

文章编号 1004-924X(2023)04-0517-16

面向航天光学遥感场景压缩感知测量值的 舰船检测

肖术明^{1,2}, 张 叶^{1,2*}, 常旭岭^{1,2}, 孙建波^{1,2}

(1. 中国科学院 长春光学精密机械与物理研究所, 吉林 长春 130033;

2. 中国科学院大学, 北京 100039)

摘要: 基于压缩感知的航天光学遥感成像系统可以在采样阶段通过硬件同时完成采样和压缩。在面临舰船检测任务时, 系统需要重建原始场景, CS 的场景重建过程计算量大、内存要求高且耗时。本文提出了直接对成像系统测量值进行舰船检测的算法——基于压缩感知和改进 YOLO 的测量值舰船检测算法。为了模拟成像系统的分块压缩采样过程, 利用步长和卷积核尺寸相等的卷积测量层对场景进行卷积运算, 将高维图像信号投影到低维空间得到全图 CS 测量值。得到场景的测量值后, 测量值舰船检测网络从测量值中提取舰船的位置信息。在主干网络中导入 SENet 模块, 利用改进后的主干网络来提取测量值的舰船特征信息; 利用特征金字塔网络强化特征提取的同时融合浅层、中层和高层的特征信息, 进而完成舰船的位置信息预测。其中, CS-IM-YOLO 将卷积测量层和 CS 测量值舰船检测网络连接起来端对端训练, 大大简化了算法的预处理过程。通过数据集 HRSC2016 评测算法性能, 实验结果表明: CS-IM-YOLO 对于 SORS 场景 CS 测量值舰船检测的检测精度为 91.60%, 召回率为 87.59%, F1 值为 0.90, 和 AP 值为 94.13%。这充分表明该算法可以对 SORS 场景的 CS 测量值进行高质量的舰船检测。

关键词: 压缩感知测量值的舰船检测; 压缩感知; 深度学习; 联合训练优化

中图分类号: TP394.1; TH691.9 文献标识码: A doi: 10.37188/OPE.20233104.0517

Ship detection oriented to compressive sensing measurements of space optical remote sensing scenes

XIAO Shuming^{1,2}, ZHANG Ye^{1,2*}, CHANG Xuling^{1,2}, SUN Jianbo^{1,2}

(1. Changchun Institute of Optics, Fine Mechanics and Physics, Chinese Academy of Sciences,
Changchun 130033, China;

2. University of Chinese Academy of Sciences, Beijing 100039, China)

* Corresponding author, Email: yolanda@spirits.ai

Abstract: The compressive sensing (CS)-based space optical remote-sensing (SORS) imaging system can simultaneously perform sampling and compression by using hardware at the sensing stage. The system must reconstruct the original scene during the ship detection task. The scene reconstruction process of CS is computationally expensive, memory intensive, and time-consuming. This paper proposes an algorithm

收稿日期: 2022-03-31; 修订日期: 2022-04-21.

基金项目: 钱学森空间技术实验室创新工作站开放基金资助项目 (No. GZZKFJJ2020003); 2019-长光复旦-基于中医的光照场自适应健康状态检测方法资助项目 (No. Y9S333T190); 吉林省省院合作计划资助项目 (No. 2020SYHZ0031)

named compressive sensing and improved you only look once (CS-IM-YOLO) for direct ship detection based on measurements obtained by the imaging system. To simulate the block compression sampling process of the imaging system, the convolution measurement layer with the same stride and convolution kernel size is used to perform the convolution operation on the scene, and the high-dimensional image signal is projected into the low-dimensional space to obtain the full-image CS measurements. After obtaining the measurements of the scene, the proposed ship detection network extracts the coordinates of the ship from the measurements. The squeeze-and-excitation Network (SENet) module is imported into the backbone network, and the improved backbone network is used to extract the ship feature information using the measurements. The feature pyramid network is used to enhance feature extraction while fusing the feature information of the shallow, middle, and deep layers, and then to complete predicting the ship's coordinates. CS-IM-YOLO especially connects the convolutional measurement layer and the CS based ship detection network for end-to-end training; this considerably simplifies the preprocessing process. We present an evaluation of the performance of the algorithm by using the HRSC2016 dataset. The experimental results show that the precision of CS-IM-YOLO for detection of ships via CS measurements in SORS scenes is 91.60%, the recall is 87.59%, the F1 value is 0.90, and the AP value is 94.13%. This demonstrates that the algorithm can perform accurate ship detection using the CS measurements of SORS scenes.

Key words: ship detection oriented to compressive sensing measurements; compressive sensing; deep learning; joint training optimization

1 引 言

航天光学遥感(Space Optical Remote Sensing, SORS)场景的舰船检测是遥感领域的研究热点。舰船检测具有广泛的民用和军事价值,例如搜索和救援、港口管理、海洋环境监控、领土安全和军事侦察^[1-4]。随着 SORS 成像系统成像分辨率的不断提高,系统获取的场景数据量也急剧增加。为了缓解数据存储和实时传输的巨大压力,传统的 SORS 成像系统并不会直接存储和传输探测器采集的原始场景数据,而是在传输前对数据进行压缩,以节省时间和空间资源。然而,这种方法数据采集的理论基础是奈奎斯特采样定理,必须以不小于信号带宽两倍的采样率对原始模拟信号进行均匀采样,以保存信号信息^[5]。这就导致冗余信息只能在压缩阶段被丢弃,从而浪费了成像系统前端使用高成本检测器获取的采样资源。

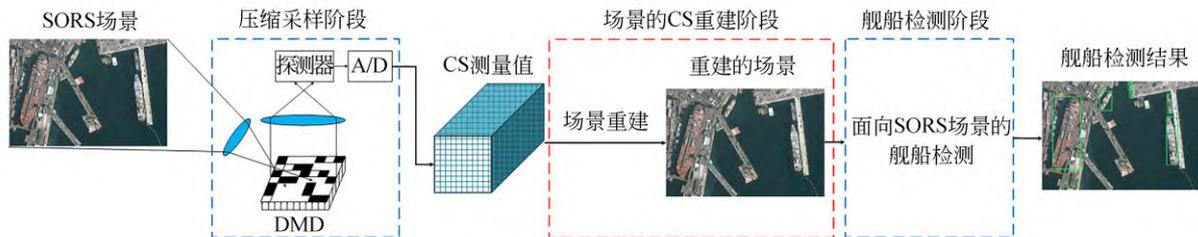
压缩感知(Compressive Sensing, CS)是一项新兴技术,如果信号在某个变换域是稀疏的,则高维信号可以通过与变换基无关的测量矩阵投影到低维空间,并且可以以远低于该变

换基的采样率准确恢复原始信号^[6-7]。CS 技术突破了奈奎斯特采样定理的瓶颈,能够以较低的采样率(远低于奈奎斯特采样率)采集场景数据,从而在数据采集的同时完成数据压缩。此外,CS 重构算法可以在原始数据稀疏的前提下,根据采集到的采样数据,理想地重构原始数据^[8],这就缓解了数据存储和实时传输的巨大压力。

最近,一种基于 CS 的 SORS 成像系统被提出^[9-11],它凭借 CS 技术在采样阶段通过硬件同时进行采样和压缩。因此,成像系统可以减少对采样设备的需求,有效减少采样数据,节省存储空间,降低传输成本。当基于 CS 的 SORS 成像系统面临舰船检测任务时,需要的结果是舰船的位置属性。图 1(a)显示了基于 CS 的 SORS 成像系统执行船舶检测任务的流程。首先,光学系统对场景进行压缩采样获得 CS 测量值。然后,图像重建算法^[12-14]作用于测量值得到重建的原始场景。最后,基于图像的舰船检测算法^[15-17]作用于重建场景得到舰船位置信息。然而,将测量值重建为原始场景的过程计算成本高、内存要求高且耗时。因此,直接对 CS 测量值进行舰船检测可

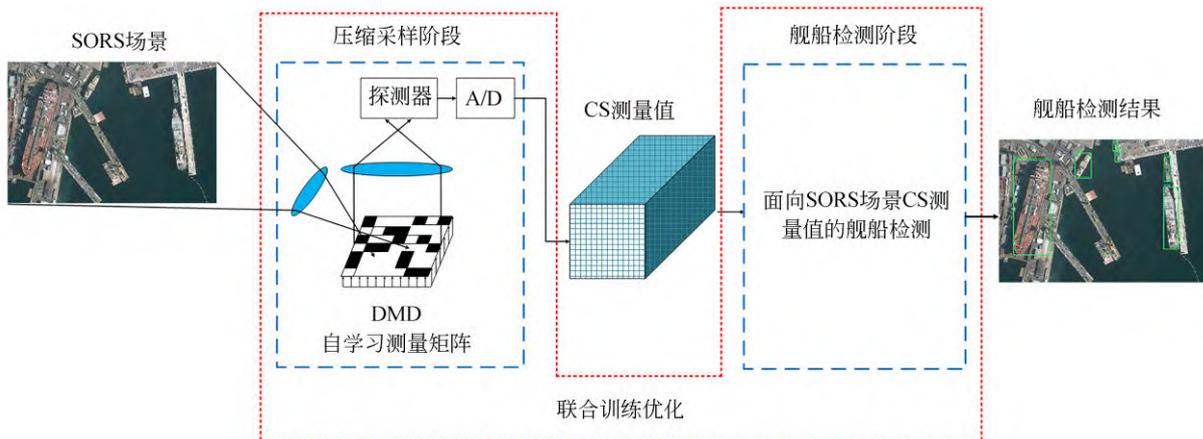
以有效地解决上述问题。图1(b)显示了本文提出的基于CS的SORS成像系统执行舰船检测任务的流程。首先,与图1(a)中的第一步相同,光

学系统对场景进行压缩采样获得测量值。然后,将基于测量值的舰船检测算法直接应用于测量值得到舰船检测结果。



(a) 基于CS的SORS成像系统执行舰船检测任务的常规流程图

(a) Routine pipeline of the CS-based SORS imaging system to perform ship detection tasks



(b) 基于CS的SORS成像系统执行舰船检测任务的创新流程图

(b) Innovation pipeline of the CS-based SORS imaging system to perform ship detection tasks

图1 基于CS的SORS成像系统执行船舶检测任务的流程示意图,其中数字镜像设备(Digital Mirror Device,DMD)表示基于CS的成像系统中的测量矩阵

Fig. 1 Illustration of the pipeline of the CS-based SORS imaging system to perform ship detection tasks, where digital mirror device (DMD) denotes a measurement matrix in the CS-based imaging system

近年来,基于卷积神经网络(Convolutional Neural Network,CNN)的图像舰船检测算法可以有效地学习复杂特征,实现高精度的舰船检测。文献[18]借助多尺度特征金字塔网络,利用RetinaNet来检测SAR图像中的船只,可以更好地检测多尺度舰船。文献[19]采用基于无先验框的目标检测方法,利用CenterNet来检测遥感图像中的舰船。文献[20]通过分辨率归一化制作混合的训练样本数据集,在Faster-R-CNN的框架下构建了一个3层卷积神经网络的舰船检测算法,取得了较好的检测效果。文献[21]通过模

型剪枝,利用剪枝后的YOLOv3框架对卫星图像进行船只检测,取得了较好的实时检测效果。然而,这些基于CNN的方法都用于提高场景舰船检测的准确性,而不能应用于CS测量值的舰船检测。

基于CNN的方法可以有效地处理压缩后的图像数据。Fu等人^[22]提出了一种基于离散余弦变换(Discrete Cosine Transform,DCT)的算法来对图像进行压缩,然后将其输送到神经网络。该方法在减小少量准确率的基础上大大增加了神经网络的训练速度。Torfasson等人^[23]设计了

一个编解码神经网络来学习 RGB 图像压缩域中的目标属性。Benjamin Deguerre 等人^[24]使用 8×8 内核和 8 步长的卷积层来保持 DCT 块的一致性,随后连接到改进的 SSD 网络,以实现压缩域图像的快速图像处理。然而,这些基于 CNN 的方法似乎是对压缩域进行图像处理,但实际上,它们仍然使用原始图像进行图像处理。

本文在基于 CS 的 SORS 成像系统的基础上,提出了应用于 SORS 场景 CS 测量值的舰船检测模型——基于压缩感知和改进 YOLO (Compressive Sensing and Improved You Only Look Once, CS-IM-YOLO) 的测量值舰船检测算法。CS-IM-YOLO 首先利用卷积测量层模拟 CS

成像系统的压缩采样过程从而获得全图测量值,然后利用改进的主干网络提取测量值的特征信息,最后利用特征金字塔网络加强特征提取,获得舰船目标的位置信息。

2 CS 测量值舰船检测算法

本文提出的 CS-IM-YOLO 算法可以用于 SORS 场景 CS 测量值的舰船检测,CS-IM-YOLO 的总体组成如图 2 所示,网络由三部分组成:场景压缩采样部分,测量值特征提取部分和多特征层特征预测部分。本章首先是模型整体概述,然后是模型中三个关键组件的详细实现,最后介绍了整体框架的联合训练优化。

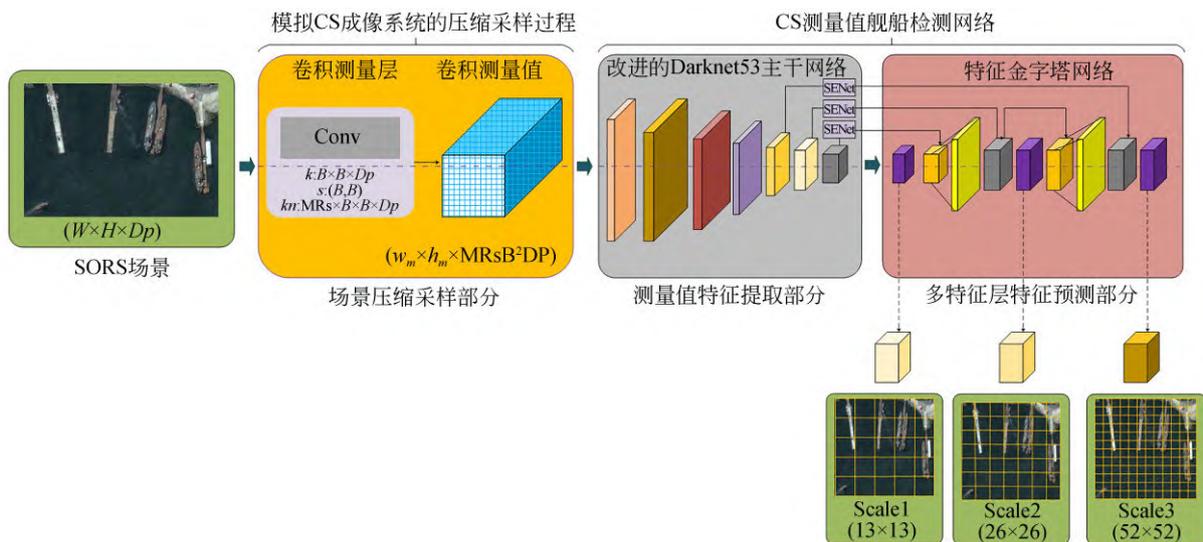


图 2 CS-IM-YOLO 的总体框架示意图,包括三部分:CML, IDBN 和 FPN

Fig. 2 Illustration of the overall framework of CS-IM-YOLO, including three parts: CML, IDBN and FPN

2.1 CS-IM-YOLO 概述

给定 SORS 场景 X , 首先卷积测量层 (Convolutional Measurement Layer, CML) 对场景分块压缩采样获得全图 CS 测量值 Y , 该过程模拟了基于 CS 的 SORS 成像系统的压缩采样过程。该过程可以表示为:

$$Y = CML(X), \quad (1)$$

其中, $CML(\bullet)$ 表示压缩采样过程。然后, 给定获取的全图测量值 Y , 改进的 Darknet53 主干网络 (Improved Darknet53 Backbone Network, IDBN) 对测量值进行特征提取得到舰船特征信息, 特征金字塔网络 (Feature Pyramid Network, FPN) 进

一步强化特征提取并且融合浅层、中层和高层特征信息, 进而完成舰船目标的位置预测。主干网络提取测量值多层特征信息 $feat1'$, $feat2'$ 和 $feat3'$ 的过程可以表示为:

$$feat1', feat2', feat3' = IDBN(Y), \quad (2)$$

其中: $IDBN(\bullet)$ 表示特征提取过程。FPN 输出的特征层 $y1$, $y2$ 和 $y3$ 分别为 $13 \times 13 \times 18$, $26 \times 26 \times 18$ 和 $52 \times 52 \times 18$, 通道数 18 表示采用 3 种先验框预测的 3 个预测框信息。FPN 的加强特征提取过程可以表示为:

$$y3, y2, y1 = FPN(feat1', feat2', feat3'), \quad (3)$$

其中, $FPN(\cdot)$ 表示加强特征提取过程。利用非极大值抑制(Non Maximum Suppression, NMS)算法去除多余预测框, 获得得分最高的舰船位置预测框。

在整体框架联合训练后, 优化后的 CML 权重值为基于 CS 的 SORS 成像系统中的测量矩阵。IDBN 和 FPN 组成场景 CS 测量值的舰船检测模型。

2.2 场景压缩采样部分

CS 测量值舰船检测的前提是测量值的获取。在基于 CS 的 SORS 成像系统中, 通过压缩采样过程完成数据采集。CS 理论中传统压缩采样问题首先场景需要满足稀疏条件, 然后采样矩阵需要满足约束等距性质(Restricted Isometry Property, RIP)。现有的采样矩阵都是信号独立的, 没有考虑被采样信号的特性从而不能使测量值中保留更多的信息。而基于 CNN 的方法可以更加有效地解决 CS 中的压缩采样问题。

为了模拟这个过程, 参考压缩感知重建相关工作^[25]中的压缩采样过程, 本文采用一个无偏置无激活函数的 CML 来测量场景。训练后 CML 中卷积核的权重值为自学习测量矩阵(Learned Measurement Matrix, LMM)^[25, 26], 即 CS 中压缩采样过程的测量矩阵。

压缩采样过程如图 3 所示。在图 3(b)中, 场景首先被划分为非重叠的场景块 $w_m \times h_m =$

$\frac{W}{B} \times \frac{H}{B}$ 。其中, W, H 和 Dp 分别是场景的宽、高和通道数($Dp = 3$), B 是场景的分块尺寸。在图 3(a)中, 每个场景块可以表示为 $x_i^{B^2 Dp \times 1}$, 其中 i 是场景块的标签($i = 1, 2, \dots, w_m h_m$), 使用尺寸为 $MRs B^2 Dp \times B^2 Dp$ 的 CS 测量矩阵 Φ_{CML} 来获取场景块 $x_i^{B^2 Dp \times 1}$ 的 CS 测量值 $y_i^{MRs B^2 Dp \times 1}$ (MRs 是 CS 技术中的测量率, 即基于 CS 的 SORS 成像系统获得的压缩测量数据量与原始场景数据量的比值)。这个过程可以表示为:

$$y_i^{MRs B^2 Dp \times 1} = \Phi_{CML}^{MRs B^2 Dp \times B^2 Dp} x_i^{B^2 Dp \times 1}. \quad (4)$$

由于测量矩阵 Φ_{CML} 中的列数为 $B \times B \times Dp$, 所以 CML 中每个卷积核的尺寸也为 $B \times B \times Dp$, 因此每个卷积核输出一个测量值。由于测量矩阵 Φ_{CML} 中的行数为 $MRs \times B \times B \times Dp$, 所以 CML 中需要 $MRs \times B \times B \times Dp$ 个卷积核来获得 $MRs \times B \times B \times Dp$ 个测量值。此外, CML 中没有偏置值和激活函数, CML 的步幅尺寸设置为 $B \times B$ 实现非重叠采样。如图 3(b)所示, 每个场景块的输出由 $MRs \times B \times B \times Dp$ 个特征映射组成。场景压缩采样过程可以表示为:

$$Y = CML(X, W_{cml}) = W_{cml} * X, \quad (5)$$

其中: $*$ 表示卷积运算; X 表示场景; W_{cml} 表示 CML 的权重值, 即 CS 中的 LMM; Y 表示场景的 CS 测量值。

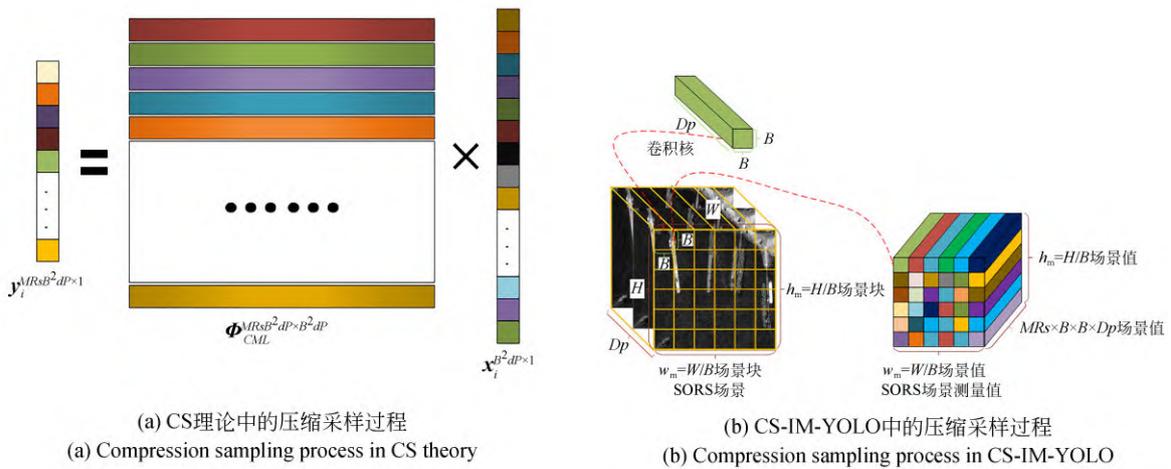


图 3 压缩采样过程的示意图
Fig. 3 Illustration of compression sampling process

因为卷积核的数量需要满足不等式 $MRs \times B \times B \times Dp \geq 1$, 所以需要 $MRs \geq 1/12$ 。为了避免在单个 MR 中场景压缩采样的偶然性, 在 CS 的研究工作^[27-28]中将 MRs 直接取为 25%, 10%, 4% 和 1%。因此, 本文设置的步幅和 MRs 之间的对应关系如表 1。

表 1 步幅和 MRs 之间的对应关系取值

Tab. 1 Relationship between stride and MRs

$B \times B$	MRs
2×2	25% 或 10%

2.3 测量值特征提取部分

由于 CS 测量值的数据量远低于其对应的原始场景, 因此测量值的特征提取网络需要提取高质量的浅层、中层和高层特征信息。本文参考相关工作^[29]中的特征提取网络, 采用了一种现有的框架结构 Darknet53。Darknet53 中的残差网络能够通过增加网络深度来提高准确率, 其内部的残差块使用了跳跃连接, 缓解了深度 CNN 中增加深度带来的梯度消失问题。

2.3.1 改进的 Darknet53 主干网络

改进的 Darknet53 的结构如图 4 所示。其中, Conv 表示卷积层, ResN 表示 N 个残差块的集合, ResN 的特性是在特征图尺寸减半的情况下通道数加倍。CS 测量值 Y 可以表示为

$Y \in R^{w_m \times h_m \times MRs B^2 Dp}$ ($w_m \times h_m$ 是测量值的尺寸), 首先尺寸为 3×3 、步长为 1 的卷积层对测量值进行卷积运算得到通道数为 32 的特征图。然后不断的通过 1×1 卷积和 3×3 卷积以及残差边的叠加得到浅层、中层和高层的舰船特征信息 $feat1'$, $feat2'$ 和 $feat3'$ 。测量值特征提取过程可以表示为:

$$feat1', feat2', feat3' = IDBN(Y, W_{bb+se}), \quad (6)$$

其中, W_{bb+se} 表示 IDBN 的网络参数。

改进的 Darknet53 网络中除了首个卷积层外其他的卷积层都采用特有的 DarknetConv2D 结构, 即每次卷积都进行 BatchNormalization 标准化与 LeakyReLU 非线性运算。LeakyReLU 非线性运算的数学表达式如式 (7) 所示, 超参数 a_i 取 0.01。

$$y_i = \begin{cases} x_i, & \text{if } x_i \geq 0 \\ \frac{x_i}{a_i}, & \text{if } x_i < 0 \end{cases} \quad (7)$$

尽管 Darknet53 网络可以从测量值中提取多层特征信息, 但是它无法从测量值中提取到舰船的关键信息。SENet (Squeeze-and-Excitation Networks, SENet) 模块可以在特征提取过程中将更多注意力放在舰船区域, 以获取有关舰船的关键特征信息, 并且抑制其他无用信息。本文将 SENet 添加到 Darknet53 网络中, 得到改进的 Darknet53 主干网络。

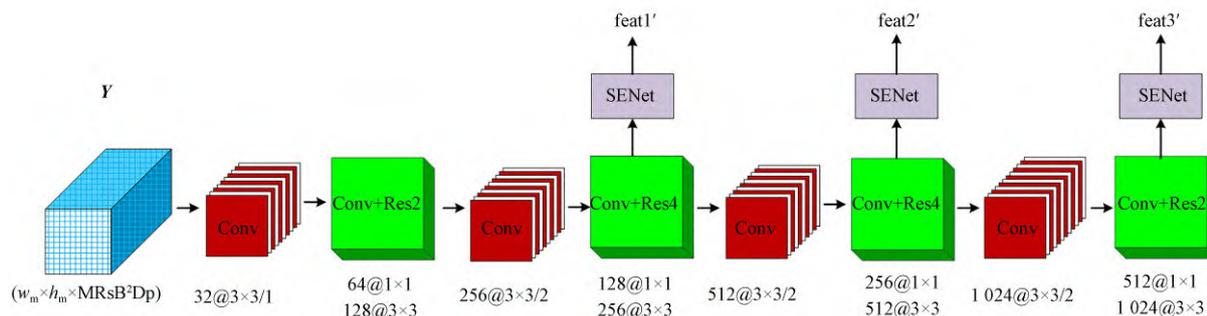


图 4 改进的 Darknet53 主干网络结构示意图

Fig. 4 Illustration of improved Darknet53 backbone network

2.3.2 SENet 模块

SENet 模块添加到 Darknet53 的位置如图 4 所示, 即 SENet 添加到浅层、中层和高层特征的输出部分。SENet 模块的特征处理过程如图 5 所示, MaxP 表示 max pool 层, AvgP 表示 avg pool

层, Sig 表示 sigmoid 函数。输入该模块的特征可以表示为 $F_{int} \in R^{\left(\frac{W}{s_c}\right) \times \left(\frac{H}{s_c}\right) \times C_{se}}$, 其中 $W \times H$ 是场景的尺寸, C_{se} 是 F_{int} 的特征通道数 ($se = 1, 2, 3, C_1 = 256, C_2 = 512, C_3 = 1024$), s_c 对应输入场景的下

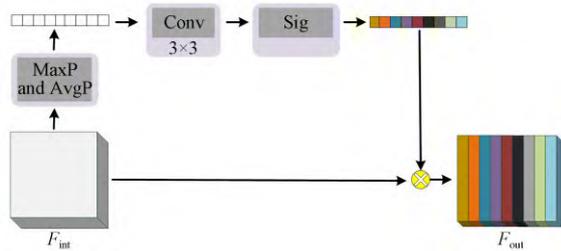


图 5 SENet 的结构示意图
Fig. 5 Illustration of SENet

采样率 ($se = 1, 2, 3, s_1 = 8, s_2 = 16, s_3 = 32$)。首先,采用 MaxP 和 AvgP 沿通道轴生成一维特征。然后,采用 Conv 和 Sig 来获得特征中元素特性。最后,将得到的各个元素特性乘以输入特征。SENet 的运算过程可以表示为:

$$F_{out} = Sig(Conv_{3 \times 3}([MPool(F_{int}); APool(F_{int})])) \times F_{int} \quad (8)$$

其中: \times 表示乘法运算; $MPool(\cdot)$ 和 $APool(\cdot)$ 分别表示最大池化运算和平均池化运算; $Conv_{3 \times 3}(\cdot)$ 表示 3×3 的卷积运算; $Sig(\cdot)$ 表示 sigmoid 非线性运算。

2.4 多特征层特征预测部分

基于无先验框的目标检测模型有很多研究工作^[30-31],但是基于先验框的目标检测模型才是主流算法,而且基于无先验框的目标检测模型并没有明显的检测优势^[32]。因此,CS-IM-YOLO 采用基于先验框的模型来预测舰船的位置信息。

2.4.1 基于特征金字塔的加强特征提取

为了采用基于先验框的模型预测舰船的中心位置信息和宽高位置信息,本文利用特征金字塔网络来加强特征提取。由于待检测舰船的目标尺寸差异很大,包括大型货轮、中型船只和小型巡洋舰,FPN 会提取 3 个尺度的特征层。FPN 的结构如图 6 所示,其中 ConvSet 表示卷积层的集合,Upsam 表示上采样。来自 IDBN 的浅层、中层和高层的特征信息 $feat1', feat2'$ 和 $feat3'$ 可以表示为 $F_{feat} \in R^{\left(\frac{W}{s_a}\right) \times \left(\frac{H}{s_a}\right) \times C_a}$, 其中 C_a 是 F_{feat} 的特征通道数 ($a = 1, 2, 3, C_1 = 256, C_2 = 512, C_3 = 1024$)。 s_a 对应输入场景的下采样率 ($s_1 = 8, s_2 = 16, s_3 = 32$)。通过 FPN 网络完成上采样和特征信息融合得到输出特征层 y_3, y_2 和 y_1 。图 6 展示了 3 种尺度特征层的前图感受野: $13 \times 13, 26 \times$

$26, 52 \times 52$ 。加强特征提取的过程可以表示为:

$$y_3, y_2, y_1 = FPN([feat1', feat2', feat3'], W_{fpn}), \quad (9)$$

其中, W_{fpn} 表示 FPN 的网络参数。

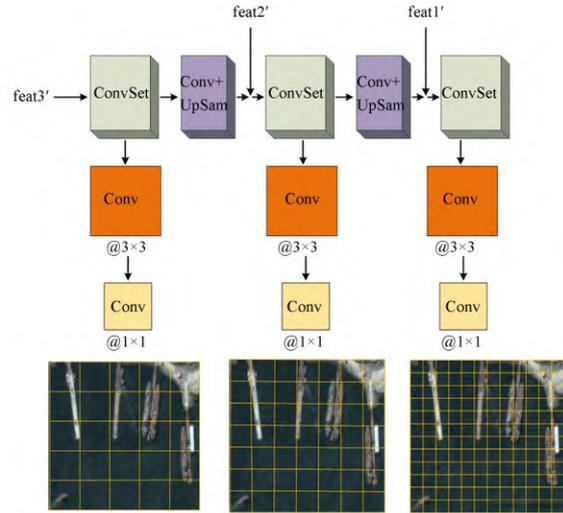


图 6 FPN 的结构示意图
Fig. 6 Illustration of FPN

2.4.2 多特征层位置信息预测

对于输出特征层 y_1, y_2 和 y_3 , 每个特征层存在 3 种尺寸的先验框。先验框的大小和形状是通过 k-means 算法在训练集上获得, 本文获得的 3 种尺度的 9 个先验框分别为: $(20, 29), (40, 70), (99, 30), (20, 147), (123, 67), (51, 170), (96, 127), (96, 247)$ 和 $(178, 166)$ 。对于特征层 y_3, y_2 和 y_1 , 每个网格单元 (y_1 具有 169 个网格单元, y_2 具有 676 个网格单元, y_3 具有 2704 个网格单元) 会预测 3 个预测框的信息, 预测信息包括预测框的中心坐标 (t_x, t_y) , 宽度和高度 (t_w, t_h) , 舰船的置信度和类别概率 (c, p) 。预测目标绝对位置 (b_x, b_y, b_w, b_h) 的计算公式如式 (10) ~ 式 (13) 所示:

$$b_x = \sigma(t_x) + c_x, \quad (10)$$

$$b_y = \sigma(t_y) + c_y, \quad (11)$$

$$b_w = p_w \times \exp(t_w), \quad (12)$$

$$b_h = p_h \times \exp(t_h), \quad (13)$$

其中: c_x 和 c_y 表示网格单元左上角点的坐标; p_w 和 p_h 分别表示先验框的宽度和高度; $\exp(\cdot)$ 表示指数运算。

2.5 CS-IM-YOLO 联合训练优化

由于联合训练优化在测量值舰船检测算法中起着至关重要的作用,本文通过学习模型中的所有参数来训练 CML 和测量值舰船检测网络。模型中所有参数的集合可以表示为 $\Theta = \{W_{cml}, W_{bb+se}, W_{fpn}\}$,而联合训练的过程就是获得

最优的网络参数。如图 7 所示,黑色箭头表示压缩采样部分和测量值舰船检测部分的联合训练过程,红色箭头表示测量值舰船检测的测试过程。首先,训练好的 CML 对 SORS 场景进行压缩采样得到测量值,然后测量值舰船检测网络提取测量值中的舰船位置信息(彩图见期刊电子版)。

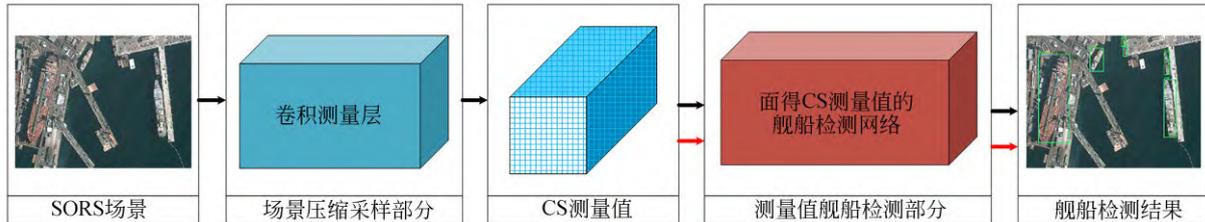


图 7 CS-IM-YOLO 联合优化过程示意图

Fig. 7 Illustration of joint optimization process of CS-IM-YOLO

3 实验与结果分析

本节通过实验来验证 CS-IM-YOLO 应用于 HSR2016 数据集^[33]中 SORS 场景 CS 测量值舰船检测的准确率。

3.1 数据集

HRSC2016 数据集中的舰船包括海上舰船和近海舰船,共有 1 680 张图像。数据集分为训练集,验证集和测试集,其中验证集损失值最小时所对应的迭代次数就是最佳训练次数。表 2 列出了训练集,验证集和测试集中的样本数量,分别包含 1 176,168 和 336 张场景。部分数据集图像如图 8 所示。

表 2 数据集的划分

Tab. 2 Dataset partitioning

数据集	场景数量
训练集	1 176
验证集	168
测试集	336

3.2 实验环境

深度学习(Deep Learning, DL)对硬件要求较高,因此 CS-IM-YOLO 采用表 3 中的实验环境。由于实验中场景尺寸不同,在输入网络之前

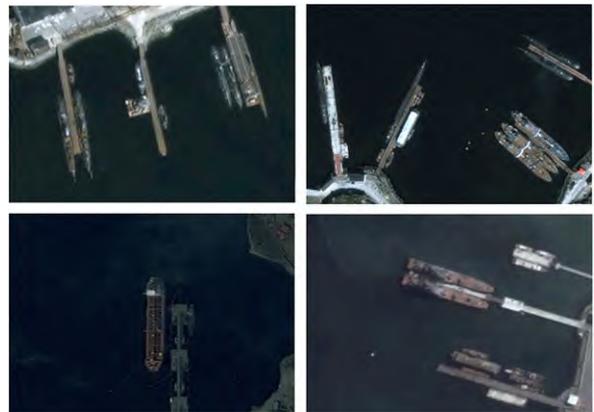


图 8 HRSC2016 部分数据集图像

Fig. 8 Part of HRSC2016 dataset

表 3 实验环境

Tab. 3 Experimental environment

系统	Ubuntu 18.04
RAM	32.0 GB
CPU	4.10 GHz Intel processor
GPU	GeForce RTX 3070, memory 8 G
DL 框架	Pytorch

将数据集图像统一设置为 416×416 。

3.3 实验参数

表 4 显示 CS-IM-YOLO 训练的参数设置。考虑到 GPU 内存 8 G,将批量大小设置为 8。

表4 实验参数

Tab. 4 Training parameters

卷积初始化	标准差为0.001的高斯分布 ^[28]
Optimizer	Adam
Learn rate	10^{-3}
Batch size	8

3.4 评估指标

舰船检测的预测框与舰船真实框之间的重合度由相交比(Intersection over Union, IoU)表示,其计算公式如式(14)所示:

$$IoU = \frac{S \cap}{S \cup}, \quad (14)$$

其中: $S \cap$ 是预测框和真实框重叠区域面积, $S \cup$ 是预测框和真实框的总面积。

如果预测结果与真实值之间的 $IoU > 0.5$,则将其定义为真正的正样本(True Positives, TP)。如果 $IoU < 0.5$,则将其定义为假的正样本(False Positives, FP)。未检测到的真实目标定义为错的负样本(False Negatives, FN)。精度和召回率通常用作评估标准,其计算公式如式(15)~式(16)所示:

$$Precision = \frac{TP}{TP + FP}, \quad (15)$$

$$Recall = \frac{TP}{TP + FN}. \quad (16)$$

然而,由于精度和召回率在数字上是矛盾的,本文添加了F1值和AP值作为评估指标。F1值是精确性和召回率之间不平衡的综合指标。AP值反映了网络性能的整体质量,它定义了一组等距召回率下的平均精度。本文计算了当IoU阈值为0.5时的AP值。F1和AP的计算方法如式(17)~式(18)所示:

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall}, \quad (17)$$

$$AP = \frac{1}{101} \sum_{r \in S} Precision|_{Recall=r}. \quad (18)$$

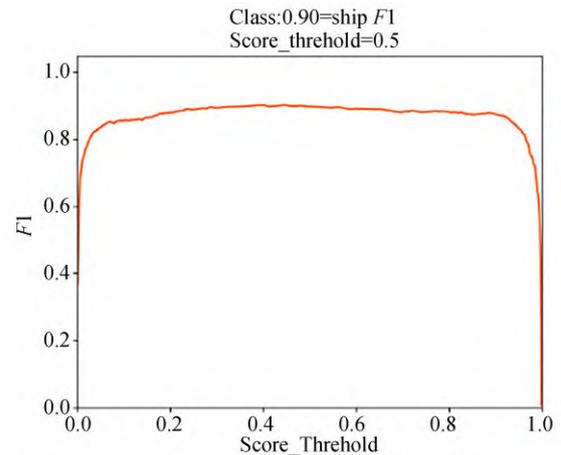
3.5 实验结果

为了测试CS-IM-YOLO对于CS测量值的舰船检测效果,本文通过数据集HRSC2016评测算法性能。表5显示了算法的舰船检测精度率、召回率、F1值和AP值。图10显示了测试集部分场景的测量值舰船检测效果。

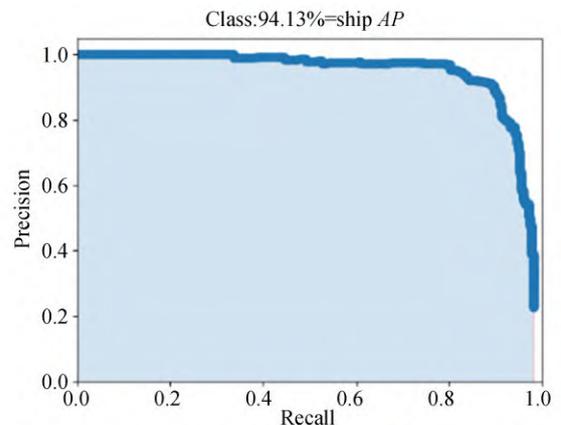
表5 HRSC2016数据集下测量值的舰船检测结果

Tab. 5 Ship detection results on measurements in HRSC2016 dataset

模型	P	R	F1	AP
CS-IM-YOLO	91.60%	87.59%	0.90	94.13%



(a) MRs=25%时CS-IM-YOLO用于CS测量值的F1值曲线
(a) F1 curves of CS-IM-YOLO for CS measurements with MRs=25%



(b) MRs=25%时CS-IM-YOLO用于CS测量值的PR值曲线
(b) PR curves of the CS-IM-YOLO for CS measurements when MRs=25%

图9 MRs=25%时CS-IM-YOLO用于CS测量值的F1曲线和PR曲线

Fig. 9 F1 and PR curves of CS-IM-YOLO for CS measurements with MRs=25%

检测精度方面,CS-IM-YOLO模型得分为91.60%;在召回率方面,CS-IM-YOLO的得分为87.59%。由CS-IM-YOLO模型的精度和召回率可得到它的F1值为0.90。CS-IM-YOLO



(a) 原始场景
(a) Ground truth
(b) MRs=25%时CS-IM-YOLO
对于CS测量值的舰船检测
结果
(b) Ship detection results of CS-
IM-YOLO at MRs=25% for
CS measurements

图 10 测试集部分场景的测量值舰船检测效果

Fig. 10 Ship detection results or CS measurements in some scenes of the test set

模型对于舰船检测的 AP 值为 94.13%。因此, CS-IM-YOLO 可以对场景 CS 测量值进行舰船检测,同时保证检测的高精度。

如 3.2 节所述,CS 测量值的大小与分块压缩采样中的 MR 有关。为了测试在不同采样率下的舰船检测性能,本文测试了 CS-IM-YOLO 在不同 MR 下的舰船检测性能,结果如表 6 所示。此外,通过设置不同的阈值,可以得到 CS-IM-YOLO 在 MRs=25% 和 10% 时的 $F1$ 曲线和 PR 曲线,如图 11 所示。从表 6 中可以看出,CS-IM-YOLO 的舰船检测性能在 MRs=10% 时比 CS-IM-YOLO 在 MRs=25% 时的舰船检测性能差。

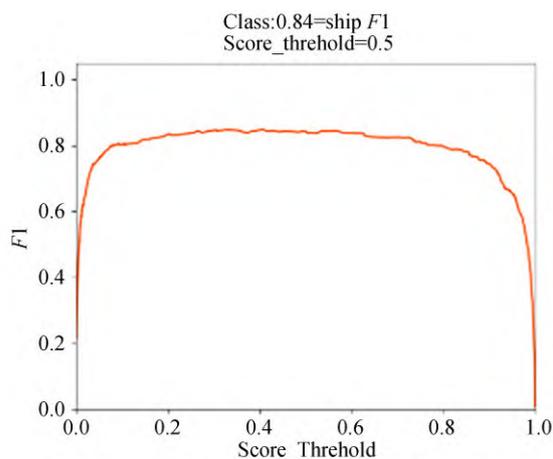
表 6 CS-IM-YOLO 在不同 MRs 下的舰船检测结果

Tab. 6 Ship detection results of CS-IM-YOLO under different MRs

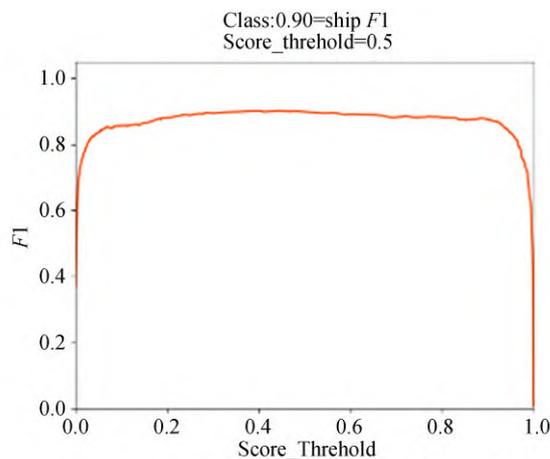
$B \times B$	P	R	$F1$	AP
10%	90.72%	78.47%	0.84	88.57%
25%	91.60%	87.59%	0.90	94.13%

这是因为随着获取的场景数据量减少,测量值中舰船的特征信息减少,从而导致测量值舰船检测的性能下降。

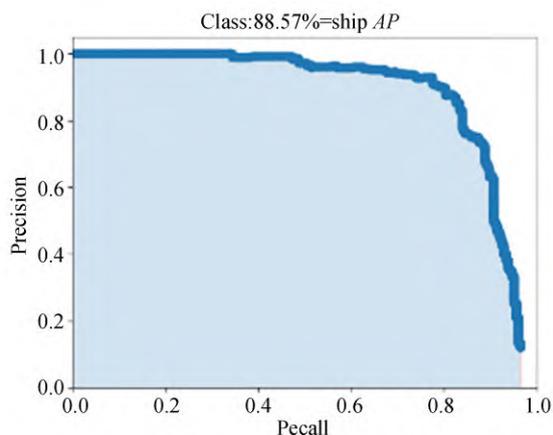
为了评估主干网络中 SENet 模块的功能,我们对 SENet 进行了消融实验,相应的实验结果如表 7 所示。此外,通过设置不同的阈值,可以得到“Darknet53+FPN”和“IDBN+FPN”在 MRs=25% 时的 $F1$ 曲线和 PR 曲线,如图 12 所示。在



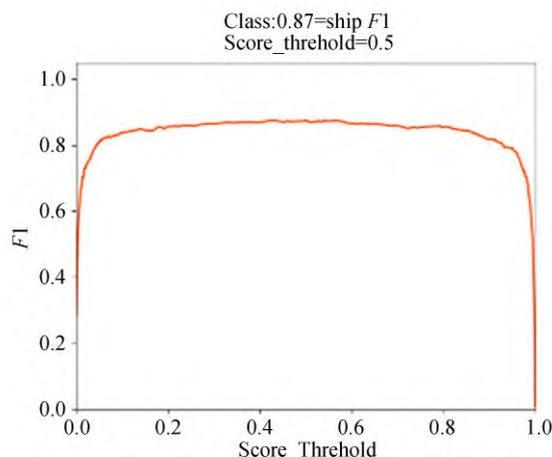
(a) MRs=10%时CS-IM-YOLO用于测量值的 $F1$ 曲线
(a) $F1$ curves of CS-IM-YOLO at MRs=10%



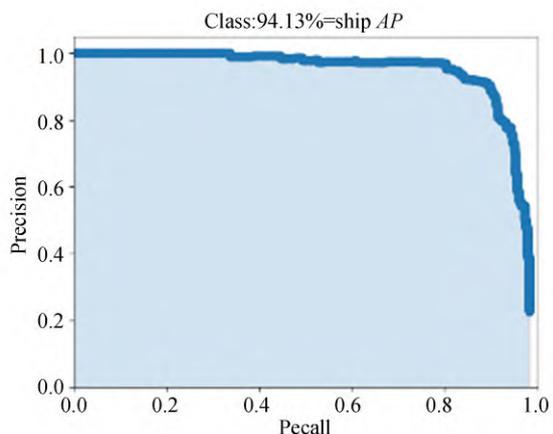
(b) MRs=25%时CS-IM-YOLO用于测量值的 $F1$ 曲线
(b) $F1$ curves of CS-IM-YOLO at MRs=25%



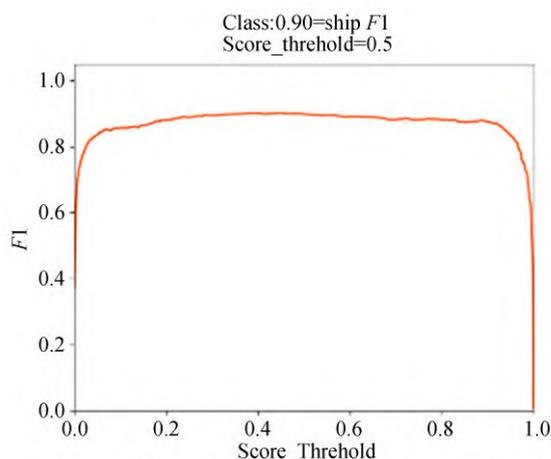
(c) MRs=10%时CS-IM-YOLO用于测量值的PR曲线
(c) PR curves of CS-IM-YOLO at MRs=10%



(a) MRs=25%时“Darknet53+FPN”用于测量值的F1曲线
(a) F1 curves of “Darknet53+FPN” at MRs=25%



(d) MRs=25%时CS-IM-YOLO用于测量值的PR曲线
(d) PR curves of CS-IM-YOLO at MRs=25%



(b) MRs=25%时“IDBN+FPN”用于测量值的F1曲线
(b) F1 curves of “IDBN+FPN” at MRs=25%

图 11 MRs=25% 和 10% 时 CS-IM-YOLO 用于测量值的 F1 曲线和 PR 曲线

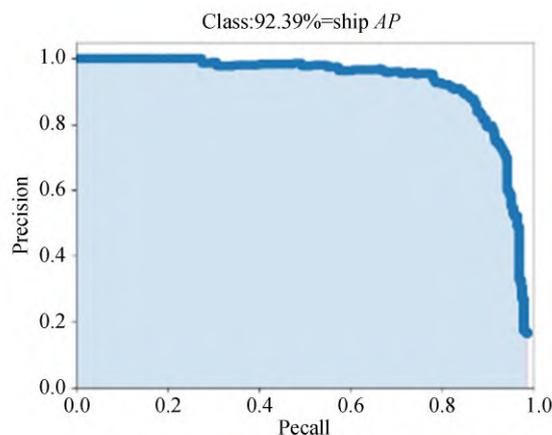
Fig. 11 F1 and PR curves of CS-IM-YOLO for measurements when MRs=25% and 10%

表 7 中,通过对比“Darknet53+FPN”和“IDBN+FPN”的实验结果可以分析 SENet 的性能,从表中可以看到 P 增加了 2.29%, R 增加了 2.19%, $F1$ 值增加了 0.03, AP 值增加了 1.74%。因此,

表 7 在 MRs=25% 时, SORS 场景 CS 测量值舰船检测结果

Tab. 7 Ship detection results on CS measurements of SORS scenes at MRs=25%

模型	P	R	$F1$	AP
Darknet53+FPN	89.31%	85.40%	0.87	92.39%
IDBN+FPN	91.60%	87.59%	0.90	94.13%



(c) MRs=25%时“Darknet53+FPN”用于测量值的PR曲线
(c) PR curves of “Darknet53+FPN” at MRs=25%

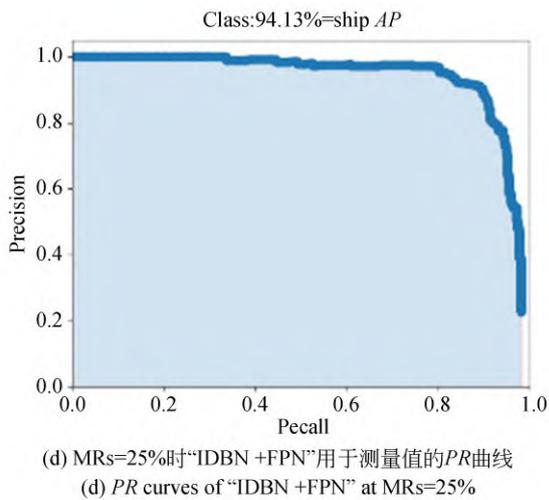


图 12 MRs=25% “Darknet53+FPN” 和 “IDBN +FPN”用于测量值的F1曲线和PR曲线
Fig. 12 F1 and PR curves of “Darknet53+FPN” and “IDBN+FPN” for measurements when MRs=25%

使用SENet模块去改进Darknet53主干网络可以达到更好的检测效果。这是因为SENet模块可以从CS测量值中更好地捕获舰船特征信息。

为了评估模型对SORS场景退化后的适用性,对测试集场景进行退化处理,退化处理分为三种:运动模糊、高斯噪声和运动模糊加高斯噪声。其中,运动模糊的像素偏移值设置为12,偏移方向设置为45°,高斯白噪声的均值设置为0,方差设置为0.01。退化处理后的部分场景如图13~图14所示。本文采用训练后的CS-IM-YOLO模型在MRs=25%时对退化处理的测试集场景进行实验,相应的实验结果如表8所示。对比模型在无退化处理和三种退化处理的实验结果,可以分析场景退化对模型性能的影响。从表

8的第1行和第2行实验结果可以看到P降低了0.84%,R降低了8.76%,F1值降低了0.06,AP值降低了6.74%。从表8的第1行和第3行实验结果可以看到P降低了4.29%,R降低了2.19%,F1值降低了0.04,AP值降低了3.62%。从表8的第1行和第4行实验结果可以看到P降低了6.06%,R降低了9.85%,F1值降低了0.09,AP值降低了7.97%。因此,运动模糊和高斯噪声的场景退化都会降低模型的检测效果,而且两者叠加到一起会更加影响检测效果。但是,两者叠加到一起后的模型舰船检测精度为85.54%,召回率为77.74%,F1值为0.81,和AP值为86.16%,这说明CS-IM-YOLO模型也可以完成对退化场景测量值的舰船检测。

为了评估模型对SORS场景分辨率等级的适用性,本文对测试集场景进行降低分辨率处理,降低分辨率处理分为分辨率/4和分辨率/8。处理后的部分场景如图15~图16所示。采用训练后的CS-IM-YOLO模型在MRs=25%时对处理后的测试集场景进行实验,相应的实验结果如表9所示。对比模型在理想场景和两种降低分辨率处理的实验结果,可以分析场景分辨率等级对模型性能的影响。从表9的第1行和第2行实验结果可以看到P降低了2.54%,R降低了4.38%,F1值降低了0.04,AP值降低了2.25%。从表9的第1行和第3行实验结果可以看到P降低了6.31%,R降低了13.15%,F1值降低了0.11,AP值降低了12.99%。因此,场景分辨率等级的降低会降低模型的检测效果。但是,分辨率/8后的模型舰船检测精度为85.29%,召回率为74.09%,F1值为0.79,和AP值为81.14%,

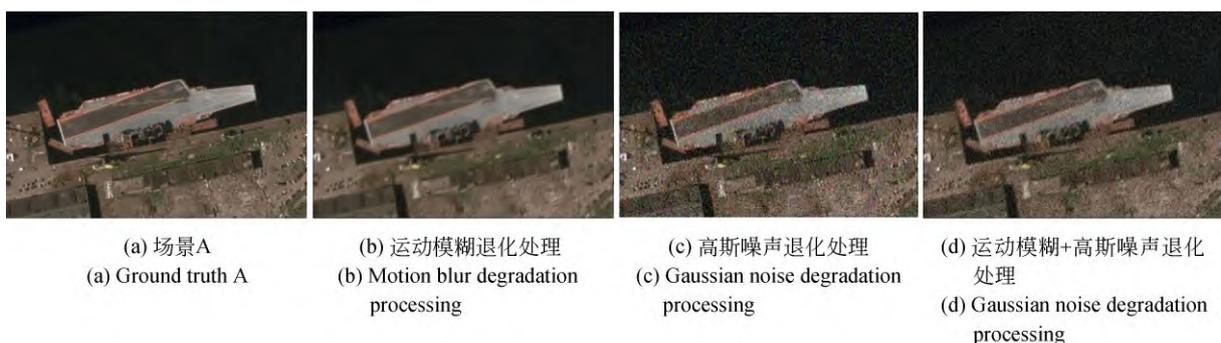


图 13 测试集中场景A的退化处理结果

Fig. 13 Degradation processing results of scene A in the test set

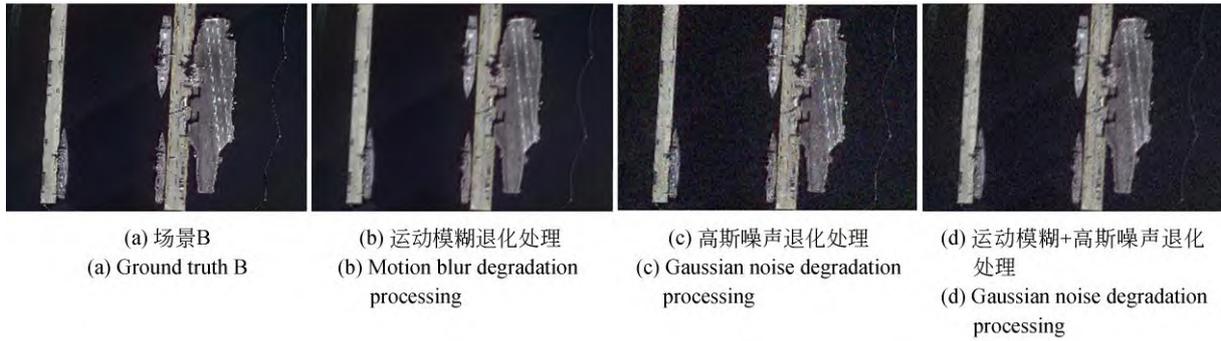


图 14 测试集中场景 B 的退化处理结果

Fig. 14 Degradation processing results of scene B in the test set

表 8 MRs=25% 退化后的 SORS 场景 CS 测量值舰船检测结果

Tab. 8 Ship detection results on CS measurements of degraded SORS scenes at MRs=25%

场景处理	<i>P</i>	<i>R</i>	<i>F1</i>	<i>AP</i>
无退化处理	91.60%	87.59%	0.90	94.13%
运动模糊	90.76%	78.83%	0.84	87.39%
高斯噪声	87.31%	85.40%	0.86	90.51%
运动模糊+高斯噪声	85.54%	77.74%	0.81	86.16%



图 15 测试集中场景 A 的降低分辨率处理结果

Fig. 15 Reduced resolution processing results of scene A in the test set

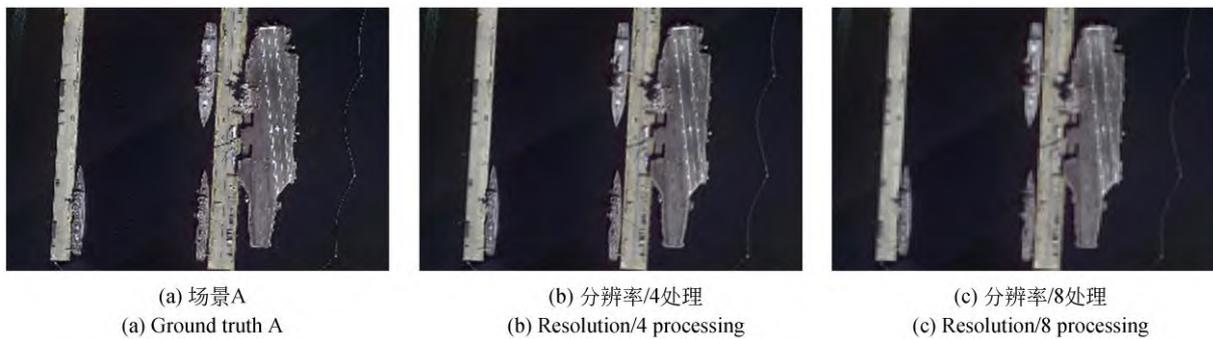


图 16 测试集中场景 B 的降低分辨率处理结果

Fig. 16 Reduced resolution processing results of scene B in the test set

表 9 MRs=25% 时降分辨率后的 SORS 场景 CS 测量值舰船检测结果

Tab. 9 Ship detection results on CS measurements of reduced resolution SORS scenes at MRs=25%

场景处理	P	R	$F1$	AP
分辨率/1	91.60%	87.59%	0.90	94.13%
分辨率/4	89.06%	83.21%	0.86	91.88%
分辨率/8	85.29%	74.09%	0.79	81.14%

这说明 CS-IM-YOLO 模型可以完成低分辨率等级的场景测量值的舰船检测。

4 结 论

为了对 SORS 场景的 CS 测量值进行舰船检测,本文提出了 CS-IM-YOLO 模型,该模型由模拟成像系统分块压缩测量的 CML 和测量值舰船

检测网络组成。在压缩采样过程中,训练完的 CML 直接对场景执行卷积运算得到全图 CS 测量值。对于 CS 测量值的舰船检测,舰船检测网络首先使用改进的 Darknet53 主干网络来提取测量值的舰船特征信息,然后使用特征金字塔网络来强化特征提取同时融合多层特征信息进而预测舰船的位置信息。本文用数据集 HRSC2016 评测算法性能,实验结果表明,该算法对于 SORS 场景测量值舰船检测的检测精度为 91.60%,召回率为 87.59%,F1 值为 0.90,和 AP 值为 94.13%。因此,它可以实现 SORS 场景测量值的高精度舰船检测。并且该算法也可以完成退化场景测量值和低分辨率等级场景测量值的舰船检测。在未来的工作中,将通过基于 CS 的 SORS 成像系统的物理平台获取 CS 测量值,研究物理平台下测量值的获取情况,并对其进行高精度舰船检测。

参考文献:

- [1] 曹佃生,石振华,林冠宇. 机载海洋改进型 Dyson 高光谱成像仪的研制[J]. 光学精密工程, 2017, 25(6): 1403-1409.
CAO D SH, SHI ZH H, LIN G Y. Development of airborne ocean modified Dyson hyperspectral imager[J]. *Opt. Precision Eng.*, 2017, 25(6): 1403-1409. (in Chinese)
- [2] 赵云峰,李夜金,张寅,等. 海洋背景下运动目标的天基红外探测场景生成系统[J]. 光学精密工程, 2017, 25(4): 487-493.
ZHAO Y F, LI Y J, ZHANG Y, et al. A space-based infrared detection scene generation system for moving objects with sea background[J]. *Opt. Precision Eng.*, 2017, 25(4): 487-493. (in Chinese)
- [3] 姜鑫,陈武雄,聂海涛,等. 航空遥感影像的实时舰船目标检测[J]. 光学精密工程, 2020, 28(10): 2360-2369.
JIANG X, CHEN W X, NIE H T, et al. Real-time ship target detection based on aerial remote sensing images[J]. *Opt. Precision Eng.*, 2020, 28(10): 2360-2369. (in Chinese)
- [4] 王慧利,朱明,简春波,等. 光学遥感图像中复杂海背景下的舰船检测[J]. 光学精密工程, 2018, 26(3): 723-732.
WANG H L, ZHU M, LIN CH B, et al. Ship detection of complex sea background in optical remote sensing images[J]. *Opt. Precision Eng.*, 2018, 26(3): 723-732. (in Chinese)
- [5] JAYAWEERA S K. *Signal Processing for Cognitive Radios* [M]. Hoboken: John Wiley & Sons Inc, 2015.
- [6] DONOHO D L. Compressed sensing [J]. *IEEE Transactions on Information Theory*, 2006, 52(4): 1289-1306.
- [7] CANDÈS E J, ROMBERG J, TAO T. Robust uncertainty principles: exact signal reconstruction from highly incomplete frequency information [J]. *IEEE Transactions on Information Theory*, 2006, 52(2): 489-509.
- [8] RICHARD BARANIUK. A lecture on compressive sensing [J]. *IEEE Signal Processing Magazine*, 2007, 24(4): 1-9.
- [9] 刘吉英,朱炬波,严奉霞,等. 基于压缩感知理论的稀疏遥感成像系统设计[J]. 系统工程与电子技术, 2010, 32(8): 1618-1623.
LIU J J, ZHU J B, YAN F X, et al. Design of remote sensing imaging system based on compressive sensing [J]. *Systems Engineering and Electronics*, 2010, 32(8): 1618-1623. (in Chinese)
- [10] ZHANG X D, XIE J N, LI C L, et al. MEMS-

- based super-resolution remote sensing system using compressive sensing[J]. *Optics Communications*, 2018, 426: 410-417.
- [11] LIU J, ZHU J, YAN F, *et al.* Theoretical frameworks of remote sensing systems based on compressive sensing[J]. *Mathematics, Environmental Science*, 2010.
- [12] DU J, XIE X M, WANG C Y, *et al.* Color image reconstruction with perceptual compressive sensing [C]. 2018 24th International Conference on Pattern Recognition (ICPR). August 20-24, 2018, Beijing, China. IEEE, 2018: 1512-1517.
- [13] LOHIT S, KULKARNI K, KERVICHE R, *et al.* Convolutional neural networks for noniterative reconstruction of compressively sensed images[J]. *IEEE Transactions on Computational Imaging*, 2018, 4(3): 326-340.
- [14] YAO H T, DAI F, ZHANG S L, *et al.* DR²-Net: deep Residual Reconstruction Network for image compressive sensing [J]. *Neurocomputing*, 2019, 359(C): 483-493.
- [15] GUO H Y, YANG X, WANG N N, *et al.* A rotational libra R-CNN method for ship detection[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2020, 58(8): 5772-5781.
- [16] WANG Z Q, ZHOU Y, WANG F T, *et al.* SDGH-net: ship detection in optical remote sensing images based on Gaussian heatmap regression [J]. *Remote Sensing*, 2021, 13(3): 499.
- [17] WANG Q, SHEN F Y, CHENG L F, *et al.* Ship detection based on fused features and rebuilt YOLOv3 networks in optical remote-sensing images [J]. *International Journal of Remote Sensing*, 2021, 42(2): 520-536.
- [18] WANG Y Y, WANG C, ZHANG H, *et al.* Automatic ship detection based on RetinaNet using multi-resolution Gaofen-3 imagery [J]. *Remote Sensing*, 2019, 11(5)
- [19] 魏玮, 杨茹, 朱叶. 改进CenterNet的遥感图像目标检测[J]. *计算机工程与应用*, 2021, 57(6): 191-199.
- WEI W, YANG R, ZHU Y. Target detection of improved CenterNet to remote sensing images[J]. *Computer Engineering and Applications*, 2021, 57(6): 191-199. (in Chinese)
- [20] 胡炎, 单子力, 高峰. 基于Faster-RCNN和多分辨率SAR的海上舰船目标检测[J]. *无线电工程*, 2018, 48(2): 96-100.
- HU Y, SHAN Z L, GAO F. Ship detection based on faster-RCNN and multiresolution SAR[J]. *Radio Engineering*, 2018, 48(2): 96-100. (in Chinese)
- [21] 陈科峻, 张叶. 基于YOLO-v3模型压缩的卫星图像船只实时检测[J]. *液晶与显示*, 2020, 35(11): 1168-1176.
- CHEN K J, ZHANG Y. Real-time ship detection in satellite images based on YOLO-v3 model compression [J]. *Chinese Journal of Liquid Crystals and Displays*, 2020, 35(11): 1168-1176. (in Chinese)
- [22] FU D, GUIMARAES G. Using compression to speed up image classification in artificial neural networks [EB/OL]. [2016-12-10]. <https://www.danfu.org/files/CompressionImageClassification.pdf>
- [23] TORFASON R, MENTZER F, AGUSTSSON E, *et al.* Towards image understanding from deep compression without decoding [EB/OL]. 2018: *arXiv: 1803.06131*. <https://arxiv.org/abs/1803.06131>
- [24] DEGUERRE B, CHATELAIN C, GASSO G. Fast object detection in compressed JPEG Images [C]. 2019 *IEEE Intelligent Transportation Systems Conference (ITSC)*. New York: ACM, 2019: 333-338.
- [25] SHI W Z, JIANG F, LIU S H, *et al.* Image compressed sensing using convolutional neural network [J]. *IEEE Transactions on Image Processing*, 2020, 29: 375-388.
- [26] ZHAO Z, XIE X, WANG C, *et al.* ROI-CSNet: Compressive sensing network for ROI-aware image recovery [J]. *Signal Processing: Image Communication*, 2019, 78: 113-124.
- [27] KULKARNI K, LOHIT S, TURAGA P, *et al.* ReconNet: non-iterative reconstruction of images from compressively sensed measurements [C]. 2016 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. June 27-30, 2016, Las Vegas, NV, USA. IEEE, 2016: 449-458.
- [28] YAO H T, DAI F, ZHANG S L, *et al.* DR²-Net: deep Residual Reconstruction Network for image compressive sensing [J]. *Neurocomputing*, 2019, 359(C): 483-493.

- [29] REDMON J, FARHADI A. *YOLOv3: an incremental improvement* [EB/OL]. 2018: *arXiv*: 1804.02767. <https://arxiv.org/abs/1804.02767>
- [30] LIN T Y, GOYAL P, GIRSHICK R, *et al.* Focal Loss for Dense Object Detection [J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2017, 99:2999-3007.
- [31] DUAN K, BAI S, XIE L, *et al.* CenterNet: Object Detection with Keypoint Triplets [EB/OL]. [2019-04-17]. <https://arxiv.org/pdf/1904.08189v1.pdf>.
- [32] WANG Q, SHEN F Y, CHENG L F, *et al.* Ship detection based on fused features and rebuilt YOLOv3 networks in optical remote-sensing images [J]. *International Journal of Remote Sensing*, 2021, 42(2): 520-536.
- [33] LIU Z K, WANG H Z, WENG L B, *et al.* Ship rotated bounding box space for ship extraction from high-resolution optical satellite images with complex backgrounds [J]. *IEEE Geoscience and Remote Sensing Letters*, 2016, 13(8): 1074-1078.

作者简介:



肖术明(1997—),男,山东潍坊人,博士研究生,2019年于东北农业大学获得学士学位,主要从事计算机视觉,压缩感知,机器学习方面的研究。E-mail: 15636041235@163.com

通讯作者:



张叶(1981—),女,吉林长春人,研究员,博士,2003年于吉林大学获得学士学位,2008年于长春光机所获得博士学位,主要从事计算机视觉,模式识别,机器学习等技术研究。E-mail: yolanda@spirits.ai