

# 基于对比学习的航海雷达目标检测方法

司凌宇<sup>1,2</sup>, 强文文<sup>1,2</sup>, 李 港<sup>1,2</sup>, 刘美琴<sup>1</sup>, 徐帆江<sup>1</sup>, 孙富春<sup>3</sup>

(1. 中国科学院软件研究所天基综合信息系统重点实验室, 北京 100191;  
2. 中国科学院大学, 北京 101408; 3. 清华大学计算机科学与技术系, 北京 100084)

**摘要:** 由于航海雷达图像中的目标与杂波的相似度较高,因此目标检测任务非常困难. 此外,虽然航海雷达的原始数据量很大,但标注需要大量的专业知识,导致目前可以直接使用的有效数据很少. 为解决上述问题,本文首先建立了两个航海雷达数据集,分别是无标签的航海雷达数据集(Unlabeled Marine Radar Dataset, UMRD)和有标签的航海雷达检测数据集(Marine Radar Detection Dataset, MRDD). 同时,本文提出了一种基于对比学习的航海雷达目标检测方法(Contrastive Learning for Marine Radar Detection, CLMRD). 该方法首先以聚类的方式产生伪标签,然后以交替预测的方式从样例级别提高特征的判别性,并根据一致性准则从数据分布级别提升特征判别性. 接下来,使用Yolov5作为目标检测网络,并结合预训练的特征提取器进行微调. 最后,CLMRD对不同切片的检测结果进行融合. 提出的方法在MRDD数据集上达到了0.97的准确率和0.95的召回率,显著优于其他检测方法,验证了其有效性和鲁棒性.

**关键词:** 航海雷达;目标检测;自监督学习;特征表示

中图分类号: TP181;TN957.52 文献标识码: A

文章编号: 0372-2112(2023)07-1791-12

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20221088

## Marine Radar Object Detection Method Based on Contrastive Learning

SI Ling-yu<sup>1,2</sup>, QIANG Wen-wen<sup>1,2</sup>, LI Gang<sup>1,2</sup>, LIU Mei-qin<sup>1</sup>, XU Fan-jiang<sup>1</sup>, SUN Fu-chun<sup>3</sup>

(1. Science & Technology on Integrated Information System Laboratory, Institute of Software, Chinese Academy of Sciences, Beijing 100191, China; 2. University of Chinese Academy of Sciences, Beijing 101408, China;  
3. Department of Computer Science and Technology, Tsinghua University, Beijing 100084, China)

**Abstract:** The task of detecting targets in marine radar images is challenging due to high similarity between the target and clutter. Although there is a large amount of raw data available for marine radar, annotating them requires expert knowledge, making labeled data particularly valuable. To address these issues, this paper establishes two marine radar datasets, the unlabeled marine radar dataset (UMRD) and the labeled marine radar detection dataset (MRDD). To improve the feature discriminability of the data, this paper proposes a contrastive learning approach for marine radar detection (CLMRD), which involves generating pseudo labels by clustering and then improving the feature discriminability at both the sample and data distribution levels using a consistency criterion. The object detection network Yolov5 is used to detect targets, and fine-tuned with a pre-trained feature extractor. CLMRD fuses the detection results of different slices to improve the accuracy and recall rates. The proposed method achieves an accuracy rate of 0.97 and a recall rate of 0.95 on the MRDD dataset, outperforming other detection methods and demonstrating its effectiveness and robustness.

**Key words:** marine radar; object detection; self-supervised learning; feature representation

### 1 引言

航海雷达被广泛应用在民用和军用监控系统中,其典型的应用场景包括导航、海上目标检测和安防等. 航海雷达的目标检测算法对雷达回波中的目标信号进行自动检测,是雷达系统设计的重要组成部分. 由于雷达回波中不仅包含目标的有效信息,还包含地海杂波等干扰信息. 因此,目标检测的精度直接影响着航海雷

达的性能.

传统雷达目标检测主要基于恒虚警技术,根据背景杂波不同,国内外学者提出多种恒虚警检测处理技术. 早期低分辨率雷达目标检测建立在服从瑞利分布的海杂波模型上,其可以分为:均值类、统计排序类和删除类<sup>[1,2]</sup>. 随着雷达分辨率的提高,非参量恒虚警处理的量化秩(Relative Quantification, RQ)检测器<sup>[3]</sup>等方

法相继产生,此类方法对非高斯分布、时变杂波背景的检测能力较高。

虽然传统方法被广泛应用但仍然存在缺陷,其问题主要包含三点<sup>[4]</sup>:第一,传统方法需要根据经验定义大量手工参数,该过程不仅费时费力,且设置的初始参数对性能影响很大;第二,传统方法运用目标的像素强度进行检测,无法利用目标视觉特征来提升性能;第三,传统算法采用固定尺寸的检测窗,难以满足多尺度船只目标检测需求。因此,为了保证检测算法的性能,目标的筛选工作需要一定的专家知识的人工介入。这使得传统航海雷达使用门槛高。因此,大量研究工作旨在提升航海雷达目标检测算法的性能,以减少使用过程中的人工干预。

随着深度学习的发展,基于人工智能技术的目标检测算法在雷达图像也出现应用,以合成孔径雷达(Synthetic Aperture Radar, SAR)雷达图像领域为例,基于深度学习的目标检测算法使用大量带有标签信息的数据进行训练,指导模型学习目标包含的特征信息。与传统方法相比,其优势在于不需要人为设计复杂的模式和规则。因此,在标注数据充分的条件下,模型训练后性能可以得到保证。王超<sup>[5]</sup>等人首次公开了SAR图像船舶检测数据集,该数据集中的船舶切片种类丰富,但SAR图像成像目标清晰,因此并不适用于航海雷达场景。刘宁波<sup>[6]</sup>等人针对雷达对海上目标探测技术和数据缺乏等问题展开了X波段雷达采集工作。但其数据集采集场景较为单一,且采集的数据不包含标注信息。之后,罗来金<sup>[7]</sup>等人针对航海雷达数据开发了相关采集回放系统。吴鹏<sup>[8]</sup>等人提出了基于多尺度卷积融合结构和空间注意力加强的改进型单个深层神经网络(Single Shot MultiBox Detector, SSD)目标检测算法模型,提升了航海雷达对弱纹理小目标特征处理能力。宋海凌<sup>[9]</sup>等人提出一种基于特征金字塔的AD-CNN算法对雷达距离-多普勒数据中的目标特征进行表征提高了模型处理目标的分辨率。苏<sup>[10]</sup>等人采用LeNet等深度神经网络提取雷达目标微动特性,实现韦布尔杂波分布中的海面目标分类,但检测结果受信噪比的影响较大。以上研究验证了深度学习方法在雷达数据领域中的可行性和有效性,同时也证明利用深度神经网络可以提取数据中的隐含特征,能够实现优于传统算法的检测性能。然而,如何在复杂强杂波环境下进行目标检测仍极具挑战,典型问题包括雷达数据的自动标注以及相关数据缺乏时如何在小样本的条件下获得稳健检测<sup>[11]</sup>等。

尽管基于监督学习的方法取得了较大研究进展,目前仍有两个问题亟待解决。一是基于监督学习的模型高度依赖于数据标注,标注的数量和质量直接决定了模型

的性能。二是,基于有限训练数据的模型鲁棒性差且泛化能力不足,难以应对不断变化的海况和背景。对比学习旨在利用无标签数据让模型具备表示特征的能力,从而提升其迁移到下游任务时的性能。相比传统自监督学习,对比学习的核心思想是实例判别<sup>[12]</sup>,即将同一输入样本的不同增强作为正样本,对于不同输入和其增强作为负样本,通过优化正样本对之间的距离学习数据特征。基于这个思想,近期涌现出不少优秀的算法,其中Deep info Max方法<sup>[13]</sup>针对序列数据,使用两个增强的数据作为输入,通过最大化数据之间的互信息来学习特征表示过去和未来的序列。SimCLR方法<sup>[14]</sup>提出了另一种图像数据特征对比学习框架,通过对比每个批次里的实例数据构建任务,但其性能对批数据大小有很强的依赖。此外,MoCo方法<sup>[15]</sup>使用内存分配来解决批数据大小的问题,具体方式为维护一个负样本的存储空间。另外,Barlow Twins方法<sup>[16]</sup>提出了一种基于冗余信息减少的算法,其通过互相关矩阵来构建损失函数来学习正负样本包含的相关性。和前两种方式不同,方法BYOL<sup>[17]</sup>通过在线网络和目标网络来约束两个输出特征的均方误差(Mean Squared Error, MSE)来构造对比框架。方法SwAV<sup>[18]</sup>通过聚类的方式对比不同视角下的聚类结果,从而替代了直接对比实例之间特征来构建表示学习任务。

航海雷达数据量大,数据类型复杂。单纯利用监督手段的方法标注成本过高,不具备普适性。同时,缺乏标签信息让基于深度学习的模型无法从杂波背景中检测小目标。为了解决上述问题,本文建立了可用于深度学习方法的航海雷达数据集,并提出了一种基于对比学习的航海雷达目标检测方法(Contrastive Learning approach for Marine Radar Detection, CLMRD),该方法通过交替预测和分布对齐的方式让模型从海量无标签数据中获取特征表示能力,从而训练模型具备分辨杂波和目标的判别能力。在预训练阶段后,方法结合目标检测器并在后处理阶段对结果进行融合处理,最终在实际航海雷达数据上取得良好检测结果。

本文的贡献总结为以下两点。

(1)本文建立了两个全新的航海雷达数据集,具体包含无标签信息的航海雷达数据集(Unlabeled Marine Radar Dataset, UMRD)和带有标签信息的航海雷达检测数据集(Marine Radar Detection Dataset, MRDD)。该数据集可支持有监督学习和无监督学习训练,填补了航海雷达领域数据集的空白。

(2)本文提出基于对比学习的航海雷达目标检测方法(CLMRD),该方法首次将对比学习引入航海雷达目标检测算法,从而有效利用无标签航海雷达数据以提升算法性能。具体而言,基于对比学习预训练阶段使用交替预测和分布对齐两种方式让模型分别从实例和

分布级别学习无标签数据特征,让模型具备分辨杂波和目标的能力.之后,CLMRD结合预训练得到的初始化权重,在目标检测阶段与Yolov5检测器结合与训练并在后处理阶段对结果融合,最终得到整体检测结果.

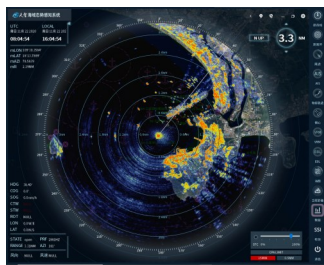
## 2 航海雷达数据集

数据集的构成航海雷达目标检测任务面临多种气候和海况变化等应用场景,为了验证算法的有效性和鲁棒性,本文建立了带有标签信息的航海雷达检测数据集(MRDD)和不包含标签信息的航海雷达无标签数据集(UMRD).该数据集可用于有监督学习任务和无监督学习任务,航海雷达智能化方法的引入提供了充足数据样本.


本文数据采集设备为古野船用FURUNO FAR-2117 X波段扫描雷达,其天线为开槽波导阵列,工作时采用水平极化,360°水平扫描,转速为24 rpm,数据显示效果如图1(a)所示.通过在常年出海的大型船只以及

岸基港口处部署相应采集系统,可获得多场景多视角的雷达目标原始回波数据.采集数据包含多种海况条件,具体包含0~4级海浪和0~5级海风.数据主要覆盖以下几种场景:(1)远海不同量程观测;(2)远海不同强度海杂波干扰;(3)近海船只目标密集;(4)近岸强地杂波干扰等常见航海雷达实际观测场景,包含了大型货船、军舰、渔船、浮标、游艇等航海雷达观测目标.图1(b)给出了部分实际观测目标的可见光数据实例(提供真值),类型包括游艇、帆船、各型货船、渔船和军舰等.图1(c)展示了MRDD数据集子图构建的过程.


通过联动采集,雷达传感器可获得雷达的连续帧图像,该类数据蕴含大量时序信息,可以有效判别运动目标.同时,雷达散射面积小的目标雷达回波较为微弱,通过连续帧的叠加可以增大目标的回波强度.本文参考邹浩等人在文献[19]中的方法,对雷达原始数据进行预处理:将连续三帧灰度图按照时间从前往后依次作为R、G、B三个通道,合成伪彩色图像.



(a) 航海雷达数据P显示例



(b) 采集船只数据示例



(c) MRDD数据集子图构建过程

图1 数据集构建过程

航海雷达无标签数据集(UMRD)航海雷达无标签数据集由包含雷达目标的图像和不包含雷达目标的杂波背景图像组成,不包含标签信息.其涵盖了各种类型的杂波和目标.本文将原始航海雷达图像切割成子图,以适配实际部署时的检测场景.UMRD总共有60 960个图像数据,单个图像数据分辨率为608×608.数据集具体示例如图2所示.

航海雷达检测数据集(MRDD)航海雷达检测数据集(MRDD)共有13 762张伪彩色图像,图像分辨率为608×608,每张数据都包含目标对应的标签信息,详细统计如表1所示.

本文将采集的数据按照9:1的比例随机划分为训

练集和测试集.针对不同数据场景,MRDD测试集划分为如下远海测试集和近海测试集,示例见图3.

远海测试集:共547张608×608×3伪彩色图像,包




图2 UMRD数据集示意

含强海杂波和远距离目标等应用场景.

近海测试集:共 700 张  $608 \times 608 \times 3$  伪彩色图像,包含有 40 张近岸陆地杂波和 40 张海湾近岸密集目标图像.

表 1 MRDD 数据统计情况

数据集	单张分辨率	数量	目标数量
MRDD 远海数据集	$608 \times 608$	547	982
MRDD 近海数据集	$608 \times 608$	700	1 873
MRDD 训练集	$608 \times 608$	13 762	23 100




图 3 MRDD 近、远海测试集

### 3 基于对比学习的航海雷达目标检测方法

对比学习作为一种创新的自监督表示学习 (Self-Supervised Learning, SSL) 方法,近期在计算机视觉任务中表现优越,其在目标分类、目标检测、分割和迁移学习等任务中的性能不输于监督学习.对比学习通过挖掘无标签数据本质的特征信息,旨在解决有限训练数据情况下模型鲁棒性、泛化能力差的问题.将对比学习引入航海雷达检测旨在让模型从海量数据特征中挖掘目标特征属性,从而让模型从复杂海况背景中完成对目标的检测任务.

本节具体介绍基于对比学习的航海雷达目标检测方法 (CLMRD).该方法包括三个阶段,如图 4 所示.第一阶段为基于对比学习的预训练.该阶段旨在为特征提取器提供一个好的初始化.第二阶段为航海雷达目标检测.该阶段使用第一阶段所学的特征提取器的初始化参数,进行端到端的目标检测网络训练.第三阶段为后处理,该阶段对第二阶段的检测结果进行整合处理,并给出最终的检测结果.接下来对每一阶段进行详

细阐述.

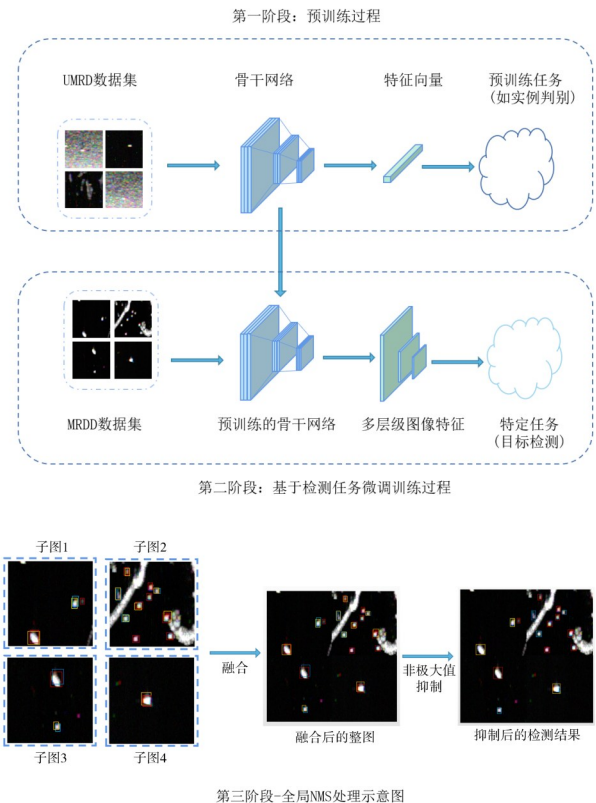


图 4 CLMRD 整体全部阶段过程示意图

#### 3.1 基于对比学习的预训练

该阶段主要包含两个模块,第一个是交替预测模块,第二个为分布对齐模块.训练时,从训练数据中采样一个批次的样本,记为  $X = \{\mathbf{x}_i\}_{i=1}^n$ ,其中  $\mathbf{x}_i$  表示一个输入样本,  $n$  表示批次所包含的样本数量.对每个批次数据的所有样本进行两次增强,得到  $X' = \{\mathbf{x}_i^1, \mathbf{x}_i^2\}_{i=1}^n$ .其中  $\mathbf{x}_i^1, \mathbf{x}_i^2$  分别是由  $\mathbf{x}_i$  经过二次不同数据增强得到.之后,对  $X'$  进行变形得到  $X' = \{X'_1, X'_2\}$ ,其中  $X'_j = \{\mathbf{x}_i^j\}_{i=1}^n, j \in \{1, 2\}$ .不失一般性,假定  $X'_j$  是从概率分布  $P^j$  采样所得.首先将  $X'$  输入到特征提取器  $f_\theta$  中得到其内所有样本的特征表示  $Z'$ ,其中  $Z' = \{Z'_1, Z'_2\} = \{\mathbf{z}_i^1, \mathbf{z}_i^2\}_{i=1}^n, \mathbf{z}_i^j = f_\theta(\mathbf{x}_i^j) / \|f_\theta(\mathbf{x}_i^j)\|, Z'_j = \{\mathbf{z}_i^j\}_{i=1}^n, j \in \{1, 2\}$ .在接下来的内容中将详细介绍基于对比学习的预训练阶段所包含的两个模块.

##### 3.1.1 交替预测模块

交替预测模块旨在从实例级别约束同一样本的不同增强下所提取出的语义信息一致.为此,本文设计了一个交替预测的学习方式.具体而言,假定训练数据包含  $K$  个类别,并将所有的类别中心所组成的类别原型矩阵记为

$\mathbf{C} = [\mathbf{c}_1 \ \mathbf{c}_2 \ \dots \ \mathbf{c}_K]$ , 其中  $\mathbf{c}_i$  表示第  $i$  个类别中心(或类别原型). 对于训练批次的一对增强样本的特征  $Z_i = \{\mathbf{z}_i^1, \mathbf{z}_i^2\}$ ,  $i \in \{1, 2, \dots, n\}$  首先给出与之对应的类别标签, 然后通过分类器对特征进行分类, 并将其分类到对应的标签, 记  $q_i^j$  为  $\mathbf{z}_i^j$  对应的标签, 其中  $j \in \{1, 2\}$ . 定义分类器  $\text{cl}_C$  预测的类别概率分布如下:

$$\text{cl}_C(\mathbf{z}_i^j)_m = \frac{\exp\left(\frac{1}{\tau}(\mathbf{z}_i^j)^\top \mathbf{c}_m\right)}{\sum_{l=1}^K \exp\left(\frac{1}{\tau}(\mathbf{z}_i^j)^\top \mathbf{c}_l\right)} \quad (1)$$

其中  $\text{cl}_C(\mathbf{z}_i^j)_m$  表示特征  $\mathbf{z}_i^j$  属于类别  $m$  的概率, 以及  $m \in \{1, 2, \dots, K\}$ . 由式(1)可知, 所定义的分类器  $\text{cl}_C$  类似于 softmax 分类器.

标签  $q_i^j$  是通过无监督聚类的方式所产生的, 其背后的主要思想是将一个迷你批的训练数据均匀分配到  $K$  个类别, 与此同时尽可能保证类内相似性. 为此可得如下目标函数式(2):

$$\max_{\mathbf{Q}^j \in \mathcal{Q}} \text{Tr}(\mathbf{Q}^j \mathbf{C}^\top Z_j') + \varepsilon H(\mathbf{Q}^j) \quad (2)$$

其中,  $\mathbf{Q}^j$  表示样本的标签矩阵, 记为  $\mathbf{Q}^j = [q_1^j \ q_2^j \ \dots \ q_n^j]$ ,  $j \in [1, 2]$ ,  $H(\mathbf{Q}^j) = -\sum_{i_1, i_2} \mathbf{Q}_{i_1, i_2}^j \log \mathbf{Q}_{i_1, i_2}^j$  表示信息熵. 其中:

$$\mathcal{Q} = \left\{ \mathbf{Q}^j \in \mathbb{R}_+^{K \times n} \mid \mathbf{Q}^j \mathbf{1}_n = \frac{1}{K} \mathbf{1}_K, (\mathbf{Q}^j)^\top \mathbf{1}_K = \frac{1}{n} \mathbf{1}_n \right\} \quad (3)$$

$\mathbf{1}_K, \mathbf{1}_n$  表示适当维度的元素值为全 1 矩阵,  $\mathbb{R}_+^{K \times n}$  表示维度为  $K \times n$  并且元素全为正数矩阵空间. 由文献[20]中方法可得, 式(3)可以使得训练数据被平均分配到每个类别. 目标函数式(2)可以通过如下等式得到传输原型的最优解  $\mathbf{Q}^*$ :

$$\mathbf{Q}^* = \text{diag}(\mathbf{u}^j) \exp\left(\frac{\mathbf{C}^\top Z_j'}{\varepsilon}\right) \text{diag}(\boldsymbol{\phi}^j) \quad (4)$$

其中  $\mathbf{u}^j \in \mathbb{R}^K$  和  $\boldsymbol{\phi}^j \in \mathbb{R}^n$  是经 Sinkhorn-Knopp 算法迭代计算得到,  $\varepsilon$  为事先给定的超参数.

最终, 基于交替迭代的学习方式, 可以训练  $f_\theta, \mathbf{C}$ , 以及  $\mathbf{Q}^j$ . 具体而言, 首先固定  $\mathbf{Q}^j$  并最小化式(5)中目标函数更新  $f_\theta$  和  $\mathbf{C}$ :

$$L(Z_1', Z_2', \mathbf{Q}^1, \mathbf{Q}^2) = l(Z_1', \mathbf{Q}^1) + l(Z_2', \mathbf{Q}^2) \quad (5)$$

其中  $l(\cdot)$  表示交叉熵损失. 接着, 固定  $f_\theta$  和  $\mathbf{C}$ , 通过式(4)更新对应的  $\mathbf{Q}^1, \mathbf{Q}^2$ .

### 3.1.2 分布对齐模块

交替预测模块基于实例级别的学习范式学习特征表示, 而分布对齐模块进一步从分布对齐的角度学习特征表示. 换言之, 分布对齐模块旨在最小化基于不同数据增强得到的分布  $P^1$  和分布  $P^2$  之间的距离. 具体而言, 给定

一个批次的样本, 记为  $X = \{\mathbf{x}_i\}_{i=1}^n$ , 其中  $\mathbf{x}_i$  表示一个输入样本,  $n$  表示批次所包含的样本数量. 对该批次数据的所有样本进行两次不同数据增强, 得到  $X' = \{\mathbf{x}_i^1, \mathbf{x}_i^2\}_{i=1}^n$ . 其中  $\mathbf{x}_i^1, \mathbf{x}_i^2$  分别是由  $\mathbf{x}_i$  经过二次数据增强得到. 之后, 同样对  $X'$  进行变形得到  $X' = \{X_1', X_2'\}$ , 其中  $X_j' = \{\mathbf{x}_i^j\}_{i=1}^n, j \in \{1, 2\}$ . 将  $X'$  输入到特征提取器  $f_\theta$  中得到其所有样本的特征表示  $Z'$ , 其中,  $Z' = \{Z_1', Z_2'\} = \{\mathbf{z}_i^1, \mathbf{z}_i^2\}_{i=1}^n, \mathbf{z}_i^j = f_\theta(\mathbf{x}_i^j) / \|f_\theta(\mathbf{x}_i^j)\|, Z_j' = \{\mathbf{z}_i^j\}_{i=1}^n, j \in \{1, 2\}$ . 假设  $Z_j'$  中的样本是从分布  $P^j$  中独立采样得到, 并记  $P^1, P^2$  为同一批次下样本经过两种不同数据增强得到的数据分布.

常用的数据分布度量算法有最大平均偏差<sup>[21]</sup>, 该方法最早被用于度量核希尔伯特空间中两个分布之间的均值差. 除此之外, 深度相关校准通过二阶统计量测量两个分布之间的差异. 此外, Kullback-Leibler 散度<sup>[22]</sup>、Jensen-Shannon 散度<sup>[23]</sup>和 Wasserstein 距离<sup>[24, 25]</sup>都是衡量两个分布之间差异的有效方法. 类似地, 文献[26, 27]采用衡量互信息来度量不同分布间的相似性. 另外, 文献[28]是利用熵最小化的过程来计算分布间的差异. 本文采用 KL 散度计算数据分布  $P^1$  和数据分布  $P^2$  之间的距离.

对于随机变量  $\mathbf{x}$ , 以及两个不同的概率分布  $P(\mathbf{x})$  和  $V(\mathbf{x})$ , KL-散度 (Kullback-Leibler Divergence) 定义如下所示:

$$\text{KL}(P(\mathbf{x}) \parallel V(\mathbf{x})) = \int P(\mathbf{x}) \log \frac{P(\mathbf{x})}{V(\mathbf{x})} d(\mathbf{x}) \quad (6)$$

最终, 分布对齐模块的目标函数可表示为:

$$\min_{f_\theta} \text{KL}(P^1, P^2) \quad (7)$$

### 3.1.3 最终目标函数

最终目标函数是由交替预测模块的目标函数和分布对齐模块的目标函数融合所得. 具体如下, 其中超参数  $\tau$  控制分布对齐模块的目标函数占最终目标函数中的比例:

$$\min_{\mathbf{C}, f_\theta, \mathbf{Q}^1, \mathbf{Q}^2} \text{KL}(P^1, P^2) \cdot \tau + L(Z_1', Z_2', \mathbf{Q}^1, \mathbf{Q}^2) \quad (8)$$

预训练阶段流程如图 5 所示, 伪代码如算法 1 所示. 综上, 最终目标函数通过交替预测的方式从实例级别挖掘数据的一致性信息, 同时使用分布对齐的方式从数据的全局层面学习判别信息. 最终, CLMRD 可在预训练阶段充分学习海量数据特征, 从而增强模型对杂波和目标特征的判别能力.




图 5 CLMRD 对比学习阶段架构

### 算法 1 CLMRD 基于对比学习的预训练算法

输入: 训练数据集  $X$ , 预设原型矩阵  $C$ , 模型特征提取器  $\text{model}$ , 线性层  $\text{mlp}$

输出: 训练后  $\text{model}$  权重

- 1) For  $x$  in dataset  $X$ :
- 2)  $x_t = t(x)$ ,  $x_s = s(x)$
- 2)  $z = \text{model}((x_t, x_s))$
- 3)  $\text{scores} = \text{mm}(\text{cat}(z, C))$
- 4)  $\text{scores}_{x_t} = \text{scores}[\mathbf{B}]$
- 5)  $\text{scores}_{x_s} = \text{scores}[\mathbf{B}]$
- 6)  $p_{x_t} = \text{softmax}(\text{scores}_{x_t})$
- 7)  $p_{x_s} = \text{softmax}(\text{scores}_{x_s})$
- 8)  $P_{v_t} = \text{mlp}(z_t)$
- 9)  $P_{v_s} = \text{mlp}(z_s)$
- 10) Minimize function (7) and update loss in function (8)
- 11) Update parameters of  $C$  and  $\text{mlp}$
- 12) End for

## 3.2 航海雷达目标检测

Yolo 系列算法<sup>[29,30]</sup>因其计算速度快、对小目标识别友好等优点被业内普遍采用。因此,本文选择 Yo-

lov5 作为航海雷达目标检测阶段中的目标检测器并使用 3.1 节基于对比学习预训练后的权重作为其检测器的初始权重。本文所采用的整体预训练模型的网络结构如图 6 所示。为了更好的适配下游检测的任务,将 YOLOv5 的 Backbone 和 Neck 模块当作骨干网络。其中, YOLOv5 的 Backbone 由 Focus 结构和 CSP 结构组成,时序的航海雷达图像经过  $\text{resize}$  操作将其图像尺寸转换为  $640 \times 640 \times 3$  的大小,之后将其作为网络模型的输入。时序数据在输入 YOLOv5 模型后首先经过一个 FOCUS 层, FOCUS 层主要做了一个切片 ( $\text{slice}$ ) 的操作,切片后得到的图片转变为十二个通道,最后将得到的图片经过卷积操作,得到没有信息丢失的二倍采样特征图,其目的是加快后续操作的计算速度。经过处理后的图像会输入 CSP 层, CSP 层主要由卷积操作和残差单元组成。CSP 层之后连接一个 CSP 层,其主要由卷积层、批归一化 (BN) 层和激活层 (SiLU) 构成。CSP 层和 CBS 层产生不同尺寸的特征图,将其不同大小的特征图送入 Neck 模块与其不同特征在通道维度进行拼接。然后再经过一个卷积模块得到不同尺度的特征图,用于后续的输出检测结果。航海雷达目标检测模块核心伪代码如算法 2 所示。

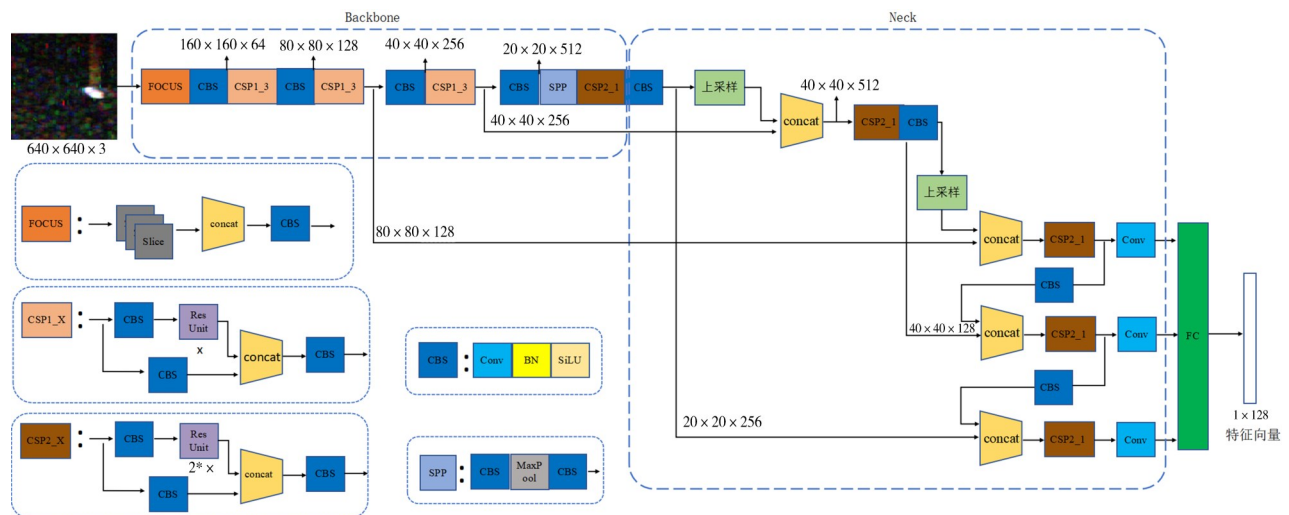


图 6 YOLOv5 网络结构示

## 3.3 后处理

在 3.2 节航海雷达目标检测阶段的基础上,本文根据航海雷达数据实际情况,在后处理阶段中提出了一种全局非极大值抑制 (NMS) 处理方法,提出的全局 NMS 算法旨在航海雷达的全图范围上融合各子图像数据的检测结果,进一步降低误报率并消除同一检测结果中存在的多个重复检测框和目标缺失的问题,从而得到算法在全局范围的最优解。其伪代码如算法 3 所示。

## 4 实验结果与分析

实验中,本文将 3.1 节基于对比学习的预训练阶段训练后得到的模型权重作为目标检测阶段的初始权重。之后,在 MRDD 训练数据集进行权重微调,并在 MRDD 远、近海测试集上进行实验。

### 4.1 对比的方法

在实验中本文选取了目前先进的目标检测器进行对比,具体包括 YOLOv3, YOLOv5<sup>[29,30]</sup>, Faster-RCNN<sup>[31]</sup>, FCOS<sup>[32]</sup>, SSD<sup>[33]</sup> 和 DETR<sup>[34]</sup>。为了保证实验的公平性,

**算法 2 Yolov5 目标检测算法**

输入:骨干网络:CSP; Neck网络:SPPF,CSP\_new; Head网络:

YOLOv3\_head; MRDD 训练数据集: $X$

输出:训练后模型权重

1) For img in dataset  $X$ :

2) features = CSP\_Darknet532\_new(img)

3) out\_features = CSP\_new(SPPF(features), features)

4) Update loss

5) Update parameters

6) End for

**算法 3 全局 NMS**

输入:子图中的所有预测框: $B=[b_1 b_2 b_3 \dots b_N]$ ,对应检测预测框的

检测分数  $S=(s_1, s_2, s_3, \dots, s_N)$ , 阈值  $C_r$ , Soft-NMS 阈值  $N_t$

输出:位置参数  $D$ , 置信度参数  $T$ .

1) For data in a batch:

2) 根据坐标关系,将子图预测框结果坐标  $B=[b_1 b_2 b_3 \dots b_N]$  转

移到全图坐标中,得到  $B'=[b'_1 b'_2 b'_3 \dots b'_N]$

3) 依据设定阈值  $C_r$ , 在列表  $B'$  中筛选置信度低于的预测框

4) 执行 Soft-NMS

5) 返回位置参数  $D$  和置信度参数  $T$

6) End for

在训练和测试阶段中,本文将所有的方法在训练及测试过程涉及的超参数保持一致。

**4.2 实验细节**

本文在实验中所用硬件配置:4个3090 GPU、2个Xeon Gold CPU和64 GB内存。本文测试代码运行均基于Pytorch框架。其中,在预训练阶段:本文设置初始学习率为0.6,并设定动态调整机制,将学习率设置为随着训练过程衰减,在训练结束时衰减至0.0006。此外,模型优化器使用了随机梯度下降方法<sup>[35]</sup>(SGD)并将其温度参数 $\tau$ 设置为0.1。另外,权重衰减参数设置为 $10^{-6}$ 。此外,预训练阶段使用LARS优化器,并将前20个阶段的学习率设置为4.8。迭代20个轮次后,将余弦学习率衰减调整为0.1。

**4.3 实验结果及讨论****4.3.1 MRDD数据集检测结果**

方法CLMRD在对比学习预训练阶段使用UMRD无标签数据集进行特征学习,训练结束后得到特征权重。在此基础上,使用Yolov5检测框架在MRDD的近海、远海数据上进行训练和测试。方法CLMRD及其对比方法的实验结果如表2和表3所示。

根据表2和表3的结果可以看出CLMRD方法在MRDD近海和远海数据集上都取得了最优的精度,其准确率和召回率分别达到0.97,0.95和0.95,0.93。与Yolov5目标检测器相比,在后者已经取得精准结果的基础上又提高5%的精度。同时,相比于目前其他高性

**表 2 近海测试集对比结果**

方法	准确率	召回率	AP	时间/ms
Yolov5	0.96	0.94	0.97	35
SSD	0.62	0.97	0.84	66
FCOS	0.74	0.82	0.82	73
Yolov3	0.87	0.69	0.87	53
Faster RCNN	0.90	0.68	0.90	85
DETR	0.96	0.96	0.98	50
<b>CLMRD</b>	<b>0.97</b>	<b>0.96</b>	<b>0.99</b>	35

**表 3 远海测试集对比结果**

方法	准确率	召回率	AP	时间/ms
Yolov5	0.94	0.92	0.95	35
SSD	0.31	0.97	0.92	66
FCOS	0.52	0.85	0.88	73
Yolov3	0.72	0.89	0.83	53
Faster RCNN	0.76	0.93	0.92	85
DETR	0.91	0.93	0.96	50
<b>CLMRD</b>	<b>0.95</b>	<b>0.93</b>	<b>0.97</b>	35

能检测器,CLMRD方法在检测性能上具有明显优势,在MRDD近、远海数据集上均能保证很高召回率和准确率。同样,在单帧检测时间上,CLMRD单张检测时间为35 ms,在对比方法中用时最短。

CLMRD在预训练阶段通过对大量无标签航海雷达数据进行自监督学习,让模型获得航海雷达目标特征的提取和表示的能力,为目标检测阶段提供更好的网络模型参数初始化权重,从而有效提高下游目标检测性能。近海测试集和远海测试集的测试结果均展现出CLMRD性能的优越性。本文实验所用的UMRD和MRDD数据采集自航海雷达实际工作场景,保证了方法的实效性,测试数据示例如图7所示。


**4.3.2 消融实验**

(1) 基于对比学习预训练及后处理阶段的影响 (CLMR)


为了进一步验证本文提出方法的有效性和泛化性,将对对比学习预训练和后处理阶段所包含的方法(CLMR)和其他目标检测器进行适配。在实验过程中,本文采用同样的训练步骤,具体为:先使用UMRD数据集训练600个轮次。之后,将预训练得到的权重作为检测模型的初始权重并在MRDD数据集上训练600个轮次。从表4可以看出,和对比的方法相比,与CLMR结合的目标检测器均取得了较大幅度的提升。其中,平均准确率提高了约5.6%,召回率提高了约5.0%。

(2) 训练轮次的影响

本节进一步在MRDD数据上展开消融实验来验证训练轮次的相关性。在预训练阶段得到的模型初始权重基础上,设置不同训练轮次并测试其在MRDD测试

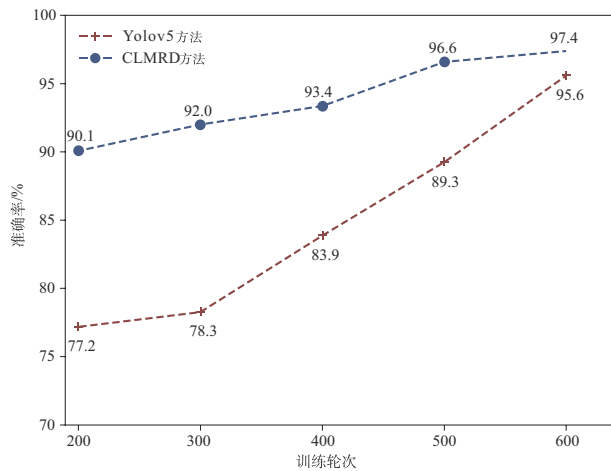


(a) MRDD 全图检测效果示意

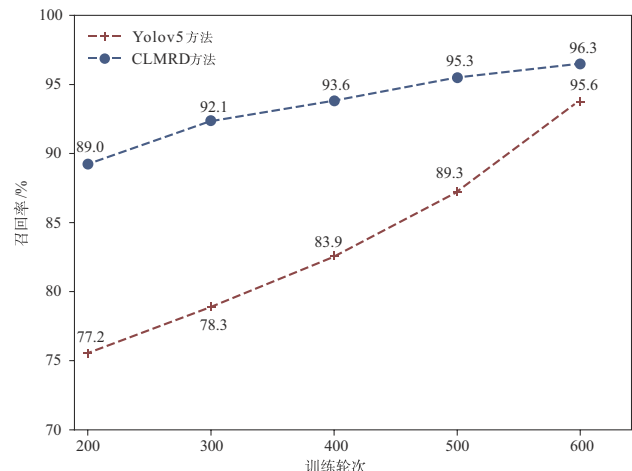


(b) MRDD 子图效果示意

图7 算法 CLMRD 在 MRDD 远、近海测试集检测效果



(a) 准确率比较结果



(b) 召回率比较结果

图8 CLMRD 和 Yolov5 在不同轮次训练下的对比结果

### (3) 预训练阶段不同训练轮次的影响

本节进一步验证了 CLMRD 对比学习阶段训练轮次对整体算法检测性能的影响,从图 9(a)和(b)中可以看到,在 400 次轮次后,预训练阶段整体损失的数值由 6.5 下降到了 4.5.同时,分布对齐模块的损失也从 0.1 下降到了 0.066 左右.从图 9(c)中可以看到,和监督方式相比,CLMRD 方法可以用更短的训练轮次获得更好的性能.同时,在对比学习预训练阶段中更多的训练轮次也可以提升 CLMRD 在检测任务中的性能.

### (4) 超参 $\tau$ 的影响


在上述实验结果基础上,本节进一步对 CLMRD 预训练步骤中分布度量模块中的超参数进行了消融实验.实验具体结果如图 10 所示.其中,参数  $\tau$  控制了分布度量损失在全局损失中的占比.根据实验结果,当参数  $\tau$  被设定为 0.01 时,CLMRD 在 MRDD 数据上取得了 AP 值 96.6 的最优结果.

(5) 除与传统方法对比外,本文同时在 MRDD 近海数据上与传统检测方法进行对比.其中传统方法采用


表4 MRDD 近海测试集消融实验对比结果

方法	准确率	召回率	AP
Yolov5	0.96	0.94	0.97
SSD	0.62	0.97	0.84
FCOS	0.74	0.82	0.82
Yolov3	0.87	0.69	0.87
Faster RCNN	0.90	0.68	0.90
DETR	0.94	0.94	0.96
<b>CLMRD</b>	<b>0.97</b>	<b>0.96</b>	<b>0.99</b>
CLMR+(SSD)	0.72	0.97	0.88
CLMR+(FCOS)	0.78	0.87	0.89
CLMR+(Yolov3)	0.89	0.75	0.85
CLMR+(Faster RCNN)	0.92	0.77	0.93
CLMR+(DETR)	0.96	0.95	0.97

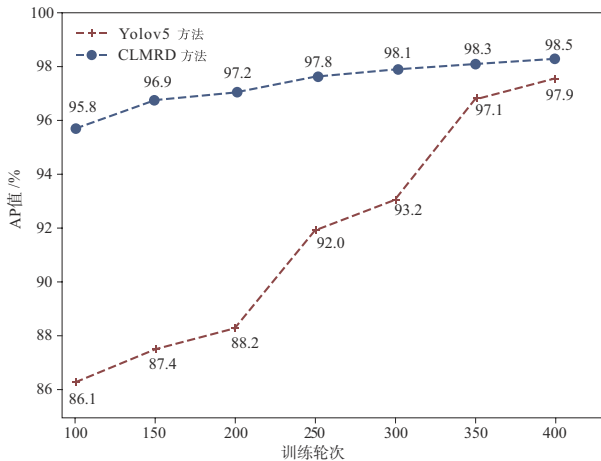
集的检测效果.如图 8 所示,相比于 Yolov5 算法,CLMRD 可以在更短的训练轮次的条件下训练得到更好的检测模型,这充分说明了预训练阶段的有效性和鲁棒性.同时,更短的训练轮次也可以缩短算法更新和部署的时间.



(a) 整体损失下降过程



(b) 分布对齐模块损失下降过程



(c) CLMRD不同预训练轮次在检测任务中的结果

图9 预训练轮次的影响

固定门限检测目标,并通过目标尺寸距离等先验条件设置感兴趣范围以剔除多余虚警. 本文参照文献[36]设置传统方法的检测参数,其中重要参数设置如下:最小目标距离为 20 m;目标跨越最小采样点数为 5;目标跨越距离向最小值为 15 m;目标跨越方位最小度数为 0.5;目标跨越方位最大度数为 6. 另外,其他参数还包括检测距离范围、有效目标强度区间、目标尺寸大小门限等. 根据表 5 可以看出,和传统方法相比 CLMRD 在高召回率的情况下可以同时保持高准确率,降低虚警的数量,见图 11.

(6)和传统NMS方法的对比

本节进一步在 MRDD 远海测试集上验证 CLMRD

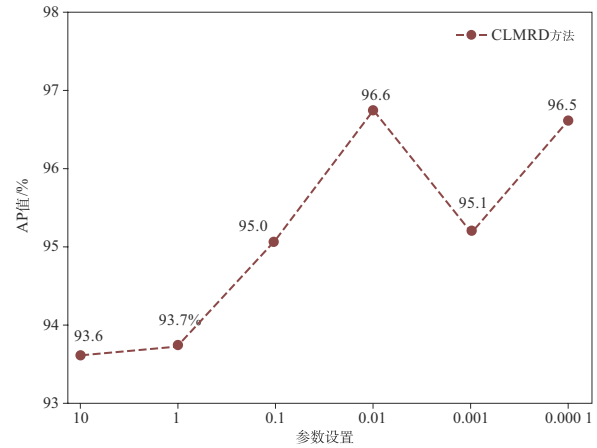


图10 不同参数  $\tau$  对 CLMRD 的影响

表 5 MRDD 近海数据集上 CLMRD 与传统方法对比结果

方法	准确率	召回率	虚警数
传统处理	0.28	0.96	20 572
<b>CLMRD</b>	<b>0.96</b>	<b>0.99</b>	<b>1 300</b>




图 11 与传统方法方式在全图对比示意(左侧为传统方法检测效果,右侧为 CLMRD 方法检测效果)

后处理中全局 NMS 算法的有效性. 从图 12 可以看出, CLMRD 在后处理阶段可以更好的去除重复检测框,减少虚警目标的数量. 同时,该阶段也可以提升算法整体检测结果的质量,让单个检测框更加贴近目标实际位




图 12 CLMRD 后处理算法可视化对比

图 12 CLMRD 后处理算法可视化对比

置,提高算法对目标的定位能力,为后续任务目标跟踪等提供支持.

#### 4 结语

本文首先建立了两个航海雷达数据集 UMRD 和 MRDD,为基于深度学习的智能算法的引入提供了基础条件.在数据集的基础之上,本文提出了基于对比学习的航海雷达目标检测方法(CLMRD),该方法在预训练阶段通过交替预测和分布对齐让模型分别从数据实例级别和数据分布级别来学习特征表示,提高模型提取特征的能力,并得到更好的初始化权重.之后,CLMRD 算法在航海雷达目标检测阶段将算法与目标检测任务结合并在后处理阶段对检测结果进行融合.在 MRDD 航海雷达目标数据集上,CLMRD 在准确率和召回率方面都大大优于其他目标检测算法,证明了方法的优越性.后续,会结合更多实验航次和更丰富的数据,进一步提高 CLMRD 算法在未知数据下的泛化能力和鲁棒性.

#### 参考文献

- [1] DE MAIO A, FOGLIA G, CONTE E, et al. CFAR behavior of adaptive detectors: An experimental analysis[J]. IEEE Transactions on Aerospace and Electronic Systems, 2005, 41(1): 233-51.
- [2] 刘彬. 舰载导航雷达目标检测技术研究[D]. 哈尔滨: 哈尔滨工业大学, 2016.  
LIU B. Shipboard Navigation Radar Target Detection Technology Research[D]. Harbin: Harbin Institute of Technology, 2016. (in Chinese)
- [3] YOUNSI A, GRECO M, GINI F, et al. Performance of the adaptive generalized matched subspace constant false alarm rate detector in non-Gaussian noise: An experimental analysis[J]. IET Radar, Sonar and Navigation, 2009, 3(3): 195-202.
- [4] BALAKHDER A M. Intelligent Approach to Improve Standard CFAR Detection in Non-Gaussian Sea Clutter[D]. Columbus: The Ohio State University, 2015.
- [5] WANG Y, WANG C, ZHANG H, et al. A SAR dataset of ship detection for deep learning under complex backgrounds[J]. Remote Sensing, 2019, 11(7): 765.
- [6] 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.  
LIU N, DONG Y, WANG G, et al. Sea-detecting X-band radar and data acquisition program[J]. Journal of Radars, 2019, 8(5): 656-667. (in Chinese)
- [7] 罗来金,曾连荪,夏念. 航海雷达数据高速采集回放系统设计与实现[J]. 电子设计工程, 2011, 19(13): 46-48.  
LUO L, ZENG L, XIA N. Design and implementation of high-speed navigation radar data acquisition and playback system[J]. Electronic Design Engineering, 2011, 19(13): 46-48. (in Chinese)
- [8] 孙备,左震,吴鹏,等. 面向无人艇环境感知的改进型 SSD 目标检测方法[J]. 仪器仪表学报, 2021, 42(9): 52-61.  
SUN B, ZUO Z, WU P, et al. Object detection for environment perception of unmanned surface vehicles based on the improved SSD[J]. Chinese Journal of Scientific Instrument, 2021, 42(9): 52-61. (in Chinese)
- [9] 宋海凌,孙宇航,何良,等. 雷达回波信号的深度学习目标检测识别方法研究[J]. 战术导弹技术, 2021, 206(2): 117-126.  
SONG H L, SUN Y H, HE L, et al. Research on deep learning object detection and recognition method based on radar echo signal[J]. Tactical Missile Technology, 2021, 206(2): 117-126. (in Chinese)
- [10] SU N, CHEN X, MOU X, et al. A deep learning method of moving target classification in clutter background[C]// Proceedings of International Conference in Communications, Signal Processing, and Systems. Singapore: Springer, 2019: 303-311.
- [11] 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.  
SONG T, HE F S, CHENG Y F. Research progress of deep learning technology in radar target detection[J]. Aeronautical Science and Technology, 2020, 31(10): 12-20. (in Chinese)
- [12] WU Z, XIONG Y, YU S, et al. Unsupervised feature learning via non-parametric instance discrimination[C]// Proceedings of IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2018: 3733-3742.
- [13] HJELM R D, FEDOROV A, LAVOIE-MARCHILDON S, et al. Learning deep representations by mutual information estimation and maximization[EB/OL]. [2022]. arXiv: 1808.06670. <https://arxiv.org/abs/1808.06670>.
- [14] CHEN T, KORNBLITH S, NOROUZI M, et al. A simple

- framework for contrastive learning of visual representations [C]//Proceedings of the 37th International Conference on Machine Learning. New York: ACM, 2020: 1597-1607.
- [15] HE K, FAN H, WU Y, et al. Momentum contrast for unsupervised visual representation learning[C]//Proceedings of IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2020: 9726-9735.
- [16] ZBONTAR J, JING L, MISRA I, et al. Barlow twins: Self-supervised learning via redundancy reduction[C]//Proceedings of International Conference on Machine Learning. PMLR, 2021: 12310-12320.
- [17] J-B GRILL, STRUB F, ALTCHÉ F, et al. Bootstrap your own latent a new approach to self-supervised learning[C]//Proceedings of Advances in Neural Information Processing Systems. California: NIPS, 2020: 21271-21284.
- [18] CARON M, MISRA I, MAIRAL J, et al. Unsupervised learning of visual features by contrasting cluster assignments[C]//Proceedings of Advances in Neural Information Processing Systems. California: NIPS, 2020: 9912-9924.
- [19] 邹浩, 林赟, 洪文. 采用深度学习的多方位角 SAR 图像目标识别研究[J]. 信号处理, 2018, 34(5): 513-522.
- ZOU H, LIN Y, HONG W. Research on multi-aspect SAR images target recognition using deep learning[J]. Journal of Signal Processing, 2018, 34(5): 513-522. (in Chinese)
- [20] ASANO Y M, RUPPRECHT C, VEDALDI A. Self-labelling via simultaneous clustering and representation learning[EB/OL]. [2022]. arXiv: 1911.05371. <https://arxiv.org/abs/1911.05371>.
- [21] BORGWARDT K M, GRETTON A, RASCH M J, et al. Integrating structured biological data by kernel maximum mean discrepancy[J]. Bioinformatics, 2006, 22(14): e49-e57.
- [22] ERVEN V, PETER H. Renyi divergence and Kullback-Leibler divergence[J]. IEEE Transactions on Information Theory, 2014, 60(7): 3797-3820.
- [23] FUGLEDE B, TOPSOE F. Jensen-Shannon divergence and Hilbert space embedding[C]//Proceedings of International Symposium on Information Theory. Piscataway: IEEE, 2004: 30-31.
- [24] HE R, WU X, SUN Z, et al. Wasserstein CNN: Learning invariant features for NIR-VIS face recognition[J]. IEEE Transactions on Medical Imaging, 2018, 37(6): 1348-1357.
- [25] SHEN J, QU Y, ZHANG W, et al. Wasserstein distance guided representation learning for domain adaptation[C]//Proceedings of AAAI Conference on Artificial Intelligence. NY: AAAI, 2018: 4058-4065.
- [26] GHOLAMI B, SAHU P, RUDOVIC O, et al. Unsupervised multi-target domain adaptation: An information theoretic approach[J]. IEEE Transactions on Image Processing, 2020, 29: 3993-4002.
- [27] XIE X, CHEN J, LI Y, et al. MI2GAN: Generative adversarial network for medical image domain adaptation using mutual information constraint[C]//Proceedings of International Conference on Medical Image Computing and Computer Assisted Intervention. Peru: Springer, 2020: 516-525.
- [28] SOHN K, SHANG W, YU X, et al. Unsupervised domain adaptation for distance metric learning[C]//Proceedings of International Conference on Learning Representations. New Orleans: ICLR, 2018.
- [29] REDMON J, FARHADI A. Yolov3: An incremental improvement[EB/OL]. [2022]. arXiv: 1804.02767. <https://arxiv.org/abs/1804.02767>.
- [30] BOCHKOVSKIY A, WANG C, LIAO H. Yolov4: Optimal speed and accuracy of object detection[EB/OL]. [2022]. arXiv:2004.10934. <https://arxiv.org/abs/2004.10934>.
- [31] 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 and Machine Intelligence, 2017, 39(6): 1137-1149.
- [32] TIAN Z, SHEN C, CHEN H, et al. FCOS: Fully convolutional one-stage object detection[C]//Proceedings of IEEE/CVF International Conference on Computer Vision. Seoul: IEEE, 2019: 9626-9635.
- [33] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector[C]//Proceedings of European Conference on Computer Vision. The Netherlands: Springer, 2016: 21-37.
- [34] ZHU X, SU W, LU L, et al. Deformable transformers for end-to-end object detection[C]//Proceedings of International Conference on Learning Representations. New Or-

leans: ICLR, 2021.

- [35] LOSHCHILOV I, HUTTER F. SGDR: Stochastic gradient descent with warm restarts[EB/OL]. (2022-09-23)[2022-09-23]arXiv:1608.03983. <https://arxiv.org/abs/1608.03983>.
- [36] JOHNSON D, WILD A. Advances in radar tracking for small target detection[C]//Proceedings of International Radar Symposium. Berlin: IEEE, 2019.

#### 作者简介



司凌宇 男, 1994年5月出生于重庆市. 现为中国科学院软件研究所工程师, 中国科学院大学博士研究生. 现从事机器学习及智能信息处理等相关工作, 在相关领域发表SCI、EI论文十余篇.

E-mail: lingyu@iscas.ac.cn



强文文(通讯作者) 男, 1992年9月出生  
于安徽省芜湖市. 2022年毕业于中国科学院大学, 取得博士学位. 现为中国科学院软件研究所助理研究员, 主要研究方向为机器学习理论及其方法, 相关成果发表于IJCV、TKDE、ICML、NeurIPS、AAAI、IJCAI等CCF-A类期刊会议.

E-mail: qiangwenwen@iscas.ac.cn