征检测器^[4]、时频域三特征检测器^[3](RI, MS, NR)进行对比。实验中，对比检测器采用256的累积脉冲，虚警控制在0.001。可以看见，经过DGI框架下表示向量的学习后，检测器在80%的数据集上得到了性能提升，只在前4组数据集上不及三特征检测器(RAA, RPH, RVE)，以及第11组数据上略微不如时频域三特征检测器(RI, MS, NR)。多特征联合可以提升检测效果，但不同的特征对不同的数据的检测能力不同，因此存在性能的差异。表1给出了观测时间为0.256s时三种检测器的平均检测概率，相比三特征检测器，所提检测器性能提升了9.2%；相比时频三特征检测器，性能提升了7.9%。

当采用孤立森林算法时，DGI输出的表示维度为4维。与节点初始表示向量结合，输入孤立森林的表示向量集为12维。图11对比了仅使用初始表示向量，即8维特征的孤立森林检测器^[21]在平均极化下的20组数据上的检测能力，观测时间为0.256s，虚警为0.001。从图中可以看出，本文所提检测方法在全部数据集上都表现出更好的检测性能。尤其针对后10组数据，性能提升明显。这是因为在同样




图7 基于互信息最大化的海面小目标检测流程




图8 检测概率随m的变化曲线




图9 平均检测概率随DGI输出节点表示向量维度的变化曲线




图 10 本文所提方法与三特征检测器、时频三特征检测器在20组数据平均极化下的对比

表 1 快速凸包算法在IPIX数据集20组数据不同极化情况下平均检测概率

| 检测器 | HH | HV | VH | VV | 平均 |
|----------|---------------|---------------|---------------|---------------|---------------|
| 三特征检测器 | 0.6544 | 0.7825 | 0.8222 | 0.6343 | 0.7234 |
| 时频三特征检测器 | 0.6961 | 0.7911 | 0.8173 | 0.6426 | 0.7368 |
| 本文所提检测器 | 0.7800 | 0.8505 | 0.8749 | 0.7574 | 0.8157 |




图 11 本文所提方法与孤立森林检测器在20组数据平均极化下的对比

采用孤立森林算法的基础上, 本文通过DGI框架无监督学习图上的结构信息, 相当于利用回波相邻距离单元数据以及历史数据中的有效信息, 提取出新的特征, 在更高维的空间中, 实现有效分类。表2进一步列出了几种极化下20组数据的平均检测结果。可以看出, 相比原始8维特征的孤立森林检测器, 所提检测器性能提升了27.4%。

为了进一步探究相同情况下, 本文所提方法对检测器性能的改善能力, 使用RAA, RPH, RVE 3个特征作为节点初始表示向量, 在输出向量维度为3时和三特征检测器进行对比。检测结果如图12所示, 在80%的数据集上, 本文所提方法的检测概率高于三特征检测器。这得益于本文所提方法能充分利用相关信息, 挖掘在特征空间中使目标和杂波分离程度更高的特征。

表 2 孤立森林算法在IPIX数据集20组数据不同极化情况下平均检测概率

| 检测器 | HH | HV | VH | VV | 平均 |
|------------|---------------|---------------|---------------|---------------|---------------|
| 8特征孤立森林检测器 | 0.3269 | 0.5085 | 0.5623 | 0.2998 | 0.4244 |
| 本文所提检测器 | 0.5965 | 0.8001 | 0.8252 | 0.5716 | 0.6983 |




图 12 采用相同三特征的本文所提方法与三特征检测器在20组数据平均极化下的对比

5 结论

本文提出了一种基于图结构和图神经网络的海面小目标检测技术。该方法首先考虑到雷达回波中的空时相关特性, 将雷达回波建模为图结构, 并提出新特征RMD, 联合7个已有特征作为节点初始表示向量。接下来, 采用GAT作为DGI框架中的编码器, 在图上无监督地学习节点表示向量。最后在下流使用机器学习方法, 实现了不同维度特征空间中的海面小目标异常检测。在实验部分, 本文采用凸包学习算法和孤立森林算法作为异常检测器。所提方法建立了待检测单元和周围单元以及历史数据之间的联系, 通过图神经网络学习新的特征向量。实测数据下的实验结果证明, 该方法在同等条件下有效提升了检测性能。

参考文献

- [1] 许述文, 白晓惠, 郭子薰, 等. 海杂波背景下雷达目标特征检测方法的现状与展望[J]. 雷达学报, 2020, 9(4): 684-714. doi: 10.12000/JR20084. XU Shuwen, BAI Xiaohui, GUO Zixun, et al. Status and prospects of feature-based detection methods for floating targets on the sea surface[J]. *Journal of Radars*, 2020, 9(4): 684-714. doi: 10.12000/JR2008. doi: 10.12000/JR20084.
- [2] HU Jing, TUNG W W, and GAO Jianbo. Detection of low observable targets within sea clutter by structure function based multifractal analysis[J]. *IEEE Transactions on Antennas and Propagation*, 2006, 54(1): 136-143. doi: 10.1109/TAP.2005.861541.
- [3] SHI Sainan and SHUI Penglang. Sea-surface floating small target detection by one-class classifier in time-frequency feature space[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 56(11): 6395-6411. doi: 10.1109/

- TGRS.2018.2838260.
- [4] SHUI Penglang, LI Dongchen, and XU Shuwen. Tri-feature-based detection of floating small targets in sea clutter[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2014, 50(2): 1416–1430. doi: [10.1109/taes.2014.120657](https://doi.org/10.1109/taes.2014.120657).
- [5] LI Yuzhou, XIE Pengcheng, TANG Zeshen, *et al.* SVM-based sea-surface small target detection: A false-alarm-rate-controllable approach[J]. *IEEE Geoscience and Remote Sensing Letters*, 2019, 16(8): 1225–1229. doi: [10.1109/LGRS.2019.2894385](https://doi.org/10.1109/LGRS.2019.2894385).
- [6] 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. doi: [10.12000/JR20055](https://doi.org/10.12000/JR20055).
GUO Zixun, SHUI Penglang, BAI Xiaohui, *et al.* Sea-Surface small target detection based on K-NN with controlled false alarm rate in sea clutter[J]. *Journal of Radars*, 2020, 9(4): 654–663. doi: [10.12000/JR20055](https://doi.org/10.12000/JR20055).
- [7] 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): 47–52,57. doi: [10.16592/j.cnki.1004-7859.2019.10.009](https://doi.org/10.16592/j.cnki.1004-7859.2019.10.009).
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): 47–52,57. doi: [10.16592/j.cnki.1004-7859.2019.10.009](https://doi.org/10.16592/j.cnki.1004-7859.2019.10.009).
- [8] WAN Hao, TIAN Xiaoqing, LIANG Jing, *et al.* Sequence-feature detection of small targets in sea clutter based on Bi-LSTM[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 4208811. doi: [10.1109/TGRS.2022.3198124](https://doi.org/10.1109/TGRS.2022.3198124).
- [9] YAN Kun, BAI Yu, WU H C, *et al.* Robust target detection within sea clutter based on graphs[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(9): 7093–7103. doi: [10.1109/TGRS.2019.2911451](https://doi.org/10.1109/TGRS.2019.2911451).
- [10] 时艳玲, 姚婷婷, 郭亚星. 基于图连通密度的海面漂浮小目标检测[J]. *电子与信息学报*, 2021, 43(11): 3185–3192. doi: [10.11999/JEIT201028](https://doi.org/10.11999/JEIT201028).
SHI Yanling, YAO Tingting, and GUO Yaxing. Floating small target detection based on graph connected density in sea surface[J]. *Journal of Electronics & Information Technology*, 2021, 43(11): 3185–3192. doi: [10.11999/JEIT201028](https://doi.org/10.11999/JEIT201028).
- [11] 许述文, 焦银萍, 白晓惠, 等. 基于频域多通道图特征感知的海面小目标检测[J]. *电子与信息学报*, 2023, 45(5): 1567–1574. doi: [10.11999/JEIT220188](https://doi.org/10.11999/JEIT220188).
XU Shuwen, JIAO Yinping, BAI Xiaohui, *et al.* Small target detection based on frequency domain multichannel graph feature perception on sea surface[J]. *Journal of Electronics & Information Technology*, 2023, 45(5): 1567–1574. doi: [10.11999/JEIT220188](https://doi.org/10.11999/JEIT220188).
- [12] 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: 4019705. doi: [10.1109/lgrs.2021.3133473](https://doi.org/10.1109/lgrs.2021.3133473).
- [13] CHEN Simin, FENG Chen, HUANG Yong, *et al.* Small target detection in x-band sea clutter using the visibility graph[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5115011. doi: [10.1109/TGRS.2022.3186283](https://doi.org/10.1109/TGRS.2022.3186283).
- [14] VELIČKOVIĆ P, FEDUS W, HAMILTON W L, *et al.* Deep graph infomax[J]. arXiv: 1809.10341, 2018. doi: [10.48550/arXiv.1809.10341](https://doi.org/10.48550/arXiv.1809.10341). (查阅网上资料,不确定文献类型,请确认).
- [15] VELIČKOVIĆ P, CUCURULL G, CASANOVA A, *et al.* Graph attention networks[C]. Proceedings of the 6th International Conference on Learning Representations, Vancouver, BC, Canada, 2018.
- [16] LACASA L, LUQUE B, BALLESTEROS F, *et al.* From time series to complex networks: The visibility graph[J]. *Proceedings of the National Academy of Sciences of the United States of America*, 2008, 105(13): 4972–4975. doi: [10.1073/pnas.07092471](https://doi.org/10.1073/pnas.07092471).
- [17] BRUNA J, ZAREMBA W, SZLAM A, *et al.* Spectral networks and locally connected networks on graphs[J]. arXiv: 1312.6203, 2013. doi: [10.48550/arXiv.1312.6203](https://doi.org/10.48550/arXiv.1312.6203). (查阅网上资料,不确定文献类型,请确认).
- [18] DEFFERRARD M, BRESSON X, and VANDERGHEYNST P. Convolutional neural networks on graphs with fast localized spectral filtering[C]. Proceedings of the 30th International Conference on Neural Information Processing Systems, Barcelona, Spain, 2016.
- [19] KIPF T N and WELLMING M. Semi-supervised classification with graph convolutional networks[C]. Proceedings of the 5th International Conference on Learning Representations, Toulon, France, 2017.
- [20] LIU F T, TING Kaiming, and ZHOU Zhihua. Isolation forest[C]. Proceedings of the 8th IEEE International Conference on Data Mining, Pisa, Italy, 2008: 413–422. doi: [10.1109/ICDM.2008.17](https://doi.org/10.1109/ICDM.2008.17).
- [21] XU Shuwen, ZHU Jianan, JING Junzheng, *et al.* Sea-surface floating small target detection by multifeature detector based on isolation forest[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2021, 14: 704–715. doi: [10.1109/JSTARS.2020.3033063](https://doi.org/10.1109/JSTARS.2020.3033063).
- [22] ECHARD J D. Estimation of radar detection and false alarm probability[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 1991, 27(2): 255–260. doi: [10.1109/7.78300](https://doi.org/10.1109/7.78300).
- 许述文: 男, 教授, 研究方向为雷达目标检测、海杂波特性分析与统计机器学习。
何 绮: 女, 硕士生, 研究方向为雷达目标检测、图信号处理、图神经网络。
茹宏涛: 男, 博士生, 研究方向为雷达目标检测、图信号处理、图神经网络。