

文章编号: 2097-1974(2025)06-0046-07

DOI: 10.7654/j.issn.2097-1974.20250607

# 基于多级网络的复杂场景遥感船舶检测方法

吴虞霖, 丛龙剑, 贺韬, 韦海萍, 赵越  
(北京航天自动控制研究所, 北京, 100854)

**摘要:** 复杂场景下遥感图像中船舶目标尺度多变, 特别是关键部位的像素占比极小, 直接检测易受背景噪声干扰, 导致船舶关键部位检测精度与鲁棒性不足。提出一种基于多级网络的分级检测方法 (Multi-level Detection Network, MDNet)。MDNet的第一级网络在Cascade R-CNN基础上, 融合全局上下文模块以增强场景判别能力, 并采用可变形卷积头以适应目标几何形态, 实现船舶的精准粗定位。经自动裁剪与伽马校正增强后, 第二级网络利用双重注意力机制, 聚焦于局部图像的微弱特征, 完成关键部位的精细识别。试验表明, 该方法能够有效滤除复杂背景噪声, 聚焦于关键区域的有效特征, 关键部位检测平均精度与直接检测相比实现显著提升。

**关键词:** 遥感图像; 卷积神经网络; 船舶检测; 关键部位检测; 分级检测

中图分类号: TP751; U675.79

文献标识码: A

## A Multi-level Network-based Method for Ship Detection in Complex Remote Sensing Scenes

WU Yulin, CONG Longjian, HE Tao, WEI Haiping, ZHAO Yue  
(Beijing Aerospace Automatic Control Institute, Beijing, 100854)

**Abstract:** In remote sensing images of complex scenes, ships exhibit significant scale variations. In particular, their key regions are represented by only a few pixels, making direct detection methods susceptible to background noise interference, which results in insufficient accuracy and robustness. To address these challenges, a hierarchical detection method based on a Multi-level Detection Network (MDNet) is proposed. In the first stage, which is built upon Cascade R-CNN, a global context module is integrated to enhance scene discrimination capability. Furthermore, deformable convolutional heads are employed to adapt to the geometric variations of objects, through which precise coarse localization of ships is achieved. Following automated cropping and enhancement via Gamma Correction, a dual attention mechanism is utilized in the second stage to focus on the weak features within local image patches, whereby fine-grained identification of the key regions is performed. Through this method, complex background noise can be effectively filtered, and salient features in key regions can be focused on. A significant improvement in average precision is thus achieved compared to direct detection methods.

**Keywords:** remote sensing images; convolutional neural network; ship detection; key regions detection; hierarchical detection

### 0 引言

随着对地观测技术的飞速发展, 高分辨率遥感图像已在海洋监视、港口管理、海事安全等领域发挥着越来越重要的作用。这些应用中, 对遥感图像中的船舶进行快速、准确的检测与识别至关重要<sup>[1]</sup>。近年来, 基于深度学习的计算机视觉技术, 特别是卷积神经网络, 在遥感图像目标检测领域取得了显著成功, 但复杂场景遥感图像中的船舶检测仍面临诸多挑战<sup>[2]</sup>。

首先, 遥感图像通常覆盖范围较广, 导致船舶目标在图像中呈现多尺度特性。其次, 复杂的背景环境, 如港口设施、近岸建筑、云层以及海面波浪等, 会产生大量背景噪声, 严重干扰对目标的准确识别<sup>[3]</sup>。更为棘手的是, 对于某些特定应用, 例如船舶类型识别、朝向判断、行为分析等, 不仅需要检测到船舶本身, 还需要定位其关键部位, 如船首、船尾等。这些关键部位在原始遥感图像中通常只占据极小的像素区域 (几十至几百个像素点), 其特征微弱,

极易被背景噪声淹没。

遥感船舶检测是一种典型的多尺度、小目标检测问题，很多学者开展了相关研究。传统检测方法大多基于手工设计的特征，在复杂背景下泛化能力不足；基于深度学习的检测算法，如 Yolo<sup>[4]</sup>、Faster R-CNN<sup>[5]</sup>、Transformer<sup>[6]</sup> 等虽取得了显著进步，但在处理遥感图像尤其是船舶关键部位时仍面临挑战。一方面，遥感图像尺寸巨大，直接处理会导致计算资源消耗极大，且船舶关键部位信噪比极低，容易错检。另一方面，船舶目标具有任意朝向、形态多变的几何特征，传统卷积神经网络固定的感受野难以有效适应<sup>[7]</sup>。

随着智能技术的发展，利用多级、协同的策略解决复杂检测问题被视为一种可行途径<sup>[8]</sup>。相比传统单级方法，多级框架具有目标针对性强、抗干扰能力强、检测精度高等特点。Liu 等<sup>[9]</sup> 提出一种基于聚类的粗到细目标检测框架，首先在降采样图像上进行粗略检测，随后精细检测以定位行人。关系部件感知网络 REPAN<sup>[10]</sup> 旨在探索多部件间的语义关联并提取区分性特征，以部件信息引导遥感复合目标定位。Zhang 等<sup>[11]</sup> 提出一种适用于遥感目标检测的粗到细框架 CoF-Net，主要包含粗到细特征适应与粗到细样本分配，分别致力于逐步增强特征表征能力与筛选更优质的训练样本。虽然多级检测已取得一定进展，但大多集中在自然图像及遥感复合目标上，并且未能针对不同阶段的任务特性进行优化，目前尚未有船舶关键部位应用多级检测的相关研究。本文采用多级检测策略，创新性设计一种能够自动实现“由粗到细”检测流程且各阶段网络具备针对性优化策略的智能检测方法，实现遥感图像中船舶关键部位高精度检测。

### 1 多级检测网络框架设计

#### 1.1 总体框架

由于在光学遥感图像中各类船舶（包括货轮、油轮、集装箱船等）关键部位（如船首、船尾或舰桥）的像素占比极低，直接在整张大尺度图像上进行检测会引入大量无关的海浪、云层阴影、港口设施及陆地背景等噪声干扰，使得模型训练困难、特征学习歧化，最终造成虚警率高、漏检等问题。因此，本文设计了一种基于深度学习的多级协同检测框架，旨在实现从广域海面船舶快速搜索到感兴趣区域内关键部位

精细识别的全流程自动化。该框架专门针对近岸港口、海上航道等典型场景下的复杂背景（如海杂波、云雾遮挡、船舶尾迹、近岸背景干扰等）进行优化，使系统在干扰下不仅能精准定位船舶，还能稳定地检测出其微小关键部位。本文设计的“由粗到细”的多级检测网络的分级检测方法（Multi-level Detection Network, MDNet）将复杂的检测任务分解为大尺度目标搜索、目标区域增强和关键部位精细识别三个自动衔接的子过程，实现端到端检测。

本文所提出的多级检测网络总体框架如图1所示。其核心思想是通过分级处理，逐步降低检测任务的复杂度，并将计算资源聚焦于最具信息量的区域。

该框架的检测流程如下：

a) 第一级粗检测：将整幅大尺度、高分辨率遥感图像输入至第一级检测网络。该网络负责在复杂的全局背景中搜索并定位所有潜在的船舶目标，输出一系列高精度的船舶边界框。

b) 中间处理：框架内的自动化处理模块接收第一级网络输出的边界框坐标。依据该坐标，在原始遥感图像上对每个船舶目标进行图像裁剪，并对裁剪后的图像进行伽马校正特征增强。

c) 第二级精细检测：将经过裁剪和增强的船舶图像切片，输入至第二级检测网络。该网络专注于分析高信噪比的局部图像，以识别并定位其中的微小关键部位。

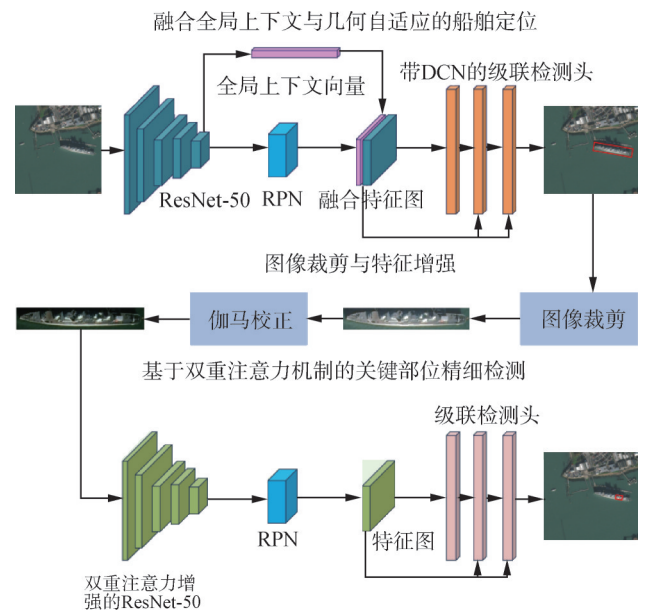


图1 MDNet总体框架

Fig.1 The overall framework of MDNet

MDNet 检测框架将一个困难的、低信噪比的全局检测问题,成功转化为一系列相对简单的、高信噪比的局部检测问题,为实现高精度检测奠定了基础。

## 1.2 融合全局上下文与几何自适应的船舶定位

第一级检测网络是整个框架的核心,其性能直接影响到最终的检测结果。本阶段的检测任务以级联区域卷积神经网络(Cascade Region-based Convolutional Neural Network, Cascade R-CNN)<sup>[12]</sup>作为基础架构。在标准的目标检测流程中,由候选区域生成网络(Region Proposal Network, RPN)产生的大部分候选框,与真实目标的交并比(Intersection over Union, IoU)普遍较低。传统检测器通常设定一个固定的IoU阈值来区分正负样本,但这会导致训练阶段与推理阶段候选框质量分布不匹配的问题。Cascade R-CNN通过级联一系列IoU阈值递增的检测头,对候选框进行渐进式的精炼。每个阶段的检测头都在前一阶段输出的基础上进行训练和预测,从而逐步过滤掉低质量的候选框,并提升高质量候选框的定位精度。

第一阶段的船舶定位面临两方面挑战:其一,需从宏观上理解遥感图像中的复杂场景,以区分远景目标与背景噪声;其二,需在微观上适应目标多变的形态,以实现精准定位。在Cascade R-CNN基础架构之上,本文提出了全局上下文与几何自适应增强的第一级检测网络,全局上下文主要提升网络对复杂场景的宏观理解能力,几何自适应增强策略增强网络对目标的微观适应能力。

### 1.2.1 全局上下文信息融合

由于成像设备分辨率和拍摄高度的限制,遥感图像中的目标存在被复杂场景淹没、目标像素点少和目标分辨率低等问题。此时,如果仅仅分析图像中的目标特征,可能会将复杂背景误认为目标,造成错检,或无法从复杂背景中提取目标特征,造成漏检。遥感图像中的上下文信息丰富,船舶一般出现在水中或岸边,而不会出现在陆地上。针对此特点,本文在骨干网络提取特征后嵌入了全局上下文模块。该模块通过捕获长距离依赖关系,为局部特征的判别提供全局背景信息。

遥感图像分辨率高,随着骨干网络中特征层数的加深,图像不断被下采样,使用低层特征图进行提取全局上下文可能会引入噪声,而高层特征图经过层层采样包含更多的场景信息,更适于提取全局上下文。

由于全局平均池化可以汇总全局空间信息,其可以视为一种结构正则化器,将特征图强制转换为置信度图。因此,全局上下文模块使用全局池化操作提取特征。

全局上下文模块如图2所示,主要包括全局平均池化层及多个卷积层。第一步,采用全局平均池化提取上下文特征,得到代表全局信息的向量。第二步,为了进一步抽象特征表示,依次添加两个 $3 \times 3$ 卷积块和一个 $1 \times 1$ 卷积块。其中,每个卷积块包含一个对应的卷积层和一个ReLU激活层。最后,将全局上下文特征与原始特征直接连接,从而使全局信息融入特征中。全局上下文模块的引入可以提高检测器理解场景的能力,而分离复杂场景特征有助于检测器正确检测目标。




图2 全局上下文模块

Fig.2 Global context module

### 1.2.2 几何自适应回归头的设计

在目标定位任务中,回归头的核心功能是根据提取到的特征,精准地预测目标的边界框。然而,标准卷积在这一环节存在固有局限。标准卷积的卷积核采样格点是固定的矩形,这导致其感受野在几何上是刚性的。当面对遥感图像中形态各异、呈任意旋转角度的船舶目标时,这种固定的感受野与细长、倾斜的目标轮廓之间存在显著的几何错配。这会造成两个问题:一是感受野中会不可避免地包含水面等大量无关的背景像素,造成特征信息混杂;二是可能无法完整覆盖目标的所有关键部分,导致特征提取不充分。

为解决这一难题,本文在Cascade R-CNN的三个级联回归头中,以可变形卷积(Deformable Convolution, DCN)<sup>[13]</sup>取代标准的 $3 \times 3$ 卷积层。DCN的核心思想是赋予卷积操作动态调整其感受野形状的能力,使其能够适应目标的真实几何形态。这一能力通过引入一个并行的、轻量级的偏移量学习分支来实现。该分支与主干卷积层共享相同的输入特征图,其作用是为每个采样点实时地预测其空间偏移量。具体

来说，对于一个标准的  $3 \times 3$  卷积核，该分支会生成一个包含  $3 \times 3 \times 3 = 27$  个通道的输出图。其中，18个通道用于编码9个采样点在  $x$  和  $y$  方向上的二维偏移量  $\Delta p_n$ ，另外9个通道则用于学习每个采样点的调制标量  $\Delta m_n$ 。最终，DCN的计算如式(1)所示：

$$y(p_0) = \sum_{p_n \in \mathfrak{R}} w(p_n) \cdot x(p_0 + p_n + \Delta p_n) \cdot \Delta m_n \quad (1)$$

式中  $y(p_0)$  表示输出特征图在中心位置  $p_0$  处的计算结果； $p_n$  表示卷积核  $R$  中的第  $n$  个采样点相对于中心点的偏移位置； $\mathfrak{R}$  定义了标准卷积核的采样范围或格点； $w(p_n)$  表示卷积核在位置  $p_n$  处的权重值； $x$  表示输入特征图； $\Delta p_n$  为可学习的二维偏移量； $\Delta m_n$  为可学习的调制标量（其值在0到1之间）。对于落在目标核心区域的采样点，网络可以赋予其较高的权重；而对于落在目标边缘或非重要区域的采样点，则可以降低其权重。

将这种几何自适应的能力应用于级联回归的每一级，其优势尤为突出。在初始阶段，面对较为粗糙的候选框，DCN能够捕捉到更准确的目标形状，实现一次大幅度的定位修正。在后续阶段，面对已经较为精准的候选框，DCN则能够进行更加精细的微调，使其感受野完美贴合在目标的边界上。这种渐进式的几何精炼，使得回归头输出的边界框能够最大程度地排除背景干扰、聚焦于目标本身，为后续处理提供了高质量的候选区域。

### 1.3 自动化图像裁剪与特征增强

该模块是连接粗定位阶段与精识别阶段的关键桥梁，承担着信息提纯与数据标准化的关键作用。它接收第一级网络输出的船舶边界框坐标，并自动执行一系列处理，为第二级网络提供最优化的输入数据。

首先是自动化图像裁剪。系统根据每个预测边界框的坐标，在原始高分辨率遥感图像上进行精确裁剪。为确保船体的完整性并保留必要的上下文信息，同时为第一级网络的微小定位误差提供容错空间，裁剪时会在原始边界框的基础上向外扩展一个预设的比例  $\delta$ （本文定义为15%），生成图像切片。

随后，为进一步提升图像质量，系统对裁剪后的图像切片进行特征增强。遥感图像的像素灰度响应往往是非线性的，尤其是在存在阴影和高光的区域，大量细节信息被压缩在很窄的灰度范围内。为解决此问题，本文方法采用伽马校正<sup>[14]</sup>，它是一种简单且计算高效的非线性增强算法。伽马校正通过一个简单的

幂律函数来调整图像的灰度分布。其变换公式如式(2)所示：

$$O(i, j) = c \cdot I(i, j)^\gamma \quad (2)$$

式中  $I(i, j)$  是归一化像素值； $O(i, j)$  是对应的输出像素值； $\gamma$  是控制变换曲线的关键参数。

船舶关键部位的特征部分位于阴影区或船体结构的暗部，因此本文设定  $\gamma=0.5$ 。这种设置能够有效提亮图像的暗部细节，使得原本难以分辨的结构轮廓和纹理变得更加清晰，同时避免了对已经很亮的区域造成过度曝光。通过伽马校正这一简单而有效的预处理，输入到第二级网络的图像具有了更均衡的灰度分布和更丰富的细节信息，为后续的精细识别任务创造了有利条件。

### 1.4 基于双重注意力机制的关键部位精细检测

第二级检测网络的核心任务是在经过处理的船舶图像切片上，实现对船首、船尾、舰桥等预定义关键部位的精准定位。此时，检测任务的性质已从复杂背景中搜索目标变为在局部相似的船舶中辨识微弱特征。

为使网络模型具备聚焦于关键特征的能力，本阶段同样采用 Cascade R-CNN 作为基础检测器。与文献 [15] 类似，在骨干网络 ResNet-50 的每个阶段最后一层的输出中嵌入了卷积注意力模块（Convolutional Block Attention Module, CBAM）<sup>[16]</sup>。CBAM 是一种轻量且高效的注意力机制，如图3所示。CBAM 通过串行方式集成了通道注意力和空间注意力两个子模块，实现了对特征图在两个独立维度上的自适应增强。




图3 卷积注意力模块

Fig.3 Convolutional block attention module

a) 通道注意力模块：该模块评估各特征通道的重要性。它首先对输入特征图  $F$  在空间维度上进行全局平均池化和最大池化，以聚合空间信息，生成两个不同的空间上下文描述符。然后，这两个描述符被送入一个共享权重的多层感知机（Multi-Layer Perceptron, MLP）中，生成通道注意力图  $M_c(F)$ ，并与输

入特征图  $F$  相乘得到输出特征  $F'$ 。该注意力图对每个通道赋予一个权重,用于增强与关键部位相关的特征通道(如边缘、角点、特定纹理的响应),同时抑制不相关的通道。其过程可表示为

$$F' = M_c(F) \otimes F \quad (3)$$

$$M_c(F) = \sigma(\text{MLP}(\text{AvgPool}(F)) + \text{MLP}(\text{MaxPool}(F))) \quad (4)$$

式中  $F$  和  $F'$  分别表示输入和输出特征图;  $M_c(F)$  为通道注意力图;  $\sigma$  表示 Sigmoid 函数; AvgPool 和 MaxPool 分别表示平均池化和最大池化操作。

b) 空间注意力模块: 此模块是定位信息最丰富的空间区域。它将经过通道注意力精炼后的特征图  $F'$  作为输入,在通道维度上进行平均池化和最大池化,生成两个二维的特征描述符。这两个描述符被拼接在一起,再通过一个标准卷积层进行处理,生成空间注意力图  $M_s(F')$ ,并与输入特征图  $F'$  相乘。该注意力图对每个空间位置赋予一个权重,从而增强关键部位所在区域的特征响应,抑制船体中部等平坦背景区域。其过程可表示为

$$F'' = M_s(F') \otimes F' \quad (5)$$

$$M_s(F') = \sigma(f^{7 \times 7}([\text{AvgPool}(F'); \text{MaxPool}(F')])) \quad (6)$$

式中  $F'$  和  $F''$  分别表示输入和输出特征图;  $M_s(F')$  为空间注意力图;  $\sigma$  表示 Sigmoid 函数;  $f^{7 \times 7}$  表示卷积核为  $7 \times 7$  的卷积运算; AvgPool 和 MaxPool 分别表示平均池化和最大池化操作。

通过 CBAM 这种双重注意力机制,第二级网络被赋予了强大的特征选择与增强能力,能够从极易混淆的船体背景中有效地分离并放大关键部位的微弱信号,最终实现高精度的、鲁棒的精细识别。

## 2 试验验证与分析

### 2.1 数据集构建

基于深度学习的目标检测算法,其性能表现高度依赖于大规模、高质量的标注数据集。然而,目前专门针对遥感船舶关键部位这一精细化识别任务的公开数据集尚属空白,现有数据集无法直接满足本文算法的训练与验证需求。

针对此问题,本文基于多个国际知名的遥感图像公开数据集,如 DOTA、HRSC2016 等,通过精心筛选其中包含各类清晰船舶目标的图像,构建了一个名为 RS-ShipKP 的自定义遥感船舶关键部位检测数据集。数据集共包含 1 689 幅图片,其中 2/3 划分为训练集,1/3 作为测试集。标注过程中,为确保后续算法

的兼容性与评测的标准化,标注格式与 DOTA 数据集格式一致。每个船舶目标首先用旋转边界框进行标注;在此基础上,进一步对船首、船尾或舰桥中心等核心关键部位以坐标点的形式进行了精细化标注,每个船舶仅标注一个关键部位。

### 2.2 模型训练

试验环境均为 Ubuntu 18.04 操作系统,软件环境为 Python 3.7.2、CUDA 10.1,深度学习框架采用 pytorch 1.5.1。试验基于开源的 MMDetection 目标检测工具箱开发与实现。其中,动量设为 0.9,初始学习率为 0.001,衰减系数为 0.1,衰减周期为 8,共 24 个训练周期。

### 2.3 结果分析

为系统地评估本文所提出多级检测方法的性能,以及各创新模块(全局上下文模块、带 DCN 的级联检测头、双重注意力机制特征提取)对整体性能的贡献,本节进行了一系列消融试验与对比试验。使用平均精度(Average Precision, AP)和单张图片检测时间作为评价指标。各组算法在 RS-ShipKP 测试集上的检测结果对比如表 1 所示。为便于分析,将标准的 Cascade R-CNN 作为基准方法。

表 1 各组算法船舶关键部位检测结果对比  
Tab.1 Comparison of key point detection results

| 方法          | AP/% | 检测时间/ms |
|-------------|------|---------|
| 基准方法        | 79.3 | 66.7    |
| MDNet(无第一级) | 82.4 | 71.4    |
| MDNet(无校正)  | 91.5 | 90.9    |
| MDNet(无第二级) | 80.1 | 66.7    |
| MDNet       | 93.7 | 90.9    |

表 1 结果说明了分级策略的对船舶关键部位检测的优越性。本文提出的 MDNet 模型相较于基准方法,精度提升了 14.4%,效果提升极大。首先,将本文经过优化的网络模块以单级检测的方式直接运行,其性能也远低于采用分级策略的模型。例如,MDNet(无第一级)即直接使用第二级精细化网络进行全局检测的精度为 82.4%,虽优于基准方法,但比完整模型低了 11.3%。这说明单纯提升网络结构的复杂度,不如采用“由粗到细”的策略从根本上降低检测任务的难度。提出的分级策略通过将全局搜索与局部识别解耦,有效过滤了海量背景噪声,可实现高精度检测。其次,缺少伽马校正环节的精度为 91.5%,比 MDNet

低2.2%，这表明对裁剪后的图像进行简单的非线性增强，能有效凸显微弱特征，是实现更高精度的重要环节。

在检测时间方面，本文所提出的分级检测策略由于包含了两个网络的前向传播和中间处理环节，其单张图像的平均检测时间相较于基准方法有所增加。然而，这种约36%的计算时间增长，换来了14.4%的精度提升。在遥感图像解译、海事安全监控等诸多专业应用领域，检测的准确性和可靠性往往是首要考虑的因素。因此，以适度的运算时间为代价，获取模型性能的质变式飞跃，充分证明了本文方法在精度与效率之间取得了平衡，具有很高的实用价值。

为更直观地展现本文方法在真实、复杂场景下的检测性能，图4给出了部分在RS-ShipKP测试集上的典型检测结果。图4中红色框线为本文方法输出的检测结果。




图4 检测结果

Fig.4 Detection results

如图4所示，MDNet在多种具有代表性的复杂场景下均取得了理想的检测效果。在近岸场景中，背景包含陆地、堤岸等多种强干扰元素，本文方法能够理解场景的整体环境，从而准确识别船舶并有效忽略岸上干扰。针对不同方向的旋转船舶，检测结果充分证明了回归头中可变形卷积在处理非轴对齐目标时的几何自适应优势。此外，对于开阔海域中的小尺度目标，传统单级检测器易因特征微弱而漏检，而本文

的分级策略则能有效锁定船舶并聚焦关键部位，实现稳定检测。在集装箱港口这类高密度、强视觉干扰的极端环境下，本方法依然成功地检测到了目标，展示了其优异的抗干扰能力。试验结果表明，本文方法不仅能够精准定位常规目标，在近岸、港口等高密度、强干扰的复杂场景下，以及针对小尺寸和任意朝向的目标时，均表现出优异的检测性能和良好的鲁棒性。

### 3 结论

本文针对复杂场景下遥感图像中船舶关键部位检测的特有挑战，展开了深入研究，并提出了一种基于多级网络的检测方法MDNet。该方法将全局检测问题分解为目标粗定位与关键部位精细识别两个阶段，并对每个阶段的网络进行针对性优化。首先，本文所构建的分级检测框架，通过先定位后识别的策略，有效过滤了海量的背景干扰，极大地提升了待检测区域的信噪比。具体而言，在第一级粗检测网络中，通过融合全局上下文模块与可变形卷积，使网络同时具备了宏观的场景理解能力与微观的几何自适应能力，从而能够输出高质量的候选区域。而在第二级精细检测网络中，通过引入卷积块注意力机制，有效增强了网络对微弱特征的敏感度，实现了对关键部位的精准定位。在自建数据集上进行的大量试验结果表明，本文所提出的完整方法在各项性能指标上均显著优于基准的单级检测方法，尤其在近岸、港口等高密度、强干扰场景下表现出优异的鲁棒性，具有较高的工程应用价值。

### 参 考 文 献

- [1] 廖育荣, 王海宁, 林存宝, 等. 基于深度学习的光学遥感图像目标检测研究进展[J]. 通信学报, 2022, 43(5): 190-203.  
LIAO Yurong, WANG Haining, LIN Cunbao, et al. Research progress of deep learning-based object detection of optical remote sensing image[J]. Journal on Communications, 2022, 43(5): 190-203.
- [2] ZHAO T, WANG Y, LI Z, et al. Ship detection with deep learning in optical remote-sensing images: a survey of challenges and advances[J]. Remote Sensing, 2024, 16(7): 1145.
- [3] ZHANG C, ZHANG X, GAO G, et al. Development and application of ship detection and classification datasets: a review[J]. IEEE Geoscience and Remote Sensing Magazine, 2024, 12(4): 12-45.
- [4] VIJAYAKUMAR A, VAIRAVASUNDARAM S. Yolo-based object detection models: a review and its applications[J]. Multimedia Tools

- and Applications, 2024, 83(35): 83535-83574.
- [5] WU Y, ZHANG K, WANG J, et al. GCWNet: a global context-weaving network for object detection in remote sensing images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022(60): 1-12.
- [6] GAO J, ZHANG Y, GENG X, et al. PE-Transformer: path enhanced transformer for improving underwater object detection[J]. Expert Systems with Applications, 2024(246): 123253.
- [7] ZHANG H, WEN S, WEI Z, et al. High-resolution feature generator for small ship detection in optical remote sensing images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2024(62): 1-11.
- [8] CAO W, XU G, FENG Y, et al. Step-by-step: efficient ship detection in large-scale remote sensing images[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2024 (17): 13426-13438.
- [9] LIU S, XIA T, CHEN X, et al. A dilated convolution-based feature adaptation method for detection of high aspect ratio objects in aerial images[J]. International Journal of Wavelets, Multiresolution and Information Processing, 2024(2): 2350048.
- [10] YUAN S, ZHANG L, DONG R, et al. Relational part-aware learning for complex composite object detection in high-resolution remote sensing images[J]. IEEE Transactions on Cybernetics, 2024, 54(10): 6118-6131.
- [11] ZHANG C, LAM K M, WANG Q. CoF-Net: a progressive coarse-to-fine framework for object detection in remote-sensing imagery[J]. IEEE Transactions on Geoscience and Remote Sensing, 2023(61): 1-17.
- [12] WANG Y, WANG X, HAO R, et al. Metal surface defect detection method based on improved cascade R-CNN[J]. Journal of Computing and Information Science in Engineering, 2024, 24(4): 041002.
- [13] SHI Y, WANG C, XU S, et al. Deformable convolution-guided multi-scale feature learning and fusion for UAV object detection[J]. IEEE Geoscience and Remote Sensing Letters, 2024(21): 1-5.
- [14] 马鑫, 喻春雨, 陈刚, 等. 分区自适应伽马校正的非均匀光照图像增强[J]. 激光与光电子学进展, 2024, 61(14): 383-390.  
MA Xin, YU Chunyu, CHEN Gang, et al. Adaptive gamma correction of subregion for non-uniform illumination image enhancement[J]. Laser & Optoelectronics Progress, 2024, 61(14): 383-390.
- [15] WU Y, ZHANG K, WANG J, et al. CDD-Net: a context-driven detection network for multiclass object detection[J]. IEEE Geoscience and Remote Sensing Letters, 2020(19): 1-5.
- [16] WOO S, PARK J, LEE J Y, et al. Cbam: convolutional block attention module[J]. Springer, Cham, 2018(6): 3-19.

#### 作者简介

吴虞霖 (1992—), 女, 博士, 高级工程师, 主要研究方向为导航、制导与控制。

丛龙剑 (1992—), 男, 高级工程师, 主要研究方向为智能感知与信息处理。

贺 韬 (1986—), 男, 高级工程师, 主要研究方向为控制系统软件开发测试。

韦海萍 (1983—), 女, 博士, 研究员, 主要研究方向为精确制导信息处理、目标与环境特性应用等。

赵 越 (1997—), 女, 工程师, 主要研究方向为导弹制导系统方案设计。