

[引用格式] 陈颖, 周海峰, 郑东强, 等. 基于改进 YOLOv8n 的船舶目标检测算法[J]. 集美大学学报(自然科学版), 2026, 31(2): 176-188. DOI:10.19715/j.jmuzr.2026.02.05.

基于改进 YOLOv8n 的船舶目标检测算法

陈颖^{1,2}, 周海峰^{1,2}, 郑东强³, 张兴杰⁴, 黄金满⁵

- (1. 集美大学轮机工程学院, 福建 厦门 361021; 2. 福建省船舶与海洋工程重点实验室, 福建 厦门 361021;
3. 集美大学海洋装备与机械工程学院, 福建 厦门 361021; 4. 集美大学航海学院, 福建 厦门 361021;
5. 厦门安麦信自动化科技有限公司, 福建 厦门 361001)

[摘要] 为了解决船舶图像目标检测任务中船舶目标尺度多样、背景环境复杂导致的漏检误检等问题, 提出一种用于船舶目标检测的 DSAMPN-YOLOv8n 算法模型。引入动态蛇形卷积 (dynamic snake convolution, DSC) 和无参数注意力机制 (simple parameter-free attention mechanism, SimAM), 提高 YOLOv8n 网络在复杂环境下对检测目标的特征提取和融合能力; 构建多尺度渐近特征金字塔网络 (asymptotic feature pyramid network, AFPN) 实现多尺度特征信息交换, 增强特征融合效果, 提高模型对不同尺度船舶目标的检测能力。使用 Seaships 船舶数据集对改进算法模型进行实验验证, 结果表明, 相较于 YOLOv8n 算法, 优化后的算法 DSAMPN-YOLOv8n 的精确率、召回率和 mAP@0.5 分别提升了 6.0%、6.7%、3.6%, 实验结果验证了改进方法的准确性和有效性。

[关键词] 船舶目标; 目标检测; YOLOv8n; 特征提取; 特征融合

[中图分类号] TP 391.4 [文章编号] 1007-7405(2026)02-0176-13 DOI:10.19715/j.jmuzr.2026.02.05

Ship Target Detection Algorithm Based on Improved YOLOv8n

CHEN Ying^{1,2}, ZHOU Haifeng^{1,2}, ZHENG Dongqiang³, ZHANG Xingjie⁴, HUANG Jinman⁵

(1. School of Marine Engineering, Jimei University, Xiamen 361021, China;

2. Key Laboratory of Shipping and Ocean Engineering of Fujian Province, Xiamen 361021, China;

3. School of Marine Equipment and Mechanical Engineering, Xiamen 361021, China;

4. School of Navigation, Jimei University, Xiamen 361021, China;

5. Xiamen Anmaixin Automation Technology Co., Ltd., Xiamen 361001, China)

Abstract: To address the challenges of missed and false detections in ship image target detection tasks caused by diverse ship target scales and complex background environments, a DSAMPN-YOLOv8n algorithm model for ship target detection was proposed. The model introduces dynamic snake convolution (DSC) and simple parameter-free attention mechanism to enhance the YOLOv8n network's ability to extract and integrate features in complex environments. Additionally, a multi-scale asymptotic feature pyramid network (AFPN) was constructed to facilitate multi-scale feature exchange, improving feature fusion and enhancing the model's capa-

[收稿日期] 2025-01-07

[基金项目] 国家自然科学基金项目 (51179074); 福建省自然科学基金项目 (2021J01839); 集美大学安麦信产学研项目 (S20127)

[通信作者] 周海峰, 博士, 教授, 硕导, 从事智能信息处理、光机电一体化、仿生机理和节能等方向研究, E-mail: zhufeng216@163.com

http://xuebaobangong.jmu.edu.cn/zkb

bility to detect ship targets of different scales. The proposed algorithm model was experimentally validated using the Seaships dataset. Results showed that, in comparing with those from the YOLOv8n algorithm, the optimized DSAMPN-YOLOv8n algorithm achieves improvements in precision, recall, mAP@0.5 by 6.0%, 6.7%, 3.6%, respectively. These findings validate the accuracy and effectiveness of the proposed method.

Keywords: ship targets; object detection; YOLOv8n; feature extraction; feature fusion

0 引言

随着航运业的蓬勃发展, 船舶在海上运输、物流调度、海洋生态保护和海上安全等领域的地位愈加重要。船舶目标检测技术作为计算机视觉与人工智能技术中的一个重要研究方向, 已经成为航运业及海上安全领域研究的热点之一。船舶目标的准确、实时检测, 可为避碰、航线规划、海洋环境监测等提供关键数据支持, 保障航行安全, 提高运输效率, 降低事故风险。然而, 船舶目标检测在实际应用中仍面临许多挑战。首先, 环境的复杂性使得目标检测变得异常困难, 如光照和天气条件不断变化, 海面反射和近岸的多种干扰因素(如漂浮物)影响船舶目标的识别精度; 其次, 船舶目标的多样性与相似性使得目标检测算法容易产生误判; 再次, 实时性也是船舶目标检测面临的难题之一。而现有的目标检测技术也不能完全满足实际应用需求。因此, 研究一种高效、准确检测的算法, 对于提升船舶目标检测的精度和鲁棒性、推动智能船舶发展具有重要意义。

在船舶检测领域, 张炳焱等^[1]在 YOLO (you only look once) 算法中融入 NAM 注意力模块并引入有效交并比损失函数, 提出了 YOLO-FNC 船舶检测方法, 实现模型的轻量化, 提高了模型的检测速度; Wang 等^[2]提出了一种用于 SAR 舰船目标检测的轻量级检测网络, 采用基于 NOFA 算法的网络结构优化算法, 通过网络剪枝技术将实现任务要求的编码转化为轻量级舰船目标检测网络, 满足船舶目标检测任务中检测网络精度和尺寸之间权衡的不同需求。虽然这两种方式都对模型进行了轻量化处理, 但忽略了通道和空间的相互作用, 丢失了特征信息。李毓滦等^[3]基于 YOLOv7 模型, 引入 ConvNext 并加入 Swin-Transformer 模块, 有效增强了模型多尺度特征提取能力, 提高了船舶识别精确率; 刘芬等^[4]在 YOLOv5 算法的基础上, 通过改进锚框算法和边框回归损失函数, 避免了相似船舶目标的误检和漏检; 张阳等^[5]改进 Faster R-CNN 算法, 使用 Transformer 与多尺度融合网络结构作为骨干网络, 引入可变形卷积, 采用 Focal Loss 损失函数, 有效提高了模型的检测性能。这 3 种改进方式都对模型进行了相应模块的创新, 有效提高了检测精度, 但忽略了针对小目标这一点, 容易丢失特征信息。Deng 等^[6]针对小目标易被图像噪声淹没等问题, 提出一种基于合成雾和多尺度加权融合的红外船舶旋转目标检测算法 FMR-YOLO。Hu 等^[7]针对小目标船舶检测性能提升问题, 提出了空间和通道维度的注意力机制, 以自适应地分配不同尺度特征的重要性, 并采用新的损失函数来约束检测步骤, 提高了训练效率和检测精度。

以上方法在图像识别能力和计算速度方面各有优势, 但整体检测效果仍有提升空间。针对小目标检测能力不足和通道-空间信息交互缺乏的问题, 本文提出基于 YOLOv8n 的改进模型 DSAMPN-YOLOv8n, 引入动态蛇形卷积增强船舶边缘结构检测能

力，通过无参数注意力机制优化通道和空间信息交互，结合渐近特征金字塔网络，增强多尺度信息融合，提高小目标检测能力，以确保网络在处理不同大小、不同角度的船舶目标时均具有良好的检测性能。

1 DSAMPN-YOLOv8n 目标检测算法

1.1 YOLOv8n 算法框架

YOLO 算法是由 Redmon 等^[8]提出的，它以全新的检测方式引起了目标检测领域研究者的广泛关注。区别于传统目标检测方法，YOLO 算法先提出候选区域再分类的方式，YOLOv1 将目标检测问题转化为回归问题，通过一个神经网络同时预测图像目标的位置和类别，极大提高了检测的速度。但相较于传统目标检测方法，YOLO 算法存在定位精度低、检测效果不佳等问题。针对定位精度低的问题，Redmon 等^[9]提出了 YOLOv2 目标检测算法，在每个卷积层后加入批量归一化层，引入锚框机制和 Darknet-19 网络结构等改进方式，提升了模型的收敛速度，简化了网络结构，在减少计算量的同时保持算法的检测性能。在此基础上，Redmon 等^[10]采用 Darknet-53 作为主干网络，采用多尺度融合和多尺度预测策略，提出了实时性与准确性兼顾的 YOLOv3 检测算法。此后 YOLO 系列算法不断发展更新，2023 年已更新至 YOLOv8 算法，它继承了 YOLOv3 和 YOLOv5 的核心思想，采用改进后的跨阶段部分融合主干网络作为骨干网络，特征金字塔网络采用路径聚合特征金字塔网络（path aggregation network feature pyramid network，PAN-FPN）。为了满足不同应用场景的需求，YOLOv8 算法被细分为多个版本，包括 YOLOv8n、YOLOv8s、YOLOv8m、YOLOv8l 和 YOLOv8xl。这些版本为适应不同的计算资源和实时性要求，在网络的宽度和深度上有所不同。本文采用 YOLOv8n 算法模型，它具有体积小、计算参数少的特点，能更好满足模型轻量化和实时性的需求。

YOLOv8n 算法的网络结构如图 1 所示。可见，该模型结构主要由输入端、主干网络、颈部网络和输出端 4 部分构成。输入端对输入的图像进行混合增强、空间扰动和颜色扰动等图像增强处理，丰富数据集。对输入图像进行数据处理之后，图像输入主干网络部分，对图像进行特征提取。主干网络部分主要由 C2f 模块、卷积模块和快速空间金字塔池化（spatial pyramid pooling fast，SPPF）模块组成，其中卷积模块由单个卷积结构、二维批量归一化和激活函数构成。YOLOv8 使用 C2f 模块取代了 C3 模块，C2f 模块的设计更加注重计算效率和特征融合，通过通道和空间特征融合提高模型的性能。

相较于 YOLO 系列算法其他网络结构，C2f 模块以残差结构和高效层聚合网络思想为核心，采用跳层连接的方式，实现轻量化，同时提高了计算效率。快速空间金字塔池化模块将多个小尺寸池化核级联代替单个大尺寸池化核，整合多个尺度的特征信息。颈部网络负责多尺度特征融合和增强，采用路径聚合特征金字塔网络结构。特征注意力网络^[11]通过通道注意力和空间注意力机制对输入特征图加权，增强关键特征，提升特征表达能力。路径聚合网络^[12]是一种特征金字塔网络结构，它通过特征图的多尺度融合，有效增强不同尺度的特征表示，提高模型的检测能力。路径聚合特征金字塔网络结构采用自下而上和自上而下的特征融合路径，有效传递特征信息。在检测头结构上采用解耦的

头部来独立处理物体性质、分类和回归任务。解耦头将分类和检测分离，分别提取类别特征和位置特征，这种设计使每个分支能够专注于该分支的任务，有效减少了模型的参数量和计算复杂度，提高了模型的整体准确性。




图 1 YOLOv8n 网络结构

Fig.1 YOLOv8n network structure

本文将动态蛇形卷积引入 C2f 模块，以增强对船舶边缘结构的捕捉能力，同时在颈部网络添加无参数注意力机制，并结合渐进特征金字塔网络，实现多尺度特征的逐步融合。改进算法的网络模块图如图 2 所示。




图 2 DSAMPN-YOLOv8n 算法网络模块

Fig.2 DSAMPN-YOLOv8n algorithm network module

1.2 动态蛇形卷积

目标检测算法主干网络通常采用标准的卷积核来提取特征，这些卷积核适用于边界清晰的采样区域，但在处理不规则图像时却表现出较差的适应性。尤其在船舶图像中，由于存在较大的尺度变化和观测视角引起的检测区域改变，所以传统卷积核难以有效拟合这些形状变化。

动态蛇形卷积是由 Qi 等^[13]提出的一种针对细长管状结构特征与复杂多变的全局形态设计的卷积模块，它是一种动态调整卷积核权重的机制。相较于传统的动态卷积，动态蛇形卷积引入更灵活的蛇形卷积路径，更适合处理具有复杂背景的目标检测任务。标准卷积核分别在 x 轴和 y 轴方向进行直线化处理，变形偏移赋予了卷积核更多的灵活性。为确保感知关注的连续性，本文采用迭代策略使学习感知不至于由于大的变形偏移而扩散。图 3 展示了动态蛇形卷积如何自适应调整感受野，捕捉目标边缘信息。

图 3 中， x 轴、 y 轴方向的变化分别为

$$K_{i\pm c} = \begin{cases} (x_{i+c}, y_{i+c}) = (x_i + c, y_i + \sum_i^{i+c} \Delta y), \\ (x_{i-c}, y_{i-c}) = (x_i - c, y_i + \sum_{i-c}^i \Delta y), \end{cases} \tag{1}$$

$$K_{j\pm c} = \begin{cases} (x_{j+c}, y_{j+c}) = (x_j + \sum_j^{j+c} \Delta x, y_j + c), \\ (x_{j-c}, y_{j-c}) = (x_j + \sum_{j-c}^j \Delta x, y_j - c)。 \end{cases} \tag{2}$$

其中： Δx 和 Δy 均是由网络学习的动态偏移量，可以确保卷积核能够根据局部特征自动调整感受野。非整数位置的特征值使用双线性插值法计算，其计算公式为

$$K = \sum_{K'} B(K', K) \times K', \tag{3}$$

$$B(K, K') = b(K_x, K'_x) \times b(K_y, K'_y)。 \tag{4}$$

其中： K 表示小数位置； K' 表示所有整数空间位置； B 表示双线性插值核。在学习特征的过程中，动态蛇形卷积根据输入数据自动调整卷积核的值，改变卷积核的形状，有效提高网络的特征提取能力。

为了增强对复杂目标形态的适应性，在 C2f 的 Bottleneck 中引入动态蛇形卷积，形成 C2f_DSC 模块。传统的 Bottleneck 采用标准卷积进行特征提取，本文将其中的标准卷



图 3 动态蛇形卷积示意图
Fig.3 Schematic diagram of dynamic snake convolution

积替换为动态蛇形卷积, 使其能自适应调整感受野, 提高边界特征提取能力。

1.3 无参数注意力机制 (SimAM)

在处理序列数据时, 注意力机制允许模型对不同位置的信息进行加权处理, 它是深度学习中常用的一种模块。传统注意力机制通常沿着通道维度或空间维度操作, 生成一维或二维权重。然而, 这些方法仍然具有计算复杂度高、参数量大的问题。无参数注意力机制是由 Yang 等^[14]提出的一种轻量级、无参数的注意力机制, 它可以生成三维权重, 同时实现对通道域和空间域的信息选择 (见图 4)。




图 4 三维无参数注意力机制

Fig.4 Three-dimensional parameter-free attention mechanism

无参数注意力机制的核心在于计算特征图的局部或全局统计信息, 这些统计信息即是注意力权重的基础。具体全局注意力的计算公式为

$$A_c = \frac{1}{HW} \sum_{i=1}^H \sum_{j=1}^W F_{ijc} \tag{5}$$

其中: A_c 表示第 C 通道的注意力权重; F_{ijc} 表示特征图位置 (i,j) 第 C 通道的特征值; H 、 W 分别表示特征图的高度和宽度。

局部注意力权重的计算公式为

$$A_{ij} = \frac{1}{N} \sum_{n=1}^N F_{i+j+n} \tag{6}$$

其中: A_{ij} 表示像素点 (i,j) 的空间注意力权重; N 表示窗口大小; F_{i+j+n} 表示窗口内的特征值。

计算权重图并将其与输入特征图相乘, 应用于特征图的每个区域, 调整特征图的加权值。此过程通常包括空间加权和通道加权, 它们的计算公式分别为

$$F'_{ij} = A_{ij} \times F_{ij}, \tag{7}$$

$$F'_c = A_c \times F_c. \tag{8}$$

其中: F'_{ij} 表示加权后的特征图; A_{ij} 表示注意力权重; F_{ij} 表示特征图; F'_c 表示加权后的通道特征图; A_c 表示每个通道加权系数; F_c 表示通道特征图。

无参数注意力机制通过动态调整特征图的加权来提升模型对关键区域的关注, 它具有计算开销小、易于集成等优点。因此, 本文引入无参数注意力机制模块, 以增强模型对通道域和空间域的信息提取能力。

1.4 渐近特征金字塔网络

渐近特征金字塔网络是由 Yang 等^[15]提出的一种支持非相邻层之间直接交互的网络。传统的特征金字塔网络通常只将相邻层的特征融合，而渐进特征金字塔网络能够直接融合 2 个相邻的低级特征，后续处理逐渐将更高级的特征融合，避免非相邻层之间产生较大的语义差距，促进特征的融合。针对不同层次特征之间的信息矛盾问题，本文引入自适应空间融合，网络先融合底层特征，再融合高级特征，最后在特征融合过程中添加顶级特征。图 5 给出了融合渐进金字塔改进网络结构，其中：黑色箭头表示卷积，红色箭头表示自适应空间融合。




图 5 融合渐进金字塔改进网络结构

Fig.5 Improved network structure with fusion asymptotic pyramid

自适应空间融合阶段的权重计算过程为

$$\mathbf{y}_{ij}^l = \alpha_{ij}^l \cdot \mathbf{x}_{ij}^{1 \rightarrow l} + \beta_{ij}^l \cdot \mathbf{x}_{ij}^{2 \rightarrow l} + \gamma_{ij}^l \cdot \mathbf{x}_{ij}^{3 \rightarrow l}。 \tag{9}$$

其中： $\mathbf{x}_{ij}^{n \rightarrow l}$ 表示从第 n 层到第 l 层的位置 (i, j) 处的特征向量； $\mathbf{y}_{ij}^l$ 表示多级特征融合的结果特征向量； α_{ij}^l 、 β_{ij}^l 和 γ_{ij}^l 分别表示每个特征在不同层的权重，它们受 $\alpha_{ij}^l + \beta_{ij}^l + \gamma_{ij}^l = 1$ 的约束。

2 实验结果与分析

2.1 实验环境和数据集

实验在 Windows 10 专业版操作系统下进行，计算机配置包括 Intel i5-6500 处理器、NVIDIA GeForce RTX 3060 显卡和 24 GB 内存。软件环境为 Python 3.9，使用 torch 1.13.0 版本。

数据集采用 Seaships 数据集^[16]，该数据集内含 7000 张图像，包括集装箱船、渔船、客船、矿砂船、普通货船和散货船 6 类常见的船舶类型（见图 6），能有效测试模型在多样化环境下的分类能力。为确保模型能够更好地进行训练和验证，本文将 Seaships 数据集分为训练集、验证集和测试集，并按照 8:1:1 的比例进行划分，这种分类方式能够有效防止过拟合并确保模型的泛化能力。



图6 船舶数据集
Fig.6 Ship dataset

2.2 评价指标

为了全面评估模型的检测性能，本文采用精确率（ P ）、召回率（ R ）和平均精度均值（mean average precision, mAP）对模型进行检测精度评价。

精确率用于衡量模型预测结果中正确预测的比例，它反映了模型预测的准确性。精确率越高，表明模型的预测结果越准确。精确率的计算公式为

$$P = \frac{t_p}{t_p + f_p} \times 100\%。$$

(10)

其中： t_p 表示正确检测的正样本数量； f_p 表示错误检测的正样本数量。

召回率用于衡量模型能够正确检测到的正样本占有所有正样本的比例，它反映了模型的完整性。召回率越高，表明模型能够检测到更多的正样本。召回率的计算公式为

$$R = \frac{t_p}{t_p + f_n} \times 100\%。$$

(11)

其中： f_n 表示未检测到的正样本数量。

平均精度均值是目标检测中常用的综合评价指标，它用于衡量模型在不同类别上的

平均检测精度。平均精度均值的计算公式为

$$\text{mAP} = \frac{1}{n} \sum_{i=1}^n \text{AP}_i。$$

(12)

其中： n 表示检测类别的数量； AP_i 表示第 i 个类别的平均精度，其计算公式为

$$\text{AP} = \int_0^1 P(r) \text{d}r。$$

(13)

本实验检测类别 $n=6$ ，交并比设置为 0.5，所有类别平均精度取平均值即为 $\text{mAP}@0.5$ 。

2.3 消融实验结果及分析

2.3.1 C2f_DSC 模块实验

本文将原算法 Backbone、Neck 的 C2f 模块替换为本文改进的 C2f_DSC 模块，利用生成的自适应卷积核解决船舶目标检测过程中小目标船舶检测特征提取困难的问题。本文采用 3 种卷积模块改进方式进行实验，结果如表 1 所示。由表 1 可知，相较于原始的 YOLOv8n 模型，改进后的模型 YOLOv8n_DSC(Backbone + Neck)虽然精度有所下降（降低了 0.5%），但召回率提升了 4.6%， $\text{mAP}@0.5$ 提高了 2.5%。与另外 2 种改进方式 YOLOv8n_DSC(Backbone)和 YOLOv8n_DSC(Neck)相比，YOLOv8n_DSC(Backbone + Neck)在精度、召回率和 $\text{mAP}@0.5$ 等指标上表现更为优秀，说明联合优化 Backbone 和 Neck 部分的效果更佳。尽管精度有所降低，但 YOLOv8n_DSC(Backbone + Neck)能显著提升召回率和 $\text{mAP}@0.5$ ，表明该方法在目标检测任务中能提供更强的目标识别能力，且其综合性能优于 YOLOv8n。图 7 为改进 YOLOv8n_DSC 模型的训练曲线对比结果。

表 1 改进 YOLOv8n_DSC 模型实验结果

Tab.1 Experimental results of the improved YOLOv8n_DSC model

模型名称	P	R	$\text{mAP}@0.5$
YOLOv8n	87.7	88.5	95.1
YOLOv8n_DSC(Backbone)	79.8	91.0	95.0
YOLOv8n_DSC(Neck)	86.6	89.6	95.1
YOLOv8n_DSC(Backbone + Neck)	87.2	93.1	97.6




图 7 改进 YOLOv8n_DSC 模型训练曲线对比
Fig.7 Comparisons of training curve from the improved YOLOv8n_DSC model

2.3.2 YOLOv8n_SimAM 模型实验

本实验设计了 3 种不同的改进方式，分别命名为 YOLOv8n_SimAM-1（在网络的第 4 层添加 SimAM 模块）、YOLOv8n_SimAM-2（在网络的第 4 层和第 6 层分别添加 SimAM 模块）和 YOLOv8n_SimAM-3（在网络的第 4 层、第 6 层和第 9 层分别添加 SimAM 模块）。通过实验对比不同改进方式对模型性能的影响，结果如表 2 所示。由表 2 可知，YOLOv8n_SimAM-1 模型的精度略有下降，从 YOLOv8n 的 87.7% 降至 80.6%，但召回率却从 88.5% 增加至 91.0%。这表明 SimAM 提高了模型对船舶目标的敏感性，边界模糊

或难以识别的目标得以检测出来。然而, 这种提升的敏感性可能会导致部分误检, 从而使得精度有所下降。图 8 为改进 YOLOv8n_SimAM 模型的训练曲线对比结果。

表 2 改进 YOLOv8n_SimAM 模型实验结果

Tab.2 Experimental results of the improved YOLOv8n_SimAM model

单位: %

模型名称	<i>P</i>	<i>R</i>	mAP@0.5
YOLOv8n	87.7	88.5	95.1
YOLOv8n_SimAM-1	80.6	91.0	95.4
YOLOv8n_SimAM-2	86.5	91.3	95.9
YOLOv8n_SimAM-3	88.2	92.5	96.4




图 8 改进 YOLOv8n_SimAM 模型训练曲线对比

Fig.8 Comparisons of training curve from the improved YOLOv8n_SimAM model

综合比较发现, YOLOv8n_SimAM-3 在精度、召回率和 mAP@0.5 等 3 个指标上达到了最优平衡, 相较于原始的 YOLOv8n, 它的各个性能指标都表现优异。因此, 本文使用 YOLOv8n_SimAM-3 作为后续改进模型。

2.3.3 YOLOv8n_AFPN 模型实验

改进后的 YOLOv8n_AFPN 模型在精度、召回率和 mAP@0.5 等 3 个指标上均表现优异, 精度、召回率、mAP@0.5 分别为 91.2%、93.6%、96.8%, 分别比原始模型提高了 3.5%、5.1%、1.7%。这表明, AFPN 网络结构的引入对提高模型特征提取能力、减少误检漏检方面具有显著作用。图 9 为改进 YOLOv8n_AFPN 模型的训练曲线对比结果。

采用相同的数据集、实验条件, 以原始模型 YOLOv8n 作为基准模型进行消融实验, 评估不同模块的加入对模型检测性能的提升效果。本文提出的改进方法在船舶数据集上的消融实验结果如表 3 所示。由表 3 可知, 相较单独添加模块, 进一步融合 C2f_DSC 模块和 SimAM 模块的算法模型表现出更为优秀的综合检测性能, 表明两者的协同作用可以更好地提升精度与召回率。在此基础上, 引入 AFPN 网络结构之后, 改进模型在所有指标上都达到了最佳表现, 精度、召回率和 mAP@0.5 分别为 93.7%、95.2% 和 98.7%。




图 9 改进 YOLOv8n_AFPN 模型训练曲线对比

Fig.9 Comparisons of training curve from the improved YOLOv8n_AFPN model

表 3 消融实验结果

Tab.3 Comparison of ablation experiment results

单位: %

模块名称				<i>P</i>	<i>R</i>	mAP@0.5
YOLOv8n	C2f_DSC	SimAM	AFPN			
✓				87.7	88.5	95.1
✓	✓			87.2	93.1	97.6
✓		✓		88.2	92.5	96.4
✓			✓	91.2	93.6	96.8
✓	✓	✓		89.4	94.7	97.5
✓	✓	✓	✓	93.7	95.2	98.7

综合来看，实验结果充分验证了每个模块对检测性能的提升效果，且多个模块的结合能够在精度、召回率和 mAP@0.5 等多方面实现最佳平衡。本文后续使用 DSAMPN-YOLOv8n 表示最终改进算法模型。

2.4 对比实验

Faster R-CNN 作为二阶段检测框架的代表算法，在目标检测任务中表现出良好的检测效果。YOLO 其他系列的轻量化算法框架能够明确对比本文改进算法的检测效果，而 SACAM-YOLOv5、MED-YOLO 为其他改进的船舶目标检测算法。因此，将本文算法与 Faster R-CNN、YOLOv5n、YOLOv6n、YOLOv7-tiny、YOLOv8n 算法在相同条件下进行对比实验，进一步评估验证本文算法的目标检测性能，结果如表 4 所示。由表 4 可知，与其他目标检测算法相比，DSAMPN-YOLOv8n 在精度、召回率、mAP@0.5 上均表现优异。

为了验证本文提出的 DSAMPN-YOLOv8n 算法在船舶目标检测任务中的有效性，将其与多个现有船舶目标检测方法进行对比，包括改进基于区域的快速卷积神经网络^[17]、MS-SOD^[18]、改进的 YOLOv5 船舶目标检测方法^[19]、基于 YOLOv5 的小目标检测方法^[20]和 SAF-YOLOX^[21]等，对比结果如表 5 所示。

表 4 改进算法与其他目标检测算法实验结果对比

Tab.4 Comparisons of experimental results from the improved algorithm and those from other object detection algorithms

模型名称	单位:%		
	P	R	mAP@0.5
Faster R-CNN	92.7	94.9	96.3
YOLOv5n	82.4	94.2	96.7
YOLOv6n	83.9	94.0	96.5
YOLOv7-tiny	87.4	91.0	91.9
YOLOv8n	87.7	88.5	95.1
DSAMPN-YOLOv8n	93.7	95.2	98.7

表 5 改进算法与其他船舶检测算法实验结果对比

Tab.5 Comparisons of experimental results from the improved algorithm and those from other ship detection algorithms

模型名称	单位:%		
	P	R	mAP@0.5
SAF-YOLOX	95.2	94.1	93.2
改进的 YOLOv5 船舶目标检测方法	88.5	98.3	—
改进基于区域的快速卷积神经网络	—	—	98.0
基于 YOLOv5 的船舶小目标检测方法	—	—	95.9
MS-SOD	—	—	62.3
DSAMPN-YOLOv8n	93.7	95.2	98.7

由表 5 可知，DSAMPN-YOLOv8n 在 mAP@0.5、精度、召回率 3 个指标上均表现优异，尤其在 mAP@0.5 指标上取得最高值。说明本文方法既保证了较高的检测精度，又具备良好的召回能力。

为验证 DSAMPN-YOLOv8n 算法在实际应用中的适用性，尤其在复杂环境中的表现，本文从数据集中选取多船舶遮挡图像、多尺度船舶图像和背景复杂的船舶图像等 3 张具有代表性的复杂船舶图像，使用本文训练的模型参数进行推理验证。图 10 是 YOLOv8n 与改进模型 DSAMPN-YOLOv8n 的船舶目标检测可视化对比结果。

第 1 张船舶图像中共有 3 艘普通货船，其中存在部分重叠遮挡。YOLOv8n 模型的检测结果为 4 艘普通货船，出现多检且检测框重叠混乱情况；DSAMPN-YOLOv8n 的检测结果为 3 艘普通货船，且检测框清晰完整，符合实际情况。

第2张船舶图像中共有5艘船,其中有1艘大型普通货船、1艘散货船、3艘小型渔船,为多尺度船舶图像。YOLOv8n 模型的检测结果为1艘普通货船、1艘渔船,出现多尺度船舶图像漏检情况; DSAMPN-YOLOv8n 的检测结果全部正确,且检测框清晰完整,符合实际情况。

第3张船舶图像中有1艘普通货船,背景复杂。YOLOv8n 模型的检测结果为1艘客船,出现复杂背景下错检情况; DSAMPN-YOLOv8n 的检测结果为普通货船,且检测框清晰完整,符合实际情况。



图 10 YOLOv8n 与改进模型 DSAMPN-YOLOv8n 的可视化对比实验结果
Fig.10 Visualization of comparative experimental results between YOLOv8n
and the improved model DSAMPN-YOLOv8n

3 结论

针对复杂背景下近岸多尺度船舶检测的错检、漏检问题,本文提出了一种改进的目标检测方法 DSAMPN-YOLOv8n。利用改进的 C2f_DSC 模块替代 C2f 模块,通过动态蛇形卷积操作,增强网络的特征提取能力;添加 SimAM 模块,通过自适应的注意力机制来捕捉更加细致的特征信息,有效帮助网络聚焦于目标区域,提高目标的辨识度;引入 AF-PN 结构,通过自适应空间融合调整各层特征的权重,实现多尺度特征融合以满足船舶目标检测的尺寸要求,实现船舶目标的精准检测。实验结果表明,DSAMPN-YOLOv8n 模型能够更好完成船舶目标检测任务。

[参 考 文 献]

- [1] 张炳焱, 张闯, 石振男, 等. 基于 YOLO-FNC 模型的轻量化船舶检测方法[J]. 中国舰船研究, 2024(5): 180-187.
- [2] WANG J L, CUI Z Y, JIANG T, et al. Lightweight deep neural networks for ship target detection in SAR imagery[J]. IEEE Transactions on Image Processing, 2023, 32: 565-579.
- [3] 李毓霖, 胡秀波, 李鑫军, 等. 基于改进 YOLOv7 的近岸目标船舶检测算法[J]. 辽宁科技大学学报, 2024, 47(3): 204-212.
- [4] 刘芬, 孙杰, 张帅, 等. 基于 YOLOv5 的红外船舶目标检测算法[J]. 红外与激光工程, 2023, 52(10): 222-233.
- [5] 张阳, 刘小芳, 周鹏成. 改进 Faster R-CNN 的 SAR 图像船舶检测技术[J]. 无线电工程, 2022, 52(12): 2280-2287.
- [6] DENG H M, ZHANG Y. FMR-YOLO: infrared ship rotating target detection based on synthetic fog and multiscale weighted feature fusion[J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73: 1-17.
- [7] HU J M, ZHI X Y, SHI T J, et al. PAG-YOLO: A portable attention-guided YOLO network for small ship detection[J]. Remote Sensing, 2021, 13: 3059.
- [8] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[C]//IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV, USA: IEEE, 2016: 779-788.
- [9] REDMON J, FARHADI A. YOLO9000: better, faster, stronger[C]//IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, HI, USA: CVPR, 2017: 6517-6525.
- [10] REDMON J, FARHADI A. YOLOv3: an incremental improvement[EB/OL]. (2018-04-08)[2025-01-01]. <https://doi.org/10.48550/arXiv.1804.02767>.
- [11] LIN T Y, DOLLAR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]//IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, HI, USA: CVPR, 2017: 936-944.
- [12] LIU S, QI L, QIN H F, et al. Path aggregation network for instance segmentation[C]//IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, UT, USA: IEEE, 2018: 8759-8768.
- [13] QI Y L, HE Y T, QI X M, et al. Dynamic snake convolution based on topological geometric constraints for tubular structure segmentation[C]//IEEE/CVF International Conference on Computer Vision (ICCV). Paris, France: ICCV, 2023: 6047-6056.
- [14] YANG L X, ZHANG R Y, LI L, et al. SimAM: A simple, parameter-free attention module for convolutional neural networks[C]//Proceedings of the 38th International Conference on Machine Learning. [S. l.]: PMLR, 2021: 11863-11874.
- [15] YANG G Y, LEI J, TIAN H, et al. AFPN: asymptotic feature pyramid network for object detection[C]//IEEE International Conference on Systems, Man, and Cybernetics (SMC). Honolulu, HI, USA: IEEE, 2023: 2184-2189.
- [16] SHAO Z F, WU W J, WANG Z Y, et al. SeaShips: a large-scale precisely annotated dataset for ship detection[J]. IEEE Transactions on Multimedia, 2018, 20(10): 2593-2604.
- [17] 齐亮, 李邦昱, 陈连凯. 基于改进的 Faster R-CNN 船舶目标检测算法[J]. 中国造船, 2020, 61(增刊1): 40-51.
- [18] 黄靖, 汤宁, 文元桥, 等. 多尺度水上船舶目标视觉检测[J]. 哈尔滨工业大学学报, 2024, 56(5): 103-113.
- [19] 宋策, 尹勇, 王鹏. 基于改进 YOLOv5 的船舶目标检测算法[J]. 集美大学学报(自然科学版), 2023, 28(2): 136-141.
- [20] 黄春森, 陈俊龙, 张海锐, 等. 基于 YOLOv5 的船舶小目标检测[J]. 中国水运, 2024, 24(22): 1-3.
- [21] 罗芳, 李家威, 何道森. 尺度适应性感受野的船舶目标检测方法[J]. 计算机应用研究, 2024(8): 2521-2527.

(责任编辑 马建华 英文审校 郑青榕)