

大场景 SAR 图像船舶目标快速检测方法 with 实例

主题方向：中国科创

专业领域/方向：电子信息

适用课程：《人工智能》、《卫星遥感进展》等

作者姓名：徐丰 王海鹏 王峰 王岩 胡凤鸣 贾赫成

工作单位：复旦大学信息科学与工程学院

中国专业学位案例中心

2024 年 2 月 20 日

大场景 SAR 图像船舶目标快速检测方法与实例*

徐丰 王海鹏 王峰 王岩 胡凤鸣 贾赫成

摘要：合成孔径雷达（SAR）具备全天候、全天时、大尺度的监测能力，已成为船舶检测的重要工具，在海洋监测中起到了不可忽视的作用。实际业务中的 SAR 图像往往以大场景的形式到来，如何在实际应用中平衡算法检测效率和虚警率是大尺度船舶目标检测的关键问题。本案例以面向 SAR 船舶目标的多尺度渐进式快速检测算法设计为例，通过分析 SAR 图像特点，介绍传统方法和深度学习各自优点，从而引入改进的算法，引导学生深入理解 SAR 图像成像机制和解决目标智能识别关键问题的思路，训练学生的创造性思维能力。

Abstract: Synthetic aperture radar (SAR) has emerged as a vital tool for ship detection due to its all-weather, round-the-clock monitoring capabilities, rendering indispensable services in marine monitoring. In practical operations, SAR images often present in large scenes, how to balance the detection efficiency of the algorithm and the false alarm rate is a key problem for large-scale ship target detection. This case takes the design of a multi-scale progressive rapid detection algorithm for SAR ship targets as an example, an improved algorithm is introduced by analyzing the characteristics of SAR images, and combining the advantages of traditional methods and deep learning methods, which guides students to deeply understand the SAR image imaging mechanism and solve the key problems of intelligent target recognition, and train students' creative thinking ability.

关键词：合成孔径雷达（SAR）；大场景 SAR 图像；多尺度检测；候选区域检索；船舶检测

Keywords: Synthetic aperture radar (SAR), ship detection, large-scene SAR images, multi-scale detection, candidate region retrieval

作者信息：徐丰，复旦大学信息科学与工程学院教授，副院长；王海鹏，复旦大学信息科学与工程学院教授；王峰，复旦大学信息科学与工程学院副教授；王岩，复旦大学信息科学与工程学院副研究员；胡凤鸣，复旦大学信息科学与工程学院助理研究员；贾赫成，复旦大学信息科学与工程学院博士研究生

^{*}(1)本案例系教育部学位与研究生教育发展中心 2022 年主题案例项目成果(项目名称：智慧天眼——卫星遥感图像智能解译技术及应用；项目编号：ZT-221024634；首席专家：徐丰)。

(2)本案例复制权、发表权、信息网络传播权等相关权益由教育部学位与研究生教育发展中心依法享有，如有相关需要，请取得教育部学位与研究生教育发展中心授权。

(3)本案例只供课堂讨论之用，并无意暗示或说明某种行为是否有效

1 引言

随着对地观测和卫星成像技术的发展，遥感图像呈现出大幅宽、高分辨率的特点，影像覆盖面更广，目标细节更加丰富。而目标检测技术将用户从海量影像数据中解放出来，是影像转为实际应用的重要内容。区别于光学传感器，SAR 拥有全天候、全天时的独特优势，在农业、军事、城市规划等领域中都发挥着重要的作用。近年来，聚焦于常见的飞机、船舶、车辆等遥感目标，涌现了大量基于 SAR 图像的目标检测研究成果。其中，SAR 船舶检测在渔业管理、港口规划、海洋监测中都起到了不可忽视的作用。

在渔业管理方面，SAR 能够对大范围渔区进行高分辨率成像，采用恒虚警率算法进行船舶识别，该方法被应用于中国东海渔区的非法捕鱼活动监测，并成功检测到海面上的非法渔船目标。对渔区进行渔船分布和活动情况的监测，能够帮助渔业管理部门优化渔业资源配置和执法行动，提升管理效率和执法效果。在港口规划方面，利用 SAR 对重要港口区域进行了精细成像，结合特征提取和目标检测算法，能够得到港口内外船舶分布情况，利用该方法对新加坡港口应用该方法进行监测，成功识别出港口内外的船舶、泊位和其他设施，分析了港口的使用效率和拥堵情况。采用多时相 SAR 数据进行分析，能进一步了解港口的使用效率和拥堵情况，为港口扩建和优化提供了科学依据，提升港口管理和规划的科学性和效率。在海洋监测应用方面，利用 SAR 图像对台风过境后海域进行目标识别，能够为灾后应急评估提供数据支撑。如采用深度学习模型（如 Faster R-CNN）对日本附近海域的台风后的 SAR 图像进行处理，识别海上船舶和漂浮物，提供了灾后评估和应急响应的关键数据，显著提高救援效率和决策水平。由于光学图像受云、光照的影响大，在上述应用场景均无法得到有效的数据用于目标识别，因此 SAR 图像海洋船舶监测中具有不可替代的作用。

实际应用中，船舶目标识别时通常与大场景关联，需要在大尺度图像中快速定位兴趣区域，并识别存在的船舶目标，如渔区非法渔船识别、大范围海域目标识别等，运算时间复杂度高。由于目标位置具有时变性，在获取数据后需要尽快得到识别结果，保证结果的时效性。利用高分辨率图像进行大尺度区域目标识别与时效性是相互矛盾的。因此当前的船舶目标检测存在两大难点：大范围检测的低效性和检测结果的高虚警率。如图 1 所示，分别体现在以下三个方面。

（1）大场景与船舶目标稀疏性。大场景 SAR 图像覆盖范围广，绝大多数船舶目标出现在水域中，这使得其分布呈现稀疏和不均衡特性。图 1 中（a）展示了一景 SAR 海洋区域影像中船舶的分布情况，其中，绿色为近岸船舶，聚集于少部分港口、码头、江河入海口等区域，黄色为远海船舶，分布更加稀疏。可以看出，船舶目标在图像中的低占比导致检测的有效区域较少，因此，如何快速

定位有效检测区域是提升检测效率的关键问题之一。

(2) 传统方法的高虚警问题。产品级单通道 SAR 图像只保留了幅值信息，相对于多通道的光学图像，可以利用的语义信息较少。另一方面，SAR 图像受散射噪声、几何畸变和相干斑的影响，加上沿岸、岛屿、港口、海杂波等复杂环境的干扰，使得传统非学习型方法容易产生大量虚警目标^[1]。图 1 中 (b) 展示了一些常见的虚警样例，包括人造设施、沿海、海杂波、小岛等。

(3) 深度学习方法的高虚警问题。相对于传统方法，深度学习方法通过学习已有样本，自动提取目标特征，虚警抑制方面更优。但对于大场景 SAR 图像中的船舶目标检测，依然存在高虚警问题，这些虚警主要来自于未学习区域。图 1 中 (c) 分析了深度学习方法的场景 SAR 图像中的高虚警问题。受限于显卡算力，对于大尺寸图像，主流的深度学习方法都将其转换为多个小尺寸场景切片进行训练。同时，考虑到正负样本的均衡性，模型训练仅使用包含目标的切片，如 (c) 中的绿色切片。另一方面，大场景图像中船舶目标的稀疏性，导致产生大量的无目标切片，如 (c) 中的红色切片，这些场景中包含大量负样本且未被训练。然而，在检测过程中，模型需要对图像所有区域进行推理，这些未学习的区域会产生大量虚警。

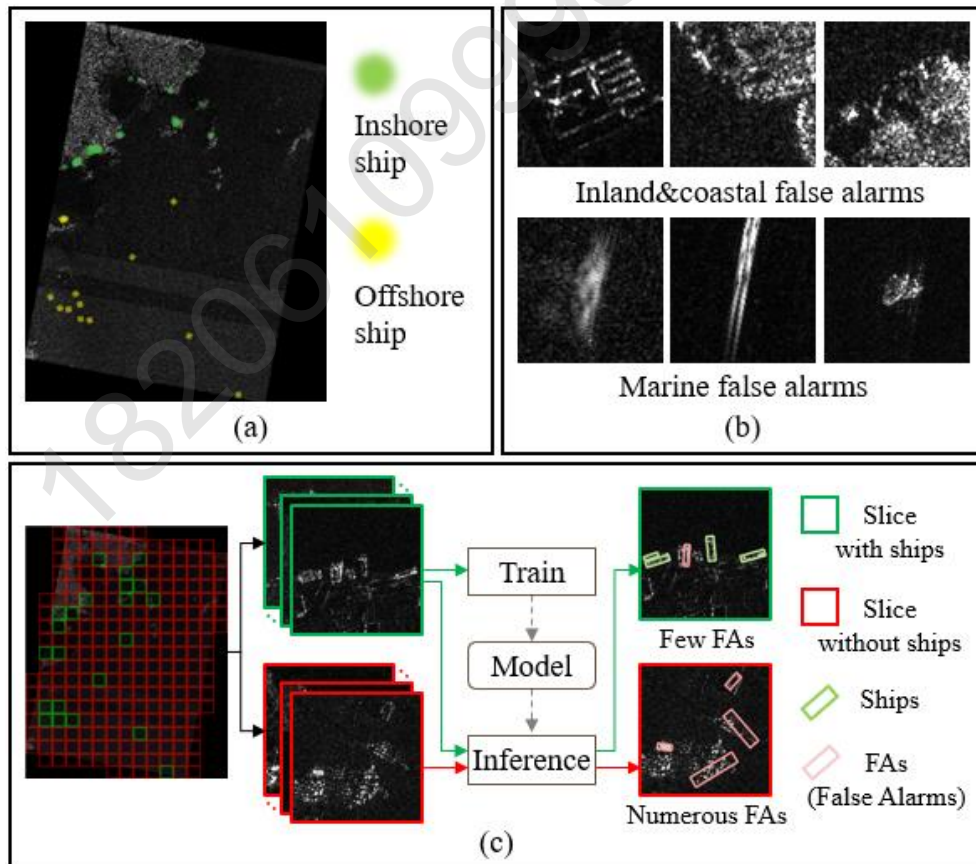


图 1 大场景 SAR 图像中船舶目标检测面临的挑战。(a) 船舶的稀疏分布，(b) SAR 船舶检测中常见的虚警，(c) 深度学习产生虚警的原因

1.1 SAR 图像介绍

SAR 是一种远程探测成像雷达，它利用移动平台（如飞机或卫星）上的侧视雷达以及相对地面大范围的雷达波束进行探测。由于其独特的成像机制，SAR 可以在任何天气和日夜条件下获得地表图像^[17]。SAR 技术的发展可以追溯到 20 世纪 50 年代，最初为军事侦察应用而开发。随着技术的进步，SAR 已经广泛应用于地震学、地质、农业、林业和城市规划等多个领域^[18]。根据其成像机制和应用，SAR 可以分为多种类型，如单极化、双极化、全极化和多频段 SAR 等。

SAR 利用雷达波的多次散射和干涉原理，通过复杂的信号处理来获取目标或地表的细节信息。图 1-2 展示了 SAR 的成像原理，它通过连续发送和接收雷达波，再对这些回波进行合成处理，从而实现高分辨率的成像^[19]。




图 1-2 SAR 成像原理

由于 SAR 独特的成像机制，与传统的光学遥感相比，其优势主要包括对天气和光照条件的不敏感性、以及能够获取目标的深层信息。另一方面，由于 SAR 利用了电磁波的散射，图像容易受散射噪声、几何畸变和相干斑的影响，这为图像中目标的检测和识别带来了一定的困难。

同样的，对比典型光学遥感目标，SAR 图像中的目标具有一些独特的特征。这些特征使得其在检测和识别上与光学图像中的目标有明显的差异。图 1-3 对比了典型的飞机、船舶、车辆目标，以这些目标为例，可以归纳以下几点^[20,21]：




图 1-3 光学遥感图像和 SAR 图像中典型目标对比

(1) 离散型性：与光学图像中连续且清晰的目标外观不同，SAR 图像中的目标往往呈现为离散的点状或不连续的形态。例如，飞机在 SAR 图像中可能只由其金属部分的亮点和由机翼产生的阴影组成，如图 1-3 中左上第一个 SAR 飞机目标所示。

(2) 方位敏感：SAR 图像的目标特别敏感于方位角。即使是相同型号的飞机，由于其不同的方位角，其在 SAR 图像中的形态也可能有很大的差异。这对于识别算法提出了额外的挑战，因为它们需要能够处理同一类型目标的多种外观变化。

(3) 复杂背景：SAR 图像中的目标经常与复杂的背景信息混合在一起。如图 1-3 左侧中间的 SAR 船舶目标所示，其可能与码头、其他船舶或水面波纹紧密相连，使得单独区分它们变得非常困难。

(4) 大场景：由于 SAR 卫星影像的覆盖范围较大，目标检测时容易产生大量的误检，特别是在多目标、复杂背景的大范围场景中。例如，在一个广阔的海域中，船舶、浮冰和波浪可能都在同一幅图像中出现，而且很可能会被误识别为其他目标。

(5) 小样本特点：与光学遥感图像相比，SAR 图像的目标样本往往更为有限。这是因为 SAR 遥感的应用相对较新，而且获取高质量的 SAR 图像样本需要特定的条件和设备。因此，针对 SAR 图像的目标检测和识别算法需要特别考虑小样本学习的问题。

综上所述，SAR 图像及其包含的目标信息，为构建全天候条件下的智能目标检测与识别算法提供了可能。但其成像机制和目标特性也为目标检测和识别算法

带来了一系列挑战,传统的光学图像处理方法不能直接应用于 SAR 图像处理中,需要研究专门的目标检测识别算法。

目前主流的 SAR 船舶目标检测方法主要分为基于先验分布和人工特征的传统方法以及基于深度学习的方法,两类方法拥有各自的特点。传统方法以 CFAR 及其变种为主要代表^[2],CFAR 通过对海杂波区域统计建模和虚警率阈值来实现船舶目标的检测。另外也有基于视觉注意力机制,通过显著性检测方法检测出预处理之后显著图中的船舶目标^[3]。传统方法相对简单、速度较快,结合一些先验知识,可以在简单场景下实现高效检测。但传统方法容易产生大量的虚警,且对于新场景的泛化能力有限。加入更复杂的模块,例如多尺度的检测^[4,5],可以有效的提高检测精度,但意味着更复杂的人工调参和检测速度的牺牲。基于深度学习的方法已经普遍用于光学遥感图像的目标检测识别任务中,自动图像特征提取及端到端检测的特性使得其在 SAR 图像目标检测中也逐步得到应用^[6]。基于深度学习的方法已数据作为驱动,使用大量的标注数据训练模型,检测精度更高,模型在新场景的泛化能力更强。但受限于硬件算力,送入深度学习网络的图像大小往往受到限制,一般采用适合网络输入的滑动窗口进行滑窗检测,而过多的滑窗导致了检测速度过慢的问题。

对于大场景 SAR 图像的船舶目标检测任务,速度和准确度已成为用户最关心的两个实用指标。针对上述难点及现有方法的不足,本案例提出一种多尺度渐进式快速 SAR 船舶检测方法,已实现检测过程中算法复杂度和效率的平衡。该方法利用传统方法和深度学习方法各自的优点,分别设计了船舶候选区域检索和船舶高精度检测两大主要模块。首先,针对大场景检测效率低的问题,在全局尺度设计基于传统方法设计海陆分割和恒虚警率预处理操作,排除大多数陆地和海杂波区域,快速提取船舶候选区域。同时针对性的设计了预处理评估指标,综合评估候选区域检索模块的背景滤除效果和前景提取可靠性。然后,为了实现高精度检测并有效抑制虚警,在场景滑窗尺度和目标尺度,基于深度学习方法,分别设计船舶有向检测器和虚警鉴别网络,精准检测候选区域中的船舶目标。目前算法回顾

1.2 传统 SAR 船舶目标检测方法

SAR 目标自动识别 (Automatic Target Recognition, ATR) 作为 SAR 图像自动解译的关键技术,用于解决人工判图成本高、效率低的问题。20 世纪 80 年代,林肯实验室便率先提出了 SAR ATR 的三级处理流程^[7-9],如图 4 所示,全流程可分为目标检测、目标鉴别和目标分类。三步流程是 SAR ATR 算法的经典设计,每一步的数据量都在递减,运算复杂度也在递增,而后来的 SAR ATR 算法大都借鉴了这一思路,包括船舶目标检测与识别。而对于 SAR 船舶检测而言,主要包括检测和鉴别两步。

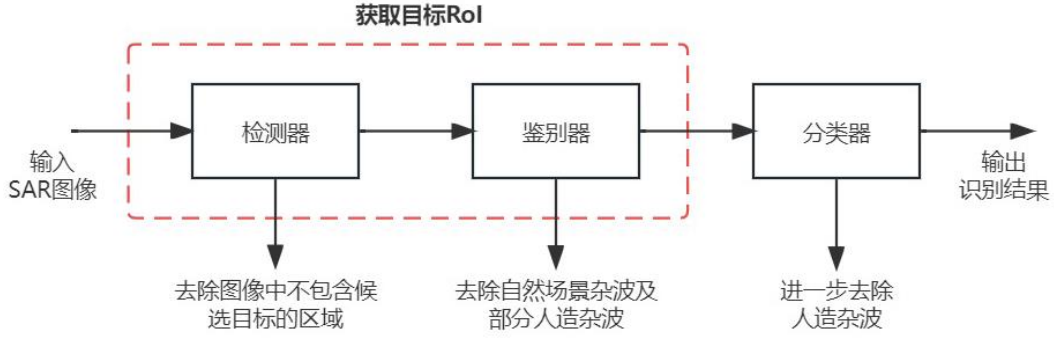


图 4 林肯实验室提出的 SAR ATR 三级处理流程

SAR ATR 的第一步是利用检测算法，将候选目标检测出来，最常见的传统目标检测算法是以杂波统计与阈值提取为基础的恒虚警率算法（Constant False Alarm Rate, CFAR）^[10,11]。上世纪 90 年代，林肯实验室的学者们推出了用于二维雷达图像的双参数 CFAR^[2]，即假设杂波服从高斯分布，对杂波像素统计建模得到自适应阈值，通过比较判断得到目标点。但由于杂波环境复杂性、计算量大等多种因素，双参数 CFAR 效果局限性较大且效率较低。针对这些不足之处，多种改进算法被提出，涉及到杂波建模^[12]、检测器^[13]、算法效率^[14]等多个方面。对于 SAR 船舶目标检测，基于 CFAR 的方法同样被广泛应用，例如，Leng 等人^[15]提出双边 CFAR，通过新的核密度估计获取空间信息，再将空间分布与强度分布进行组合实现对船舶检测。Dai 等人^[16]提出以提取的候选区域作为保护窗口取代固定滑窗，解决 CFAR 在多尺度情况下船舶的漏检问题。Ao^[4]和 Hou^[5]等人提出多尺度 CFAR，在保证检测效率的同时，提高多尺度船舶的检测精度。Cui^[17]等人利用神经网络代替 CFAR 检测器中的杂波建模来预测目标分割阈值，提高了复杂场景下 CFAR 检测器的性能。

由于 SAR 目标检测存在高虚警问题，检测完成之后需要通过鉴别器进一步排除虚警目标，对于 SAR 船舶检测来说，背景杂波主要为海杂波和沿岸杂波。传统鉴别器通常基于目标纹理将背景杂波从候选目标中剔除，也可以根据目标的独特特征来设计，例如典型的支持向量机和分类器^[18]。针对 SAR 船舶目标，Liu 等人^[19]通过利用船舶尺寸信息和上下文，并结合二进制线性规划问题来准确地定位船只并消除虚警。Ao 等人^[4]使用了特征椭圆和最大似然鉴别来进一步排除近岸和港口区域的非船舶目标。Wang 等人^[20]通过聚合费舍尔向量的密度，提高了在强烈和高度异质的海杂波环境中的虚警鉴别准确性。另外，也有一些方法^[5,21]也通过神经网络来区分船舶和虚警目标。

总的来说，结构简单的传统 SAR 船舶检测方法具有速度快、无需样本学习的优点，但面对复杂场景检测性能较差。加入复杂的结构设计，例如复杂统计模型、多尺度结构等，又会使检测效率大大下降。因此，本文利用简单结构的 CFAR

检测器,快速收缩船舶候选区域,同时调低检测阈值,最大程度降低船舶的漏检。此外,本文同样参照了经典 SAR ATR 的检测流程,设计了针对 SAR 海洋场景的虚警鉴别器,进一步降低检测虚警率。

1.3 基于深度学习的 SAR 船舶目标检测

随着深度学习在传统图像处理领域的成功, SAR 船舶检测领域也逐步从传统方法转向深度学习技术。基于深度学习的 SAR 船舶目标检测方法能够自动学习和提取复杂特征,通过多层神经网络的非线性变换,深度学习方法可以捕捉到传统方法难以识别的细微特征,提高了检测的精度和鲁棒性;深度学习方法可以通过训练大量数据,适应不同的场景和目标类型,提高检测的鲁棒性,通过大规模数据训练,深度学习模型能够自动调整参数,适应不同的环境变化,如不同的海况、天气条件和目标形态;深度学习模型可以同时完成目标检测、分类和分割等多任务,提高检测的全面性和准确性,多任务学习使得深度学习模型不仅可以识别船舶目标,还可以同时提供目标的位置、种类和边界信息,大大增强了检测系统的功能性。这些优点使得基于深度学习的 SAR 船舶目标检测方法在处理复杂场景、提高检测精度和适应性方面具有显著优势,是传统方法的重要补充和提升。早期应用于 SAR 船舶检测的深度学习方法大多直接采用光学图像中的算法,其中,考虑到船舶目标大长宽比及遥感目标俯视任意朝向的特点,有向检测器获得越来越多的关注。此外,为了更好地适应 SAR 船舶目标的特点,一些研究也对深度学习网络进行了专门的改进和优化。

(1) 有向目标检测器

在遥感目标检测任务的初级阶段,水平边界框(Horizontal Bounding Boxes, HBB)是用以描述目标边界的主要方法。然而,考虑到遥感图像中目标的位置通常是任意的,许多遥感目标检测任务开始采用有向边界框(Oriented Bounding Boxes, OBB)来进行标注。OBB 采用一个旋转矩形表示目标的最小区域,更准确地描述了目标的位置,并且具有朝向语义,特别适合于船舶等大长宽比的遥感目标。近年来,已有许多基于 OBB 的优秀检测器被提出。初期的双阶段有向检测器以 RoI Transformer (RoI-Trans)^[22]为代表,后续的一些方法多基于 RoI-Trans 进行改进。RoI-Trans 在 RPN 阶段提出了旋转 RoI (Rotated RoI, RRoI) 学习器来定位有向感兴趣区域,并通过坐标变换提高第二阶段有向边框回归的稳定性。Oriented R-CNN^[23]在此基础上进一步简化了 RRoI 的学习网络深度,提高效率的同时避免训练的过拟合。而 ReDet^[24]则在特征提取阶段引入群卷积实现旋转不变性特征提取,进一步优化了 RoI-Trans 的性能。单阶段有向检测器则多以 Retinanet^[25]作为基础结构。Yang 等人^[26]于 2021 年提出 R3Det,在 Retinanet 之后级联检测器,并使用特征精炼模块对齐中间特征,获得了更好的有向回归和分类性能。之后,SCRDet++^[27]在此基础上加入目标级注意力模块,进一步提升了检

测器的性能。另外一些方法^[28,29]通过改变 OBB 表示法来优化有向目标的定位准确度。此外, Li 等人^[30]在 Reppoints 的基础上改进了三种定向转换函数, 实现了一种遥感有向目标的无锚框检测方法。

(2) SAR 船舶目标检测

结合实际应用需求, 目前也涌现出许多针对 SAR 船舶目标改进的深度学习检测器。Li 等人^[31]将 Faster R-CNN 引入 SAR 船舶检测, 并通过特征融合、迁移学习等策略来改进检测器的性能, 同时提出了名为 SSDD 的 SAR 船舶检测数据集。Cui 等人^[32]提出 shuffle-group enhance 注意模块来提取更强的船舶语义特征并抑制噪声, 从而有效地减少近岸和内陆干扰引起的虚警。Sun^[33]等人通过检测船上的强散射点并利用注意模块来抑制陆地干扰, 从而提高近岸 SAR 船舶的检测效果。Ke 等人^[34]提出了一种改进的 Faster R-CNN 算法, 该算法使用可变形卷积核替代传统卷积核进行 SAR 舰船检测, 以更好地模拟船舶的几何变换。He 等人^[35]提出自适应特征编码和高斯导引采样结合的无锚舰船检测, 有效提高数据集中小型船舶的检测性能。

以上研究根据 SAR 船舶特点进行了针对性的改进, 比直接应用光学遥感图像算法取得了更好的效果。但在大场景 SAR 图像中船舶检测的研究相对较少, 如何提高深度学习方法在大范围 SAR 图像中的检测效率并有效抑制虚警, 依然是一个具有挑战性的问题。鉴于深度学习方法优良的检测性能, 本文的船舶高精度检测模块基于深度学习技术实现, 并通过特征融合策略进一步提高 SAR 船舶目标的检测效果。

2 改进算法

2.1 多尺度高效检测框架

本案例所提方法整体框架如图 5 所示, 包含三个主要步骤, 分别对应所提出的 CRM、OSD 和 FDM。同时, 三个子模块分别在三个尺度渐进式的处理, 由粗到细, 逐步缩小处理范围, 提高检测精度。

第一步, 通过 CRM 在全局尺度进行快速候选区域检索, 包括海陆分割和 CFAR 预处理操作。首先做海陆分割处理, 得到陆地掩膜, 去除大部分陆地区域。然后在剩余海面区域做 CFAR 处理, 得到不包含船舶目标的海面区域掩膜, 去除大部分海杂波区域。预处理操作需要快速定位出船舶候选区域, 不需要精确的检测结果, 且对计算资源依赖少, 因此在全局尺度做处理, 并通过图像下采样操作提高处理速度。该步骤最终输出船舶候选区域掩模图。

第二步, 在场景切片尺度使用 OSD 进行精细化检测。受限于深度学习方法

依赖的显卡资源限制，单次输入网络图像大小有限，因此采用滑窗方法，在每个滑窗场景内做船舶检测。滑窗基于原图进行，并通过和候选区域掩模图进行匹配，来确定当前滑窗是否送入检测器进行检测。最后，合并每个滑窗的结果，并对合并结果的进行非极大值抑制，得到初步检测结果。

第三步，在目标尺度做虚警抑制操作。对于初步检测结果，将达到置信度阈值的结果做目标区域切片，输入深度学习分类器进行船舶和虚警类别的分类。分类器处理完成后，结果被还原回场景图，并滤除非船舶类别的结果，达到滤除虚警的目的。

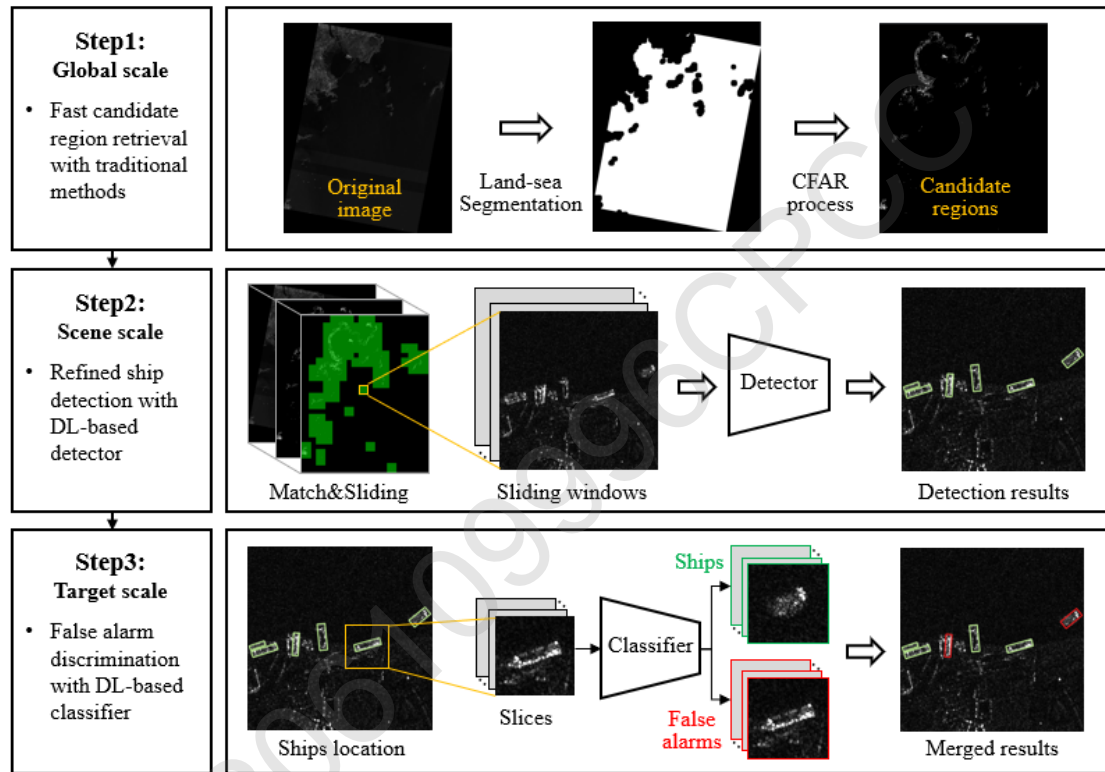


图 5 整体检测方案流程

另外，所提算法的推理过程采用了分块读取技术和滑窗策略，以加速算法执行效率。如图 6 所示，对于整景图像中目标的检测，所提算法每个模块由粗到细，涵盖不同尺度的处理区域，包含全局尺度、场景切片尺度、目标切片尺度。分块读取同时被用于场景切片尺度和目标切片尺度的局部图像读取，如图 6 中的步骤 2 和 3 所示，分块处理功能通过调用和二次封装 GDAL 栅格影像读取接口实现。所提算法在图像预处理之后将得到的候选区域掩膜二值图保存至硬盘，后续检测网络通过该二值图确定需要检测的区域。由于需要检测的区域占比较小，为了提高局部读取效率并降低外存读取开销，分块读取技术通过场景切片在大图的相对位置，将影像的局部内容从外存读入内存，再对该区域做量化拉伸后送入检测网络检测结果。另外，虚景鉴别处理采用的目标切片以同样的方式从外存获取局部

影像至内存，对切片单独拉伸后送入虚景鉴别网络预测类别。此外，分块处理技术也被用于最终结果的切片生成，结合多进程设计模式，实现并行目标切片保存。




图 6 多尺度分块读取和滑窗策略

所提框架中的滑窗包括分块滑窗和检测滑窗两种，分别使用 W_{block} 和 W_{det} 表示。其中，分块滑窗用于上述分块读取操作，检测滑窗用于 OSD，每次一个分块切片被读入内存，并做量化处理，之后再基于检测网络滑窗进行检测。为了最高效的利用滑动窗口， W_{block} 和 W_{det} 满足如下关系：

$$W_{block} = W_{det} + (\sqrt{BS} - 1)(W_{det} - OL) \quad (2-1)$$

其中，BS为 OSD 每次推理的并行样本数 (batch size, BS)， W_{det} 固定为 1024*1024 像素大小，OL表示检测滑窗重合区域，这里固定为 400 像素大小。为了充分利用显卡资源，BS 可以改变，所有 W_{det} 一次性送入显卡并行推理。当BS=1 时， W_{block} 尺寸等于 W_{det} ，即为非并行单次推理的情况。理论上，单次并行推理的切片图像越多，整体推理速度更快，显卡资源利用越充分。但实际过程中，由于 W_{block} 同时变大，加大了检测范围，变相增加了推理时间和虚警率。另外，并行推理的速率还和显卡性能有关。

2.2 船舶候选区域检索

2.2.1 基于海陆分割的陆地区域滤除

传统的海陆分割方法一般分为基于地理信息的匹配方法和图像处理的方法两种。图像处理速度较慢，特别是针对整景遥感图像的范围。由于本文待检测图像为已做地理编码的 SAR 二级影像，所提方法采用较快的基于地理信息模板匹配方法进行海陆分割操作。采用的匹配库为 250 米分辨率全球海陆掩膜库^[36]，该掩膜库由 GeoTIFF 格式的栅格切片组成，切片为 0-1 二值图，0 代表水域，

1 代表陆地。

基于地理信息的海陆分割整体流程如图 7 所示，首先提取原始图像的地理信息，并根据地理信息查找海陆掩膜数据库中的对应区域。然后将掩模和原图进行匹配并分割，得到初始结果。之后，对结果进行形态学处理，对海陆分割线分别进行一次腐蚀和膨胀操作，形成内陆区域、海陆隔离带、海洋区域。其中，内陆区域和海陆隔离带组合形成最终海陆分割结果，而海洋区域用于下一步的海杂波滤除操作。

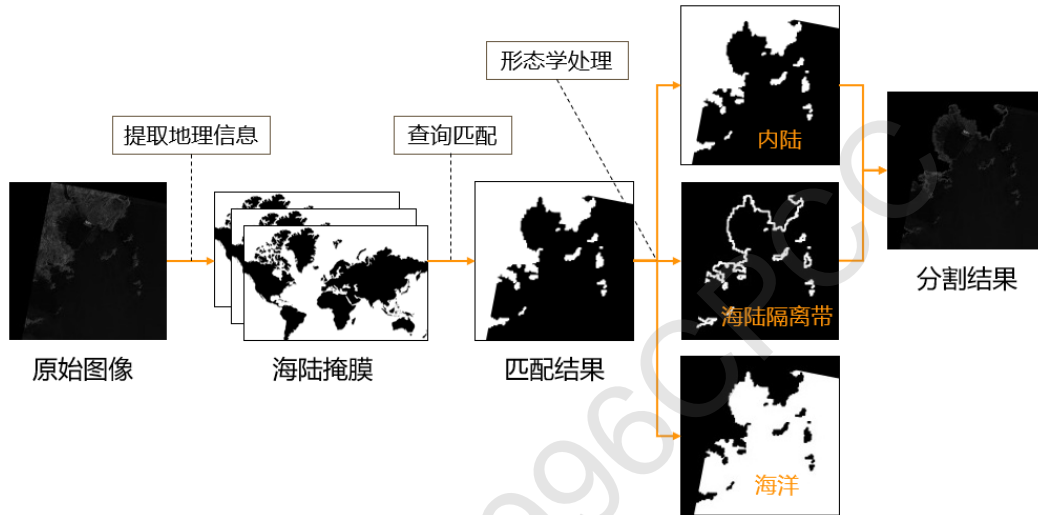


图 7 基于海陆掩膜库的海陆分割流程

2.2.2 基于恒虚警率的海杂波滤除

本文所检测 SAR 图像为单通道二级图像，每个像素代表了处理之后的幅值信息，即目标返回的能量强度。经典的 CFAR 检测器通过统计学原理对图像中的像素值进行函数拟合和建模，通过建模后的统计分析来区分目标像素和背景像素。对于海洋中的船舶检测场景来说，根据像素强度分布的特点大致可以分为三类目标：含有大量金属二面角和三面角结构的人造目标、陆地区域、海面区域。船舶目标属于像素强度最高的人造目标之一，另外，此类人造目标还大量存在于陆地区域，例如建筑、车辆等。上一节所提的海陆分割方法已经将陆地区域排除，剩余的海洋区域只包含海面、船舶、其他海面人造目标，海面区域也称之为海杂波区域，在 SAR 幅值图像上的能量一般较小，本节设计了基于 CFAR 的海杂波滤除方法，整理流程如图 8 所示，主要包含海岸线扩张、海杂波建模、分割阈值优化、海岸线后处理等操作。

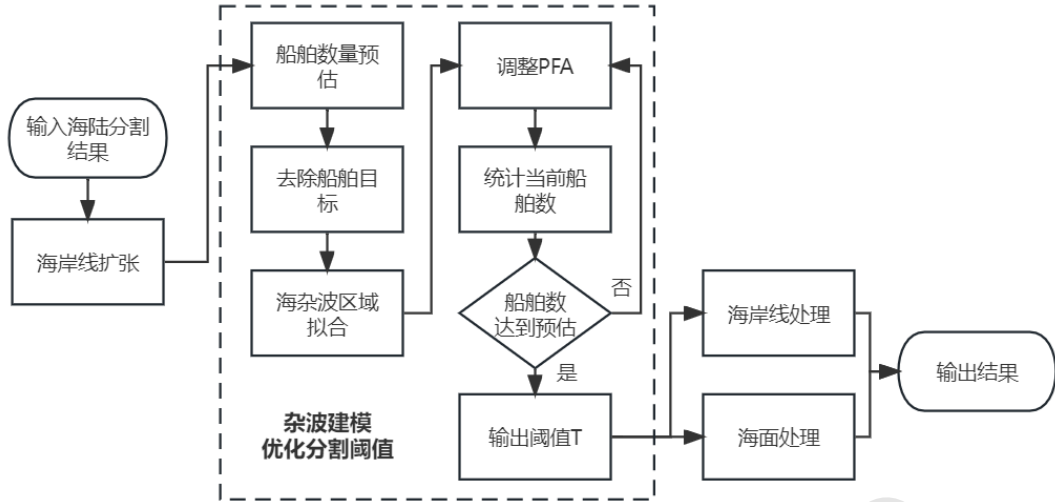


图 8 海杂波滤除流程

(1) 扩张海岸线




图 9 海岸线扩张处理。(a) 处理前，(b) 处理后

由于海陆分割采用了模版匹配的方法，受影响地理编码偏差的影响，提取的海面区域依然包含部分沿海陆地区域，这些区域的像素强度最高，对水域杂波建模带来不确定性。因此，为了更好的对海杂波区域进行建模，本方法首先对海陆分割的海岸线做了形态学腐蚀处理，这个操作在去除海陆隔离带之后再做一次，以完全去除陆地区域对统计建模的干扰，效果如图 9 所示。

(2) 海杂波建模

对海杂波像素区域做拟合时，还需要排除船舶等人造目标的干扰，由于这些目标相对占比较少，这里采用 15 倍像素均值作为阈值快速排除船舶区域像素。海杂波统计建模部分，由于广义伽马分布 (Generalized Gamma Distribution, GGD) 在 SAR 海杂波拟合方面的优良性能^[4,5,17]，本研究也采用其作为拟合方法，基于 GGD 的概率密度函数 (Probability Density Function, PDF) 定义如下：

$$f(x; \alpha, \beta, \mu) = \frac{\beta^\alpha x^{\alpha\mu-1} e^{-\beta x^\mu}}{\Gamma(\alpha)}, x \geq 0 \quad (2-2)$$

其中 $f(x; \alpha, \beta, \mu)$ 为海杂波的 PDF, $\Gamma(\alpha)$ 是伽马函数, α, β, μ 分别表示形状、尺度和能量参数。




图 10 海杂波区域和船舶区域的概率密度拟合

方法中使用 GGD 对海杂波区域和船舶区域分别进行拟合, 由于海杂波区域能量低且面积大, 船舶像素强度高但数量少, 可以得到的类似图 10 中的概率密度曲线, 蓝色和红色分别为海杂波和船舶区域的 PDF 曲线。因此, 可以通过设置合适的强度阈值 T 区分海杂波和船舶目标所属的像素。

实际应用过程中, 为了得到最佳分割阈值 T , 根据拟合的概率密度曲线以及累积密度函数(Cumulative Density Function, CDF), 计算出虚警率 P_{FA} (Probability of False Alarm, PFA), 定义如下:

$$C(x; \alpha, \beta, \mu) = \int_0^x f(t; \alpha, \beta, \mu) dt, x > 0 \quad (2-3)$$

$$P_{FA} = 1 - C(T; \alpha, \beta, \mu) \quad (2-4)$$

其中 $C(x; \alpha, \beta, \mu)$ 为 CDF, 对于图 10 中的海杂波曲线, P_{FA} 代表曲线在阈值 T 右侧的面积, 即海杂波被误识别为船舶的概率。而大于阈值 T 的像素即为船舶目标区域。因此, 通过调整 P_{FA} 的大小就能确定最佳阈值 T 。

(3) 优化分割阈值

对于最佳阈值 T 的确定, 本研究采用迭代优化方法[4]。迭代过程如图 8 所示,

对于每轮迭代，对当前得到的 P_{FA} ，计算掩膜保留的船舶数量，与预估船舶的数量进行比较，根据差值每次增加或者减少 P_{FA} 值，直到差值在一定范围之内。这里真实船舶数量为初始图像均值得到的船舶数量估计。迭代结束之后，根据当前 P_{FA} 计算出最佳阈值 T

（4）优化海陆隔离带

在得到分割阈值之后，本方法也对海陆分割得到的海陆隔离带进行阈值后处理，进一步滤除其中沿海陆地像素。最终得到整个船舶候选区域的二值掩膜图。图 11 展示了处理前后效果，从图中可以看出，沿岸陆地被进一步滤除，同时，处于海陆隔离带的近岸船舶目标被完整保留，如图中红圈所示。

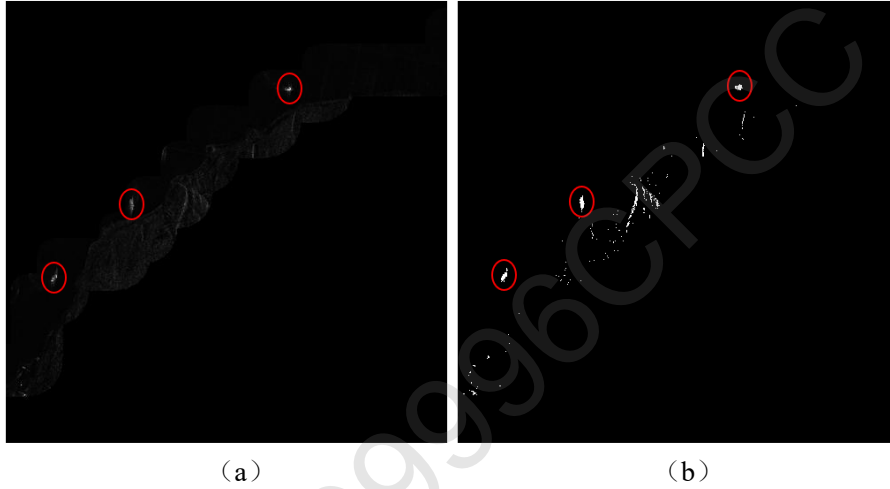


图 11 海陆隔离带后处理。(a) 处理前，(b) 处理后

2.2.1 预处理评价指标设计

本文引入的图像预处理方法主要作用在于减少无效检测区域以加快检测速度，同时需要确保预处理之后船舶目标的高覆盖率，将预处理部分的漏检降到最低。为了有效评估预处理模块的性能，本文设计了两个专用评估指标：真值命中率和检测范围，分别用 r_{hit} 和 r_{scop} 表示。

（1）真值命中率

真值命中率用于评估预处理操作之后，候选区域涵盖的船舶目标数量的比例，使用 r_{hit} 表示，定义如下：

$$r_{hit} = n_{hit}/n_{total} \quad (2-5)$$

其中 r_{hit} 代表真值命中率， n_{hit} 为候选区域命中的船舶数量， n_{total} 为真值船舶总数量。 r_{hit} 越高，代表候选区域检索操作漏检越少。




图 12 候选区域命中船舶的计算方式。(a) 有向框真值, (b) 最小邻接矩形框真值

单个船舶目标是否被候选区域命中由其矩形边界框 (Horizontal Bounding Boxes, HBB) 真值中是否包含候选区域像素确定。预处理之后的得到的候选区域为 0-1 二值掩膜图, 1 代表该像素为潜在船舶目标, 0 代表背景。图 12 所示, (a) 为真值目标及其 OBB 标注, (b) 为 OBB 最小邻接 HBB, 灰色像素为预处理之后目标被滤除的区域, 红色为保留的区域, 即候选区域像素。HBB 中目标候选区域像素数量大于 0 则代表命中目标。因此, n_{hit} 的计算方式如下:

$$n_{hit} = \sum_{i=1}^{n_{total}} \max(H_i) \quad (2-6)$$

其中 H_i 代表目标 HBB 在预处理掩膜图中的像素矩阵, 当最大像素值等于 1 时说明包含可能为船舶的像素。

此外, 船舶是否会在后续检测网络检测范围内是由检测网络的执行策略决定的, 后续检测网络采用滑动窗口策略对原始整景大图进行检测, 如果当前滑窗在掩膜图相对区域内存在值为 1 的像素, 则认为可能存在船舶目标, 即有效区域, 会被送入检测网络推理预测。由于滑窗为矩形, 只要确保目标的 HBB 范围内存在掩膜候选区域像素, 就可以保证船舶目标至少被其中一个滑窗完整覆盖, 并输入后续检测网络。对于边界情况, 如图 13 所示, 红色代表预处理之后某目标保留的像素, 这里极端情况下只有船头两个点被保留, 且被前一个滑窗边缘覆盖。这种情况下, 由于所提方法设计了相邻滑窗重合区域, 下一个相邻滑窗可以确保检测到完整目标。这种滑窗策略确保了 n_{hit} 计算的有效性。




图 13 目标保留像素的边界情况和滑窗策略

滑窗重合区域的大小由目标尺寸确定，本节统计了 30 景高分 3 影像中船舶目标 HBB 尺寸，如图 14 所示，其中 x 轴为目标 HBB 宽度，y 轴为目标 HBB 高度，以像素为测量单位。根据统计的尺寸信息，设置滑动窗口大小为 1024*1024 像素，重合区域为 400 像素，可以确保检测网络的滑窗覆盖所有船舶目标。




图 14 船舶目标矩形标注框尺寸统计

(2) 检测范围

检测范围用于评估图像预处理之后，整景图像中送入后续检测网络的有效检测范围占比，该指标越低，后续检测速度越快。检测范围和真值命中率一样，基于预处理后的船舶候选区域掩膜图计算，由后续检测网络的滑窗策略决定。如图 15 所示，计算时根据设计的滑窗尺寸和重合区域，模拟一遍逻辑滑窗流程，当前滑窗对应的掩膜区域包含船舶像素则为有效滑动窗口，对应图中绿色部分，所有有效滑窗并集占原图面积的比例即为检测范围，定义如下：

$$r_{\text{area}} = (\bigcup_{i=1}^{n_w} a_i) / a_{\text{total}} \quad (2-7)$$

其中 r_{area} 表示检测范围， n_w 为所有命中滑窗总数， a_i 为当前滑窗的面积， a_{total} 为整景图像面积。




图 15 整景图像检测范围计算。(a) 预处理后的船舶候选区域二值图，(b) 包含候选区域的滑窗

2.3 船舶有向检测器

本文提出的船舶有向检测器采用深度学习网络进行设计，用于船舶目标的精细化检测，包含有向表示法设计、网络结构、数据增强这三个方面，下文依次展开叙述。

2.3.1 有向表示法

目前主流的检测器目标定位方式主要分为正框和有向框两大类，其中，有向检测算法对于船舶类长宽比较大的目标具有独特优势，体现在减少相邻目标检测框重合、目标区域特征高效提取、更丰富的语义信息等方面。

如图 14 所示，体现在以下几点：

1) 对于靠岸和近岸船舶密集排列的场景，如图 16 (a) 所示，相邻目标的正框存在高交并比问题，目前主流检测器普遍采用 NMS 进行后处理，会造成相邻目标漏检，而基于有向框的表示不存在这个问题。

2) 遥感图像中俯视目标任意朝向的特点，导致正框区域特征提取往往包含很多目标不相关的背景，导致检测精度下降，而紧贴目标的有向边框很少包含目

标不相关的背景区域。

3) 旋转目标边框可以包含更多的语义信息，例如目标的朝向、长度、宽度等，如图 16 (b) 所示，而正框表示法无法对这些信息进行表征。




图 16 SAR 船舶目标正框与斜框标注。(a) 密集排列场景下的正框标注，(b) 斜框标注

由于 SAR 近岸和靠岸场景中包含了大量船舶密集排列的场景，正框和斜框算法首先进行了比较，实验采用经典的 RetinaNet^[25]网络结构，分别测试了原始正框检测网络和加入角度参数的 RetinaNet-R。图 17 展示了图像中一些典型的密集船舶区域检测结果，展示区域中斜框算法漏检 3 个，正框算法漏检 7 个，可以看出其中单个船只正框和斜框检测性能接近，而在密集排列的区域，正框算法存在大量的漏检。因此，本节所提场景尺度下精细化的 SAR 船舶检测采用了有向目标检测框架。




图 17 正框与斜框算法结果对比。(a) 斜框算法结果，(b) 正框算法结果




图 18 有向边框表示法。(a) 为 OpenCV 表示法，(b) 为长边表示法，(c) 为边中心点偏移标识法

目标的有向边框表示方法对算法的性能影响较大，目前大多数检测器采用 OpenCV 表示法或者长边表示法，如图 18 中的 (a) 和 (b) 所示。这两种表示法都采用 5 个参数定义有向边框 $\{x, y, w, h, \theta\}$ ，分别代表中心点 x 坐标、中心点 y 坐标、宽度、长度和角度，区别在于角度的表示范围不同。OpenCV 表示法 θ 范围为 $(-90, 0]$ ，以靠近 x 轴的边为 w ；长边表示法 θ 范围为 $(-90, 90]$ ，以长边为 w 。角度是一个周期性参数，临界值会导致训练时角度损失不稳定，称之为角度周期性问题，这两种表示法都存在这个问题。另外，由于 OpenCV 表示法将靠近 x 轴的边作为宽，还存在边的交换性问题，会额外增加训练时边框损失的不稳定。为了解决角度周期性问题，Oriented R-CNN (Ori-RCNN) ^[23] 采用了中心点偏移表示法 (Midpoint Offset Representation, Mid-OR)，如图 18 (c) 所示，Mid-OR 采用 6 参数表示有向边界框 $\{x, y, w, h, \Delta\alpha, \Delta\beta\}$ ，其中 $\Delta\alpha, \Delta\beta$ 分别为预测框的边的中心点的偏移量，该表示法去除了角度参数，解决了角度的周期性问题，但会存在边框回归不够精确的问题，适合用于初步的 RRoI。

根据以上各种有向表示法的优缺点，所提方法采用双阶段网络结构，结合 Mid-OR 表示法和长边表示法进行有向边框表示。具体来说，Mid-OR 被应用于第一阶段的有向 RPN (Oriented Region Proposal Network, Oriented RPN) ^[23]，克服角度周期性问题；第二阶段的边框回归子网络仍采用长边表示法，以更精准的定位边界框。其中，第二阶段参考 RoI-trans^[22] 的做法，将框定义的参考坐标系投影到 RRoI 上，如图 19 (a) 所示。由于前一阶段 Oriented RPN 模块已经预测出大致的目标角度，投影操作使得头部网络需要微调的边框大多数不会在临界值附近，如图 19 (b) 所示，因此也不会存在角度周期性问题。




图 19 头部网络的边框回归过程，蓝色为待回归边框，绿色为真值。(a) RRoI 坐标系投影，(b) 第一阶段输出框结果分布

2.3.2 网络结构设计

根据设计的有向表示法，所提方法选择简单高效的双阶段 Ori-RCNN 网络作为基础进行改进。第一阶段保留 Oriented RPN 网络输出 RRoI，第二阶段采用 RoI-trans 网络的分类和回归子网络结构，精修有向框，同时对 RRoI 进行分类。另外，CNN 算子受到局部感受野的限制，不能较好的建立图像中不同区域之间的长距离依赖关系，对于较大的复杂场景 SAR 图像，需要多层堆叠以获得全局信息，而随着层数的增加，小目标和聚集目标的特征区分性会逐渐衰减。Transformer^[37]模型存在自注意力机制，通过使用多头注意力，可以将全局信息映射到多个不同的空间。为了更好的捕捉场景切片内的全局信息，所提方法的主干网络使用 Swin Transformer^[38]做多尺度特征提取。

改进后的网络整体结构如图 20 所示。主干网络部分为 Swin Transformer 的 4 阶段特征提取，每阶段对特征图下采样 2 倍生成多尺度特征，然后采用 FPN 特征金字塔结构对特征进行多尺度融合并送入进一步的双阶段处理。借鉴 Ori-RCNN 的做法，第一阶段采用 Oriented RPN 预测出 RRoI，第二阶段剪裁出 RRoI 区域并做有向特征对齐，对齐的有向特征经过两层全卷积层由头部的分类和回归网络分别得到类别和边框位置。网络的损失函数如下：

$$L_{\text{total}} = \lambda_1 \cdot L_{\text{cls}_r} + \lambda_2 \cdot L_{\text{reg}_r} + \lambda_3 \cdot L_{\text{cls}} + \lambda_4 \cdot L_{\text{reg}} \quad (2-8)$$

其中 L_{total} 表示多任务联合损失， L_{reg_r} 和 L_{reg} 分别表示一阶段和二阶段的回归损失，回归目标分别为中心点偏移表示法和长边表示法的参数偏移量，均采用 smooth_{L1} 损失函数。 L_{cls_r} 和 L_{cls} 分别为一阶段和二阶段的分类损失，采用多类别交叉熵损失函数，一阶段为前景背景二分类，二阶段为多目标分类（对于检测任务来说，和二分类一样）。此外， λ_1 、 λ_2 、 λ_3 、 λ_4 为每个任务损失的权衡因子。

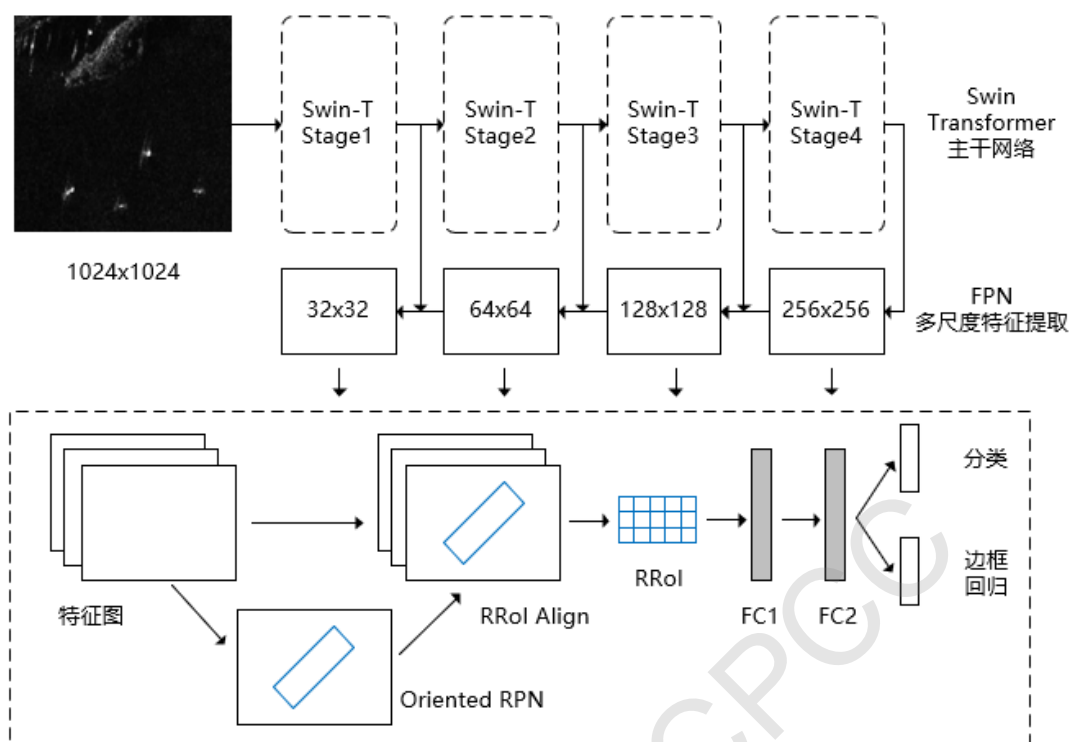


图 20 船舶有向检测网络结构

2.3.3 数据增强

为了在有限样本条件下增强模型在复杂场景的鲁棒性，本文所提方法利用 SAR 目标的特性扩充场景训练样本的多样性，主要包括通用数据增强和多通道特征融合操作。

通用数据增强分为翻转、旋转和随机剪裁拼接。翻转包括水平、垂直、对角线三种方式；为了保持 SAR 数据分布特性，旋转只采用了 90° 及其整数倍的旋转方式。另外也加入了随机剪裁拼接数据增强，所有的通用数据增强方法在训练的每次迭代过程中随机执行，没有扩充原有训练数据。

多特征融合操作同样应用于图像层级，包括多种对比度下的特征和 CFAR 处理后的特征。单通道 SAR 图像原始数据包含大量的峰值点，为返回能量值最高的目标结构。基于深度学习的目标检测网络应用于单通道幅值 SAR 图像时，一般会将 SAR 图像先做量化处理到可视范围之内，基于之前的研究^[5]，所提方法统一采用 15 倍均值量化策略使船舶目标的显著性更高。但由于成像环境和参数的影响，每景 SAR 图像最优的量化参数并不相同，因此，所提方法补充了 8 倍均值量化策略。此外，区别于量化操作，CFAR 处理后的图像特征来自于统计学方法处理结果。融合操作如图 21 所示，三通道融合图为 RGB 伪彩图，红色为 CFAR 通道，绿色和蓝色分别为 8 倍均值和 15 倍均值通道。视觉上绿色为主基调，这是由于 8 倍均值量化的杂波区域像素值相对较大，而在目标区域可以明显

的看到 CFAR 通道的蓝色像素。




图 21 多通道融合处理，第一行和第二行分别展示了场景切片和目标的融合效果

2.4 虚警鉴别模块

图像预处理得到船舶候选区域后，由于检测范围的缩小，虚警率已大大降低，但还是会存在一定的虚警目标，主要来自于海陆隔离带区域、海面非船舶人工设施、桥梁等区域。这些虚警目标产生的原因如第 1 节所述，主要由于网络对负样本学习不够充分，以及候选区域中依旧包含部分没有船舶的区域。因此，和传统的 SAR ATR 技术一样，虚警鉴别器在所提方法中十分必要。




图 22 虚警目标示例。(a) 陆地，(b) 沿海，(c) 桥梁，(d) 海杂波，(e) 海面

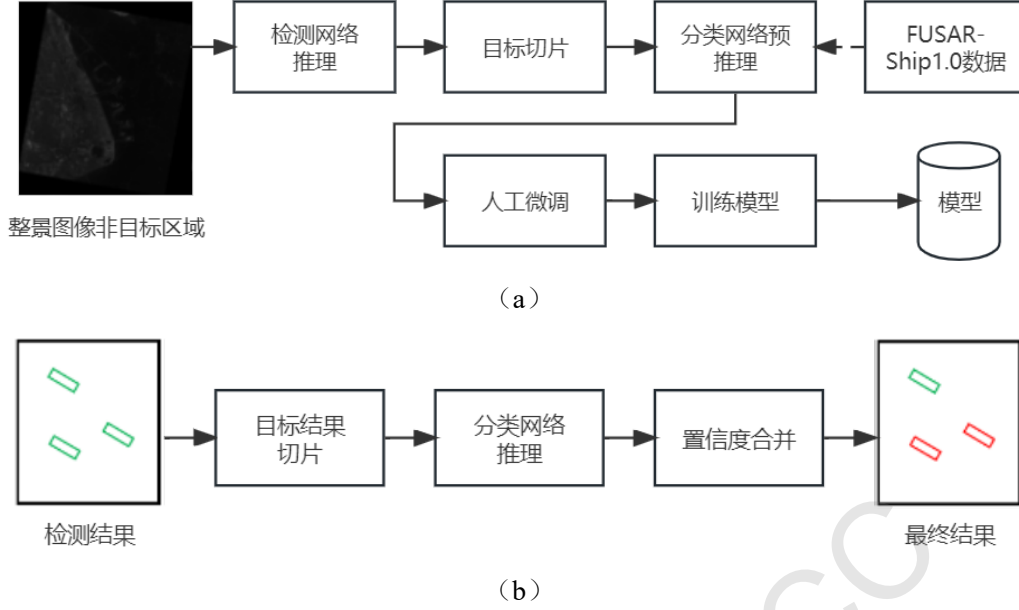


图 23 虚警鉴别网络训练和推理流程。(a) 训练流程，(b) 推理流程

虚警鉴别模块 (FDM) 基于深度学习分类器进行设计。图 23 展示了 FDM 的训练和推理流程设计，为了获取更有效的虚警样本，所提方法训练前先对训练集中的整景原始图像进行一次检测，自动分离出非真值区域的检测结果作为虚警目标样本，同时加入 FUSAR-Ship1.0^[5]中的虚警数据库以保证充足的训练样本。同时，FUSAR-Ship 数据集训练的初始分类模型被用于预推理，加快人工微调的效率。

推理阶段，方法先对检测结果做切片，使用虚警鉴别网络对切片进行分类，然后对分类置信度和检测置信度做调和平均得到最终结果的置信度，计算方式如下：

$$S_c = \frac{2S_d \times S_r}{S_d + S_r} \quad (2-9)$$

其中 S_c 为输出的合并置信度， S_d 为检测网络结果置信度， S_r 为虚警鉴别网络结果置信度。

虚警鉴别的目的是准确的鉴别出船舶目标和非船舶目标，可以是二分类，也可以是多分类，称之为细粒度虚警鉴别。相对于船舶目标，虚警目标由于其广阔的覆盖范围，特征呈现出多样性。当分类网络中定义的单类别内部特征不统一时，会造成网络预测的不稳定。所设计的 FDM 采用多分类虚警鉴别，包括 7 类目标：船舶、陆地、沿海、桥梁、海面、杂波、其他，典型的样例如图 22 所示。类别细粒度以及不同深度学习网络对虚警鉴别效果的影响，将在第 4 节第 4 部分做详细实验分析。

此外，和检测网络一样，虚警鉴别部分也对船舶和虚警目标切片做数据增强和特征融合操作，数据增强包括随机翻转、90 度倍数旋转、对比度增强。特征融

合为 CFAR 特征、8 倍均值特征、15 倍均值特征融合，如图 24 所示，分别为红色、绿色和蓝色通道。




图 24 目标多通道融合处理

3 实验

3.1 实验数据和评估指标

本文所提方法应用对象为大场景 SAR 图像，实验数据由 30 景完整的高分 3 超精细条带（UFS）模式影像组成，已通过商业软件进行地理编码和几何校正，保留单通道幅值信息。影像分辨率 1 米，每景的宽高约为 30000 像素左右，包含 10 亿像素大小的图像区域。影像主要涵盖船舶目标较多的杭州湾、长江入海口、东海、渤海等区域，包含靠岸、近岸、离岸等多种复杂的水域环境，典型的样例如图 25 所示。数据集共包含船只 3783 个，划分成训练集 20 景，测试 10 景。




图 25 高分 3 整景水域影像示例。(a) 中国江西省鄱阳湖区域，(b) 中国渤海海域

算法评估方面，CRM 的评估采用第 3 节第 2 部分定义的真值命中率和检测范围评价指标。AP 和准确率分别用于 OSD 和 FDM 的评估，检测率和虚警率整景图像结果的评估，定义分别如下：

$$FA = \frac{FP}{TP + FP} \quad (3-1)$$

其中FP、TP、FP分别表示真正例、假正例、假负例。

另外，大场景图像的可视化检测结果采用 QGIS 软件呈现，算法各个模块的配置细节由后续实验部分给出。

3.2 候选区域检索模块评估

CRM 为非学习型算法，为了验证方法的通用性，算法基于训练集进行人工参数调整，然后在测试集上测试。评估指标包含真值命中率、检测范围以及时间性能。CRM 包含海陆分割和 CFAR 处理两部分，依次执行，首先评估海陆分割性能，结果见表 3-1。从量化结果可以看出，采用的海陆分割方法减少了一定的陆地无效检测区域，减少的比例不多，在 20%~25%左右，主要是由于只有部分测试图像中有陆地区域。同时，由于海陆分割带的设计，减少了海岸线附近船舶的漏检，构建海陆隔离带的形态学操作耗时在 1~2 秒左右，开销很小。另外，由于采用掩膜匹配的方式，算法可以在较短时间内完成海陆分割，更有利于实际应用。

表 3-1 海陆分割量化评估结果

	海陆隔离带	真值命中率	检测范围	时间（秒）/景
第一组 20 景		96.83%	75.52%	11.8
	√	99.78%	77.36%	13.6
第二组 10 景		96.21%	79.48%	12.2
	√	99.61%	82.77%	13.3

图 26 展示了其中 3 景影像的可视化结果，都含有较多陆地区域。从结果中可以看出，所提方法能有效去除大部分陆地区域，同时也能保留内陆河流、湖泊等水域。由于 SAR 影像的地理编码误差，基于掩膜的匹配方法会导致沿海地区匹配不准，形态学处理和海陆隔离带消除了地理误差带来的影响。图 27 展示了其中一幅典型图像的海陆隔离带区域，从图中可以看出，部分沿岸区域还有大量的船舶，隔离带可以有效的保留这些目标。另外，海陆隔离带仅存在与沿海地区，相对占比较少，对后续检测时间的影响有限。




图 26 所提方法部分海陆分割结果




图 27 其中一景影像的海陆隔离带区域示意

在海陆分割的基础上加入 CFAR 预处理，得到 CRM 的最终结果，如表 3-2 所示，其中的处理时间仅为 CFAR 用时。相较于海陆分割，本模块大幅缩短了检测范围，这是由于本实验选取的影像包含海洋区域较多，CFAR 滤除了大部分海杂波区域。另外，扩张海岸线操作使杂波建模更加准确，减少了部分能量较弱船舶目标的漏检。时间性能方面，由于设计的处理方法相对简单，只在全局尺度进行参数估计和阈值计算，保证了该模块的时效性。

表 3-2 加入海杂波滤除后的量化评估结果

	扩张海岸线	真值命中率	检测范围	时间（秒）/景
第一组		98.91%	19.03%	6.5
20 景	√	99.64%	20.07%	7.3
第二组		98.44%	19.22%	6.2
10 景	√	99.39%	20.29%	7.5

图 28 展示了其中一景影像结果的可视化，为所设计船舶候选区域检索模块的最终输出。图中放大了两部分海洋区域的结果，可以看出，海杂波滤除模块有效的去除了大部分海面区域，同时保留了各尺度船舶的像素。




图 28 船舶候选区域检索最终结果及海杂波滤除效果展示

3.3 船舶有向检测器评估

本节将所提的 OSD 和目前最优的 SOTA 方法做了实验对比，涵盖单阶段、双阶段、无锚框等多种类型。实验数据为整景图像中包含船舶区域的切片，切片大小为 1024*1024 像素，训练切片共 2555 张，包含 7447 个目标，来自于 20 景训练集，测试切片共 1037 张，包含 2680 个目标，来自于 10 景测试集。所有算法都采用了 FPN 特征金字塔结构，网络输入尺寸为 1024*1024，训练使用 4 张 RTX3090 显卡，36 个训练轮次（Epoch），BS 为 8；推理使用 1 张 RTX3090 显卡，bs 为 1，结果置信度阈值为 0.05，评估指标为检测出的结果数量、Recall、mAP、每秒检测帧数（Frames Per Second, FPS）和模型推理时显存占用，其他控制的变量包括是否做数据增强。

表 3-3 有向检测器评估结果

检测器	类型	结果数量	Recall	mAP	FPS(bs=1)	显存(GB)
RetinaNet-R-HBB	单阶段	3479	0.896	0.8802	20.3	2.14
RetinaNet-R-OBB		3244	0.888	0.861	21.6	2.14
R3Det		3607	0.911	0.886	16.7	2.17
RetinaNet-R-GWD		3293	0.895	0.879	20.2	2.14
RetinaNet-R-KLD		3267	0.903	0.8828	21.2	2.14
R3Det-KLD		4044	0.916	0.892	16.7	2.17
Oriented Reppoints	无锚框	5515	0.942	0.909	19.6	2.3
Roi Transformer	双阶段	2478	0.869	0.86	19.1	2.8
Gliding Vertex		3576	0.865	0.849	21.1	2.64
Oriented R-CNN		6095	0.913	0.899	20.5	2.69
ReDet		2890	0.931	0.922	3.8	2.9
所提方法		2671	0.917	0.911	17	2.46

表 3-3 为未做数据增强条件下所提方法和其他算法的性能对比。从结果可以看出，单阶段算法普遍速度较快，但整体性能不如双阶段算法。单阶段算法中，KLD^[29]性能最好，它使用 KL (Kullback-Leibler) 散度进行边框回归训练，较好的缓解了角度周期性问题，另外，采用 R3Det^[26]的结构可以提高 KLD 的检测性能，但级联的网络增加了额外的推理时间；Ori-RCNN 虽然采用了双阶段结构，但 RPN 阶段只增加了一个卷积层用于生成 RRoI，设计的 6 参数边框回归方式同样克服了训练时的角度周期性问题，在检测精度和时间方面都达到了较高水平；所提算法基于 Ori-RCNN 进行改进，进一步提高了检测性能，获得了最高的 AP。另外，网络的改进使得算法速度有所下降，但依旧处于较高水平。

表 3-4 展示了数据增强的实验结果，实验同时对比了性能较好的 KLD、Ori-RCNN 以及所提方法，另外也比较了一些常用技巧对网络的影响，其中 DCN 代表可形变卷积^[39]，FP16 代表混合精度训练^[40]。从实验结果看，在加入数据增强后，Ori-Repp、Ori-RCNN 以及所提方法性能上都得到了提升；KLD 和 Ori-RCNN 加入 DCN 后 mAP 没有提升，同时增加了推理时间。加入数据增强后，所提方法 mAP 提升了 1.8%，优于其他方法。加入 FP16 混合精度训练之后，所提方法的 FPS 从 17 提升到了 20，与最快的 Ori-RCNN 接近，同时方法的精度并没有下降。最后，所提方法进行了更多的 Epoch 训练，mAP 达到 0.939。

表 3-4 数据增强评估结果

检测器	数据增强	其他	结果数量	Recall	mAP	FPS (bs=1)	显存 (GB)
R3Det-KLD			4044	0.916	0.892	16.7	2.17
	✓		5824	0.921	0.884		
	✓	DCN	5714	0.921	0.883	16	2.25
Oriented Reppoints			5515	0.942	0.909	19.6	2.3
	✓		8569	0.963	0.921		
Oriented R-CNN			6095	0.913	0.899	20.5	2.69
	✓		8810	0.931	0.903		
	✓	DCN	11452	0.93	0.903	19.5	2.84
所提方法			2671	0.917	0.911	17	2.46
	✓		3274	0.945	0.929		
	✓	FP16	3110	0.946	0.931	20	2.59
	✓	FP16 Epoch72	2885	0.948	0.939		

图 29 展示了 KLD、OSD 以及数据增强策略的部分可视化结果。可以看出，OSD 对于船舶的角度预测更优，减少了密集排列区域的漏检，如图中的第一列所示。所提的数据增强方法，有效的提高了各种复杂场景下的船舶检测性能，包括密集排列、近岸场景、强散射噪声干扰等情况。例如第三列和第四列图像中的船舶，SAR 成像和复杂环境导致其能量较弱，特征不明显，数据增强融入多种对比度和 CFAR 处理后的目标特征，提高了这些目标的检测率。另外，从图中可以看出，所提方法依然存在漏检，特别是密集排列区域，这些难度较大的场景，值得后续进一步做深入研究。

为了充分利用显卡资源，本研究对滑窗大小和 bs 参数做了实验，以确定实际应用过程中最合理的取值。

此外，设计的大图推理优化策略也进行了实验评估，测试了不同分块滑窗和 bs 下的推理速度，测试数据为 10 景 SAR 图像原图，实验基于 3.3 节的船舶候选区域检测的掩膜结果展开，采用单张 RTX3090 显卡。结果如

表 3-5 所示，随着分块滑窗的逐渐增加，bs 逐渐变大，提高了并行推理的效率。但整景图像的检测范围也逐渐变大，整体的检测时间并没有减少。同时，检测范围变大导致更多虚警目标，由于图像拉伸范围的影响，检测率也有所下降。通过实验分析，所提方法后续设置分块滑窗和检测网络同为 1024 大小。另外从

表 3-5 可以看出，整景检测的虚警率依旧较高，下一小节将分析并描述解决方案。




图 29 KLD、OSD 以及数据增强策略的部分结果可视化，绿色、蓝色、红色分别为检测正确、漏检、虚警。(a) KLD，(b) OSD，(c) 加入数据增强的 OSD

表 3-5 大图推理策略实验

分块滑窗 大小（像素）	bs	检测率	虚警率	检测范围	检测时间 （秒）	显存 (GB)
1024	1	0.9218	0.2357	0.2014	828	2.47
1648	4	0.9214	0.2366	0.3116	860	4.12
2272	9	0.9214	0.2397	0.4148	897	11.49
2896	16	0.9208	0.2435	0.5019	973	15.32

3.4 虚警鉴别模块评估

所提 FDM 使用了多分类的方式鉴别虚警目标，包含船舶和 6 类虚警类别。本小节首先对虚警类别细粒度对鉴别效果的影响进行实验研究。实验采用的分类器为 VGG16，从 FUSAR-Ship 虚警数据库种划分 20%做验证集。本实验比较了 3 种细粒度，2 分类为船舶、所有虚警；5 分类为船舶、陆地和沿海虚警、海面

杂波虚警、桥梁、其他；7 分类为所有类别。

表 3-6 虚警细粒度分类实验结果

细粒度类别数	全类别准确率 (%)	船舶准确率 (%)	非船舶准确率 (%)
2	96.31	95.87	97.69
5	98.12	99.03	97.22
7	98.46	99.62	97.43

结果如表 3-6 所示，其中非船舶准确率为所有虚警当做一个负样本。从结果可以看出，多分类整体性能优于二分类，类别划分越细，准确度越高。当细粒度为 2 时，非船舶虚警最具多样性，使得非船舶准确率较高，船舶检测率较低。船舶准确率越高代表船舶漏检越少，是辅助性的虚警鉴别网络更关注的指标。综上，本研究采用了最优的 7 分类策略。

另外，本小节对比了不同深度学习网络的虚警目标鉴别性能，以及数据增强效果。实验采用 7 分类的细粒度类别，评价指标为全类别准确率，时间性能采用每秒所执行的浮点运算次数（Floating-point operations per second, Flops）评估，G 代表 10^9 次浮点运算。实验比较了 VGG16、ResNet50 和 Swin-Transformer tiny（Swin-tiny）。结果如表 3-7 所示，加入数据增强后，三个网络的分类性能都得到了提高，证明了所提数据增强策略的有效性。ResNet 和 Swin 相对复杂，速度较 VGG16 慢，但达到较高的准确度，因此，本研究采用 ResNet50 作为 FDM 中的鉴别器。

表 3-7 不同分类网络结果评估

网络	数据增强	准确率 (%)	Flops(G)
VGG16		96.71	15.5
	√	98.46	
ResNet50		97.12	25.56
	√	99.32	
Swin-tiny		97.84	28.29
	√	99.45	

3.5 基于整景图像的消融实验

考虑到本文所提方法由多个模块共同组成，本节进行了消融实验，验证算法各个模块在整景检测时的作用和效果。实验配置方面，有向检测网络训练采用 4 张 RTX 3090 显卡，BS 为 8，初始学习率为 0.0001，共训练 72 个 Epoch，训练过程加入数据增强操作。虚警鉴别网络训练同样采用 4 张显卡，bs 为 64，初始学习率为 0.01，共训练 100 个 Epoch，训练过程同样加入数据增强操作。整景推理采用了单张 3090 显卡，各个模块按单独进程串行执行，检测网络和虚警鉴别

网络的 BS 分别设置为 1 和 64。评估指标方面，针对整景图像采用了更加直观的检测率、虚警率以及推理时间。

本文所提方法包含 3 个主要模块：候选区域检索、有向检测网络、虚警鉴别网络。其中，有向检测网络的效果已在本书的第 3 部分进行了实验验证。消融实验对候选区域检索模块、虚警鉴别模块进行消融，基准方法为所提的有向检测网络。量化结果如表 3-8 所示，可视化结果综合置信度为 0.8，图 30 可视化了其中三景完整影像的检测结果。图 31 和图 32 可视化了部分局部区域各模块的效果。其中绿色为检测正确、蓝色为漏检、红色为虚警。


表 3-8 消融实验结果

候选区域 检索模块	虚警鉴别 模块	检测率	虚警率	平均时间 (秒)/景
		92.21	30.76	431
√		92.18	23.57	82
√	√	91.47	12.69	96


只采用基准检测网络时，推理时间长且虚警率很高，基本无法满足实际需求，图 30（a）可以看出有大量的内陆和海面虚警，但基于深度学习的方法，船舶定位相对较准，如图 31（a）第 3 列结果所示。

加入图像预处理模块后，推理时间大大减少，且虚警率下降。从图 30（a）和（b）的整景结果对比可以看出，大部分陆地虚警和海洋虚警被滤除，但仍然存在部分沿海和海杂波虚警。图 31（a）和（b）对比了加入前后可视化结果，陆地和海面存在部分与船舶目标相似的设施，这些区域的虚警仅靠神经网络难以全部滤除。


加入虚警鉴别模块后，整体检测时间有所增加，但依旧处于较快的检测时间范围内。此时虚警率进一步下降，对比图 30（b）和（c），可以看出，沿岸和非船舶类沿海虚警进一步减少，而整体检测率有所下降，这部分漏检主要由虚警鉴别网络中和船舶较接近的其他类导致。图 31（c）和（d）对比了加入前后的效果，从左到右依次展示了海面、人造设施、沿岸区域的虚警，这些目标在候选区域检索之后被保留下来，设计的虚警鉴别网络可以进一步滤除。另外，在加入所有模块后，算法检测每景图像的平均时间为 96 秒，在 10 亿像素大小的图像上实现了分钟级检测效率。



(a)




(b)



(c)

图 30 消融实验结果整景可视化。(a) 所提有向检测网络，(b) 加入候选区域检索模块，
(c) 同时加入候选区域检索和虚警鉴别






图 31 CRM 和 FDM 的效果可视化。(a) 加入 CRM 前。(b) 加入 CRM 后。(c) 加入 FDM 前。(d) 加入 FDM 后。




图 32 虚警鉴别模块加入前后对比，第一行为加入前，第二行为加入后

3.6 和其他方法对比实验

一些已有的方法也针对整景 SAR 图像船舶检测做了研究。这里，所提方法和多尺度 CFAR^[4]、深度学习正框算法进行了比较。实验对比了三个方法在整景图像上的检测性能。所有方法都加入海陆分割和虚警鉴别模块，正框算法采用 Faster-RCNN 网络结构，同时也加入本文所提的候选区域检索模块。结果如表 3-9 所示，所提方法获得了最优的检测结果，且速度保持在相对较快的水平。多尺度 CFAR 为非学习型算法，优势在于不需要标注和训练，且速度较快，但对于新场景的鲁棒性较差。正框算法对于远海船只的检测率和所提方法接近，但对于近岸密集排列的船只，漏检较多，导致整体检测率较低。另外，由于都加入了虚警鉴别模块，三个方法的虚警率差别不大。

表 3-9 对比实验结果

方法	检测率 (%)	虚警率 (%)	平均时间 (秒) / 景
多尺度 CFAR	81.37	15.86	65
正框算法	85.92	13.74	92
所提方法	91.47	12.69	96

图 33 展示了所提方法在其中一景图像上的检测效果，分别放大了其中四个区域，涵盖靠岸、近岸、远海、密集排列等场景。图中可以看出，所提方法可以在多种复杂的水域中精准的检测出船舶目标。但算法依然存在一些漏检和虚警，如图中右上方放大区域，包含沿岸码头虚警、靠岸密集船舶部分漏检。还有图中左下方小型船只密集排列区域的一个漏检。漏检的船舶结构不明显，部分尺寸很小。这些不足有待后续进一步研究和讨论。




图 33 所提方法在其中一景影像中的检测效果，绿色为正确检测、蓝色为漏检、红色为虚警

4 案例小结

本案例聚焦于大场景下单通道 SAR 中船舶目标的检测效率问题，提出了一种多尺度渐进式的快速船舶目标检测方法，通过全局尺度搜索候选区域、场景尺度有向检测目标、目标尺度虚警滤除实现快速、精准的 SAR 船舶目标检测。本文首先叙述了方法的整体框架，然后分别介绍了其中三个主要模块：船舶候选区域检索、船舶有向检测网络、虚警鉴别网络。基于传统方法设计候选区域检索模块，通过海陆分割和 CFAR 预处理快速定位船舶候选区域。基于深度学习设计高精度有向检测器和虚警鉴别网络，从候选区域中进一步检测出船舶目标。最后，每个模块分别进行了单独的实验验证，并通过消融实验和对比实验验证了方法在大场景 SAR 图像中的整体有效性。

5 案例思考

SAR 图像是一种重要的遥感数据源，基于 SAR 图像的海面目标识别技术目前已成功应用于渔业管理、港口规划和海洋监测等典型应用场景中，在利用单通道大场景 SAR 图像对近岸和远海区域的船舶进行目标检测时，面临效率低下和高虚警率的双重挑战，为此本案例在分析 SAR 图像特征，传统 SAR 船舶目标识别技术以及先进的深度学习技术的基础上，结合传统算法以及深度学习算法的优势，提出一种多尺度渐进式快速 SAR 船舶检测方法。这种方法通过结合传统的海陆分割和恒虚警率预处理技术以及先进的深度学习技术，有效平衡了算法复杂度和检测效率。具体操作上，首先在全局尺度进行快速地海陆分割和预处理，快速提取船舶候选区域，这一步骤迅速缩小了关注区域，从而减轻了后续处理的计算负担。接着，在这些预筛选的候选区域内，应用精细化的深度学习模型进行详细的目标检测，这不仅提高了检测的速度，也显著减少了复杂背景如杂波、岛屿和沿岸环境引起的虚警，实现检测过程中算法复杂度和效率的平衡。此外，通过实施数据增强、迁移学习等策略，进一步增强了模型在面对不同场景时的泛化能力和适应性。

从技术应用方面来说，本案例结合传统方法（如 CFAR）和深度学习方法（如 Faster R-CNN）的优点，采用传统方法初步检测和过滤背景噪声，深度学习方法用于精确识别和分类目标。传统方法在计算速度和初步筛选上具有优势，而深度学习方法在特征提取和精确识别方面表现出色。结合两者的优势，能够有效提高检测的整体性能，减少虚警率和漏检率。这种多尺度渐进式的方法不只能应用于 SAR 船舶检测，它的设计原则和实施框架也可以应用遥感图像的广域监测任务中

例如，在城市规划中，该技术可以用于广域建筑物、道路和其他基础设施的

变化检测，通过传统方法快速检测可疑活动区域，然后使用深度学习方法进行精确识别和分类，提升监控效率和准确度。在军事应用中，可以用来识别和跟踪地面或海面的移动目标，采用广域到局部的算法能够识别重要目标，实现高时效性的情报生成。在自然灾害如地震、洪水等发生后，利用多尺度渐进式检测方法处理灾区遥感图像，快速识别受灾区域和关键设施的损毁情况。这种方法能够快速定位灾区内的受损区域，并提供精确的灾情评估，帮助应急救援队伍迅速制定救援计划，提高救援效率。在农业监测中，通过多尺度渐进式检测方法对大范围农田遥感影像进行处理，快速识别病虫害发生区域和作物生长状态。这种方法可以帮助农业管理部门及时发现和处理农田问题，提高农业生产效率，保障粮食安全。

因此，这种多尺度渐进式检测方法不仅在技术层面上提供了一种高效且准确的解决方案，也为广泛的应用领域带来了实际的价值和可能性，这种结合传统方法与人工智能方法的研究有助于充分发挥不同算法的优势，推动遥感技术的进一步应用和发展。

通过本案例的分析，我们了解了传统目标检测以及基于深度学习的目标检测算法，同时学习了结合两种算法的改进检测算法，主要思考的问题如下：

- (1) 目前 SAR 图像船舶检测主要存在哪些问题？
- (2) 针对 SAR 图像船舶检测的主要算法有哪些？不足之处体现在哪些方面？
- (3) 探讨本案例提出算法相对于传统算法的优势。
- (4) 改进算法能够解决哪些关键问题，还有哪些问题尚待解决？

此外，在本案例的基础上，学生后续还可以通过分析 SAR 图像中的目标稀疏性，探讨如何优化算法以提升检测效率，包括如何设计更有效的候选区域提取方法以及改进全局尺度的预处理操作。通过研究虚警样例，可以思考如何改进传统方法和深度学习方法以减少虚警率，如通过改进杂波建模和设计更鲁棒的特征提取方法。在实验过程中，通过调整参数和改进算法，验证不同方法在各种复杂环境下的性能表现，例如如何在高噪声和强杂波背景下维持高检测精度。还鼓励结合实际应用场景，提出新的检测策略和优化方案，探索多尺度渐进式检测方法在不同应用中的适应性。

本案例从应用出发，通过对典型应用实例的分析引起技术存在的难点，从 SAR 图像成像机理出发，分析目标识别算法存在的难点，进一步介绍了传统 SAR 船舶目标识别算法以及基于深度学习的目标检测算法的优劣，从而提出改进算法。案例在理论介绍的基础上，也包含大量数据处理试验，如 SAR 船舶目标检测中的多尺度渐进式算法实验，学生需从数据收集、算法实现到结果分析进行完整操作，数据处理试验引导学生运用所学知识进行创新，提高他们的动手能力。在

实现改进算法的基础上，设置开放性问题，引导学生继续对技术存在的问题进行深入思考，如算法效率优化、虚警率降低等关键技术点的进一步优化。本研究案例是需求导向型典型案例，学生在案例学习后能够了解本领域的最新技术，并具备一定的实践能力。

6 参考文献

- [1] Li J, Xu C, Su H, et al. Deep Learning for SAR Ship Detection: Past, Present and Future[J], 2022, 14(11): 2712.
- [2] Burl M C, Owirka G J, Novak L M. Texture discrimination in synthetic aperture radar imagery[C]. Twenty-Third Asilomar Conference on Signals, Systems and Computers, 1989., 1989: 399-404.
- [3] Zhang C, Liu P, Wang H, et al. A Review of Recent Advance of Ship Detection in Single-Channel SAR Images[J]. Waves in Random and Complex Media, 2022.
- [4] Ao W, Xu F, Li Y, et al. Detection and Discrimination of Ship Targets in Complex Background From Spaceborne ALOS-2 SAR Images[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2018, 11(2): 536-550.
- [5] Hou X, Ao W, Song Q, et al. FUSAR-Ship: Building a high-resolution SAR-AIS matchup dataset of Gaofen-3 for ship detection and recognition[J]. Science China Information Sciences, 2020, 63: 1-19.
- [6] Zhu X X, Montazeri S, Ali M, et al. Deep Learning Meets SAR: Concepts, models, pitfalls, and perspectives[J]. IEEE Geoscience and Remote Sensing Magazine, 2021, 9(4): 143-172.
- [7] Novak L M, Owirka G J, Netishen C M. Radar target identification using spatial matched filters[J]. Pattern Recognition, 1994, 27(4): 607-617.
- [8] Novak L M, Owirka G J, Brower W S, et al. The automatic target-recognition system in SAIP[J]. Lincoln Laboratory Journal, 1997, 10(2).
- [9] Novak L M, Halversen S D, Owirka G, et al. Effects of polarization and resolution on SAR ATR[J]. IEEE Transactions on Aerospace Electronic Systems, 1997, 33(1): 102-116.
- [10] Goldstein G B. False-Alarm Regulation in Log-Normal and Weibull Clutter[J]. IEEE Transactions on Aerospace and Electronic Systems, 1973, AES-9(1): 84-92.
- [11] Rohling H. Radar CFAR Thresholding in Clutter and Multiple Target Situations[J]. IEEE Transactions on Aerospace and Electronic Systems, 1983, AES-19(4): 608-621.
- [12] Li J, Zelnio E G. Target detection with synthetic aperture radar[J]. IEEE Transactions on Aerospace and Electronic Systems, 1996, 32(2): 613-627.
- [13] Smith M E, Varshney P K. Intelligent CFAR processor based on data variability[J]. IEEE Transactions on Aerospace and Electronic Systems, 2000, 36(3): 837-847.

- [14] Pham Q H, Brosnan T M, Smith M J. Multistage algorithm for detection of targets in SAR image data[C]. Algorithms for Synthetic Aperture Radar Imagery IV, 1997: 66-75.
- [15] Leng X, Ji K, Yang K, et al. A bilateral CFAR algorithm for ship detection in SAR images[J]. IEEE Geoscience Remote Sensing Letters, 2015, 12(7): 1536-1540.
- [16] Dai H, Du L, Wang Y, et al. A modified CFAR algorithm based on object proposals for ship target detection in SAR images[J]. IEEE Geoscience Remote Sensing Letters, 2016, 13(12): 1925-1929.
- [17] Cui J, Jia H, Wang H, et al. A Fast Threshold Neural Network for Ship Detection in Large-Scene SAR Images[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2022, 15: 6016-6032.
- [18] Chen H, Wang Q, Shen Y. Decision tree support vector machine based on genetic algorithm for multi-class classification[J]. Journal of Systems Engineering and Electronics, 2011, 22(2): 322-326.
- [19] Liu G, Zhang Y, Zheng X, et al. A New Method on Inshore Ship Detection in High-Resolution Satellite Images Using Shape and Context Information[J]. IEEE Geoscience and Remote Sensing Letters, 2014, 11(3): 617-621.
- [20] Wang X, Li G, Plaza A, et al. Ship Detection in SAR Images by Aggregating Densities of Fisher Vectors: Extension to a Global Perspective[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1-13.
- [21] An Q, Pan Z, You H J S. Ship detection in Gaofen-3 SAR images based on sea clutter distribution analysis and deep convolutional neural network[J], 2018, 18(2): 334.
- [22] Ding J, Xue N, Long Y, et al. Learning RoI transformer for oriented object detection in aerial images[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 2849-2858.
- [23] Xie X, Cheng G, Wang J, et al. Oriented R-CNN for object detection[C]. Proceedings of the IEEE/CVF international conference on computer vision, 2021: 3520-3529.
- [24] Han J, Ding J, Xue N, et al. Redet: A rotation-equivariant detector for aerial object detection[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 2786-2795.
- [25] Lin T-Y, Goyal P, Girshick R, et al. Focal loss for dense object detection[C]. Proceedings of the IEEE international conference on computer vision, 2017: 2980-2988.

- [26] Yang X, Yan J, Feng Z, et al. R3det: Refined single-stage detector with feature refinement for rotating object[C]. Proceedings of the AAAI conference on artificial intelligence, 2021: 3163-3171.
- [27] Yang X, Yan J, Liao W, et al. SCRDet++: Detecting Small, Cluttered and Rotated Objects via Instance-Level Feature Denoising and Rotation Loss Smoothing[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 45(2): 2384-2399.
- [28] Yang X, Yan J, Ming Q, et al. Rethinking rotated object detection with gaussian wasserstein distance loss[C]. International conference on machine learning, 2021: 11830-11841.
- [29] Yang X, Yang X, Yang J, et al. Learning high-precision bounding box for rotated object detection via kullback-leibler divergence[J]. Advances in Neural Information Processing Systems, 2021, 34: 18381-18394.
- [30] Li W, Chen Y, Hu K, et al. Oriented reppoints for aerial object detection[C]. Proceedings of the IEEE/CVF conference on computer vision and pattern recognition, 2022: 1829-1838.
- [31] Li J, Qu C, Shao J. Ship detection in SAR images based on an improved faster R-CNN[C]. 2017 SAR in Big Data Era: Models, Methods and Applications (BIGSAR DATA), 2017: 1-6.
- [32] Cui Z, Wang X, Liu N, et al. Ship detection in large-scale SAR images via spatial shuffle-group enhance attention[J]. IEEE Transactions on Geoscience and Remote Sensing, 2020, 59(1): 379-391.
- [33] Sun Y, Sun X, Wang Z, et al. Oriented ship detection based on strong scattering points network in large-scale SAR images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, 60: 1-18.
- [34] Ke X, Zhang X, Zhang T, et al. SAR ship detection based on an improved faster R-CNN using deformable convolution[C]. 2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS, 2021: 3565-3568.
- [35] He B, Zhang Q, Tong M, et al. An anchor-free method based on adaptive feature encoding and Gaussian-guided sampling optimization for ship detection in SAR imagery[J]. Remote Sensing, 2022, 14(7): 1738.
- [36] The Global 250 m MODIS Water Mask[EB/OL]. <http://glcf.umd.edu/data/watmask/>.
- [37] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need[J], 2017, 30.

- [38] Liu Z, Lin Y, Cao Y, et al. Swin transformer: Hierarchical vision transformer using shifted windows[C]. Proceedings of the IEEE/CVF international conference on computer vision, 2021: 10012-10022.
- [39] Dai J, Qi H, Xiong Y, et al. Deformable convolutional networks[C]. Proceedings of the IEEE international conference on computer vision, 2017: 764-773.
- [40] Micikevicius P, Narang S, Alben J, et al. Mixed precision training[J], 2017.

18206109996CPCC