

基于幽灵卷积多尺度特征融合的船舶检测算法

鲜润东^{1,2}, 黄可逸¹, 唐立军^{1,2}

(1. 长沙理工大学 物理与电子科学学院, 长沙 410114;
2. 柔性电子材料基因工程 湖南省重点实验室, 长沙 410114)

摘要: 如今船舶目标检测技术在不断发展, 但在雾天、雨天和雪天等恶劣天气条件下, 船舶目标的可见度低, 导致模型特征提取不全面, 检测性能会显著下降; 针对以上问题, 提出了一种轻量化目标检测模型 GSPN-YOLO; 该模型基于 YOLOv8s 架构, 在主干网络采用幽灵卷积替换普通卷积, 使用 GhostNCSP 模块替代 C2f 模块, 降低计算量的同时提高网络精度; 在颈部网络设计了通道重排多尺度特征金字塔, 显著提升了多尺度特征的代表能力; 经实验测试, GSPN-YOLO 在自制数据集上, 相较于基准模型 YOLOv8s, 其 AP@50 : 95 提升了 2.1%, AP@50 提升了 2.7%, AP@75 提升了 2.5%, 同时参数量减少了 45.5%; 此外, 其检测性能优于 YOLOv10s、YOLOv11s 等 SOTA 目标检测算法, 满足了在复杂天气条件下船舶检测的应用需求。

关键词: 船舶检测; 特征金字塔; 轻量化模型; 多尺度增强; 恶劣天气

Ship Detection Algorithm Based On Ghost Convolution Multi-scale Feature Fusion

XIAN Rundong^{1,2}, HUANG Keyi¹, TANG Lijun^{1,2}

(1. School of Physics and Electronics Science, Changsha University of Science & Technology,
Changsha 410114, China;
2. Hunan Provincial Key Laboratory of Flexible Electronic Materials Genetic Engineering,
Changsha 410114, China)

Abstract: With the continuous development of ship target detection technologies, ship targets have low visibility under adverse weather conditions such as fog, rain, and snow, which leads to incomplete feature extraction of the model and a significant decline in detection performance. To address these issues, a lightweight target detection model, GSPN-YOLO, is proposed. Based on the YOLOv8s architecture, the ordinary convolution in the backbone network is replaced by the Ghost convolution, and the C2f module is replaced by the GhostNCSP module. This approach reduces the computational load while improving network accuracy. In the neck network, a channel-rearranged multi-scale feature pyramid is designed, which significantly enhances the representation ability of multi-scale features. Experimental tests show that on a self-made dataset, compared with the baseline model YOLOv8s, the GSPN-YOLO improves the AP@50 : 95 by 2.1%, the AP@50 by 2.7%, and the AP@75 by 2.5%, respectively, while the number of parameters is reduced by 45.5%. Moreover, this algorithm is superior in detection performance to state-of-the-art (SOTA) target detection algorithms such as YOLOv10s and YOLOv11s, meeting the application requirements of ship detection under complex weather conditions.

Keywords: ship detection; feature pyramid; lightweight model; multi-scale enhancement; severe weather

收稿日期: 2025-02-24; 修回日期: 2025-04-01。

基金项目: 长沙理工大学专业硕士研究生项目(CLSJCS24078)。

作者简介: 鲜润东(2000-), 男, 硕士。

通讯作者: 唐立军(1963-), 男, 教授。

引用格式: 鲜润东, 黄可逸, 唐立军. 基于幽灵卷积多尺度特征融合的船舶检测算法[J]. 计算机测量与控制, 2026, 34(3): 138

0 引言

由于对船舶的检测能力不足,常常导致船舶事故、非法捕鱼和走私等问题^[1],给国家造成重大损失。而基于数据源的船舶探测主要分为3类:合成孔径雷达图像^[2]、光学遥感图像^[3]和视觉图像。合成孔径雷达图像视野宽广,且具有全天/全季节的性能^[4],但数据更新周期长、细节信息不全、图像颜色单一,难以实现实时性检测和分类检测^[5]。光学遥感图像主要由卫星摄像机拍摄,具有高分辨率的优势,但在夜间难以获得^[6]。视觉图像富含色彩与纹理的详尽信息,具有成本低、传输快、低功耗等特点,在港口监控、跨境船舶检测等多元化场景中广泛应用^[7]。

视觉图像的船舶检测算法主要有传统检测算法和深度学习检测算法。传统检测算法主要依靠边缘检测算子对船舶轮廓和边缘进行特征提取,接着将特征输入分类器来实现船舶识别^[8],泛化能力差,检测精度低^[9]。

相比之下,深度学习具有强大的特征学习能力,使其成为当前船舶检测技术的主流方法。文献[10]首先结合特征融合和迁移学习等策略,改进了Faster R-CNN来检测船舶目标,然而,在定位船舶的轮廓边缘区域时仍然存在重大误差,这表明有必要进一步提高模型精度。文献[11]提出了一种增强的R-CNN方法,称为Ship R-CNN,该方法提高了在复杂背景和船舶与远岸差异最小的场景中的船舶检测精度。然而,这种方法没有考虑到复杂天气下的船舶识别。文献[12]通过增强融合图像特征信息,提高了模型的去雾性能,然而,该网络没有考虑到雨雪天气条件的挑战,其模型表现出有限的泛化。文献[13]基于YOLOv7设计了一个高效层聚合网络 and 全维动态卷积来应对海上船舶图像中常见的复杂背景干扰,从而提高了模型的特征提取能力,但该网络存在着参数沉冗的问题。

综上所述,尽管在复杂海况下的船舶图像检测方面取得了一些研究成果,但挑战仍然存在。首先,视觉图像中的船舶呈现出丰富的色彩细节信息和显著的尺寸变化特征,但这些关键信息在恶劣天气的影响下往往提取不完整,模型的多尺度提取能力不足和鲁棒性低^[14]。尽管FPN^[15]、PANet^[16]等特征融合方法在多尺度特征提取方面取得了一定效果,但目标的语义特征信息在深层特征中容易丢失,而大范围的特征图深度融合又可能破坏浅层特征图中的目标特征信息。因此,有效提取特征图的融合特征信息,成为恶劣天气下船舶目标检测的关键问题。针对这些问题,本文提出了一种基于幽灵卷积和通道重排多尺度特征金字塔的恶劣天气下轻量级船舶检测方法,该方法的主要贡献如下:

1) GSPN-YOLO在主干网络中引入了幽灵卷积来替

换普通卷积,以较低的计算成本获得了较高的特征提取能力。2) 针对模型参数量大,特征信息结合不充分的问题,设计了幽灵卷积多重跨阶段连接模块(GhostNCSP, ghostncross-stage partial connections)并引入模型的主干网络中,通过在不同层级提取特征,大幅减少模型参数量的同时有效提升了模型梯度流动。3) GSPN-YOLO提出了通道重排多尺度特征金字塔(SFPN, channel shuffle feature pyramid network),通过重排特征融合网络,增加模型检测头,提升了模型的多尺度描述能力和复杂天气下模型检测的鲁棒性。

1 GSPN-YOLO 设计原理

GSPN-YOLO的结构如图1所示,其由骨干网络、特征金字塔和检测头构成。首先,骨干网络提取输入图像的多尺度特征图,与YOLOv8^[17]不同的是,本文将骨干网络中的普通卷积替换为GhostConv, C2f模块替换为单个GhostNCSP模块。虽然这降低了网络的深度,但得益于GhostNCSP的多分支特征增强架构,模型在保持较低计算复杂度的同时,仍然能够实现强大的特征提取能力。该网络的输入图片大小为 $640 \times 640 \times 3$,从主干网络中获得大小为 $160 \times 160 \times 128$ 、 $80 \times 80 \times 256$ 、 $40 \times 40 \times 512$ 、 $20 \times 20 \times 1024$ 的4种不同尺寸的有效特征层并输入特征金字塔中。然后,四路经特征处理模块处理后的特征图被输入到SFPN中进行融合增强,生成特征子集。最后,将特征子集输入检测头,以获取船舶最终检测结果。




图1 GSPN-YOLO 结构图

1.1 Ghost 模块

Ghost模块的主要思想是利用两步卷积操作产生同等数量的特征图,但计算量远低于普通卷积,结构如图2所示。具体地说,幽灵卷积将输入特征图分成两部分,首先使用较少的计算资源生成大部分特征图,然后使用少量计算资源生成补充特征图,并将两者拼接在一

起。这种方法有效地减少了模型的计算复杂度，同时保持了较高的特征提取力。




图 2 Ghost 卷积结构图

假设输入特征图为 X ， $X \in R^{H \times W \times C}$ ，普通卷积和参数量可以如 (1) 和 (2) 式所示：

$$Y = X \times T \tag{1}$$

$$P = n \times c \times k \times k \tag{2}$$

其中： T 是卷积， X 是输出特征图， n 指的是卷积核个数， c 指的是通道数。而 Ghost 模块将输出特征图分为两部分，首先通过普通卷积生成原始特征图 Y' ， $Y' \in R^{H' \times W' \times C'}$ ，如 (3) 式所示，输出特征为 m 个基本特征图集，为了补全剩余的特征图，对这 m 个基本特征图集通过线性变换操作来产生了 Ghost 特征图 Y_{ij} ，具体如公式 (4) 所示，其中 s 表示生成的 Ghost 特征图数量，且 $s = n/m$ ，最终，将第一步得到的原始特征图和第二步得到的 Ghost 特征图进行拼接，得到最终输出结果：

$$Y' = X \times T' \tag{3}$$

$$Y_{ij} = \varphi_{ij}(Y'_j) \forall i = 1, \dots, m, j = 1, \dots, s \tag{4}$$

Y'_j 表示第 j 个输入特征图， Y_{ij} 表示第 i 个输入特征图经过 φ_{ij} 线性运算得到的第 j 个输出特征图。因此，Ghost 模块的参数数量由两部分组成：普通卷积和线性变换。第一部分，传统卷积运算的参数数量计算如公式 (5) 所示：

$$P_1 = c \times \frac{n}{s} \times k \times k \tag{5}$$

假设线性运算的每个卷积核大小也为 $k \times k$ ，则第二部分线性变换的参数数量如 (6) 式所示：

$$P_2 = \frac{n}{s} \times (s - 1) \times k \times k \tag{6}$$

普通卷积与 Ghost 卷积模块参数量之间的关系用压缩比表示如如 (7) 式所示，当时有：

$$r_c = \frac{n \times c \times k \times k}{c \times \frac{n}{s} \times k \times k + \frac{n}{s} \times (s - 1) \times k \times k} \approx \frac{s \times c}{c + s - 1} \approx s \tag{7}$$

由式 (7) 可知，Ghost 模块通过线性变换替代冗余特征生成，可将参数量压缩至普通卷积的 $1/s$ 。Ghost 模块减少参数量的同时保留关键特征多样性，例如在船舶模糊轮廓区域，Ghost 模通过减少沉闷特征避

免了重复的边缘响应，增强船体边缘的连续性表达，而普通卷积可能因参数冗余导致噪声放大。

1.2 GhostNCSP

GhostNCSP 模块是一种结合了跨阶段部分连接和高效层聚合网络的特征增强架构，结构图如图 3 所示。GhostNCSP 将输入特征图分为两部分，分别通过幽灵卷积跨阶段部分瓶颈结构（GhostCSP，ghost conv cross stage partial）和普通卷积处理，最后拼接所有分支的特征图。输入张量在主干层中经历了许多卷积运算，促进了网络不同阶段之间的信息流动。它通过特征压缩与分支融合，构建稀疏但更具判别性的特征空间，使网络能够更聚焦船舶主体而非背景噪声。在某些情况下，可以增加通道数，同时减少特征图的空间维度。凭借这些层在不同抽象级别提取特征的能力，该模块可以获得对象检测至关重要的高级语义信息和基本细节。当输入张量通过主干级别时，将其用分层特征提取使得每一层都捕获不同级别的特征。作用是进行特征提取和变换，同时保持计算效率和模型的紧凑性。特别是在深层网络中，能够有效提升梯度流动和模型性能。

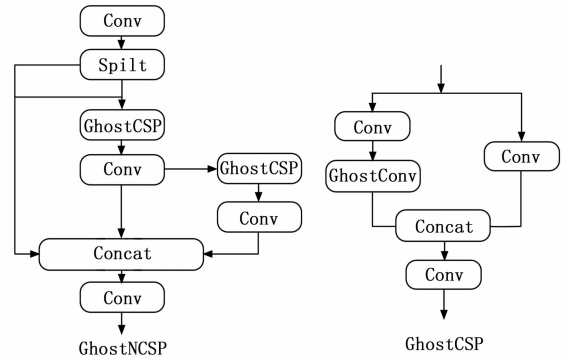


图 3 GhostNCSP 模块结构图

GhostCSP 是一个跨阶段部分瓶颈（CSP，cross stage partial）结构，结合了幽灵卷积和普通卷积模块，用于增强特征提取能力。CSP 结构将输入特征图分为两部分，一部分直接通过卷积，另一部分通过多个 GhostConv 模块处理，最后将两部分特征图拼接，从而减少计算量并增强特征融合。

本文提出了一种高效轻量化的 GhostNCSP 模块，并针对 YOLOv8 网络结构的特性，将其应用于骨干网络中，替换了原有的 C2f 模块。具体而言，骨干网络中 16 倍和 32 倍下采样部分的 C2f 模块（通道数分别为 512 和 1 024）被 GhostNCSP 模块所取代。这种替换方式不仅能够有效利用网络中的关键特征信息，还能大幅压缩模型规模。值得注意的是，4 倍与 8 倍下采样层的 C2f 模块保持原始结构未作替换。这类低层级模块因具有较高的空间敏感度，承担着高频细节和位置特征的基础捕获任务，其信息保真度直接制约深层网络的语义抽

象能力, 故维持其原本设计以保障特征金字塔底层的表征稳定性。通过后文的模块替换实验方案本文在模型压缩与精度之间寻求了一个较好的平衡。

1.3 SFPN

与许多基于特征金字塔网络的目标检测方法一样, 在特征融合网络之前, 从骨干网络中提取不同级别的特征。参考文献 [18] 基于 YOLOv8 框架的设计, SFPN 从主干的每个 CSP 模块中逐级提取具有空间层次关系的特征集合 $\{C_2, C_3, C_4, C_5\}$, 其中 C_2 对应最高分辨率的浅层特征, C_5 表征最深层的语义信息。在特征融合过程中采用递进式融合框架, 特征金字塔网络采用自底向上的融合路径, 首先将高分辨率特征 C_2 与 C_3 进行语义对齐, 随后逐级引入中层特征 C_4 和深层语义特征 C_5 , 通过多尺度特征交互最终输出 $\{P_2, P_3, P_4, P_5\}$ 多尺度特征集合, 如图 4 所示。




图 4 SFPN 结构图

具体而言, SFPN 首先融合浅层特征 C_2 , 然后逐层融合更高级的特征 C_3, C_4 , 最终整合深层特征 C_5 。由于非相邻特征层 C_2 和 C_4 之间的语义差异显著高于相邻层 C_3 和 C_4 , 直接融合 C_2, C_3, C_4 和 C_5 会导致融合效果不佳。这种渐进融合策略使得不同层次特征的语义信息更加接近, 从而提升了整体特征融合的效果。

单阶段目标检测算法中特征金字塔融合存在的跨尺度特征不一致性问题, YOLOv8 利用 PAN 结构进行不同尺度的特征融合, PAN 通过在通道维度上直接拼接不同尺度的特征层来实现特征融合。这种粗粒度聚合方式难以有效协调浅层细节特征与深层语义特征之间的信息差异, 导致跨尺度特征交互效率不足。同时在恶劣天气下, 船舶可能仅部分可见, 参考文献 [19], 本文设计了 SASF 模块通过空间权重学习, 在低层特征中强化船体轮廓等边缘响应, 在高层特征中聚焦语义显著区域, 如船体颜色形状等。特征融合如图 5 所示。

SASF 模块融合了 3 个层次的特点, 其在某位置的输出如下所示:

$$y_{ij}^l = F_s(\alpha_{ij}^l \times x_{ij}^{1 \rightarrow l} + \beta_{ij}^l \times x_{ij}^{2 \rightarrow l} + \gamma_{ij}^l \times x_{ij}^{3 \rightarrow l}) \quad (8)$$

F_s 表示对最后融合而成的特征向量进行通道重排, 重新排列分组后的特征图通道, 促进不同组之间的信息




图 5 SFPN 特征融合示意图

交流, $x_{ij}^{1 \rightarrow l}$ 表示从 level1 特征层级调整为 levell 特征层级后, 在 (i, j) 处的特征向量。 y_{ij}^l 表示多级特征的通道重排空间融合获得的特征向量, 并由特征向量 $x_{ij}^{1 \rightarrow l}$, $x_{ij}^{2 \rightarrow l}$ 和 $x_{ij}^{3 \rightarrow l}$ 的线性组合来定义, 其中的权重参数 α_{ij}^l , β_{ij}^l 和 γ_{ij}^l 是到 level1 到 levell 特征图经过 1×1 的卷积得到的。并且参数 α_{ij}^l , β_{ij}^l 和 γ_{ij}^l 经过通道方向上的拼接再通过 softmax 函数, 得它们的范围都在 $[0, 1]$ 内并且和为 1, 如下式所示:

$$\alpha_{ij}^l + \beta_{ij}^l + \gamma_{ij}^l = 1 \quad (9)$$

2 实验与结果分析

2.1 实验环境

本文模型和其它对比模型的训练和检测均在台式计算机上进行, 所用计算机配置为: Windows10 操作系统, CPU 为 Intel Core I5-13490F CPU, 显卡为 Nvidia Geforce RTX 4070 GPU, 12 GB 内存。编程语言为 Python3.8, 程序框架为 PyTorch2.0.1 和 Cuda11.8。模型训练轮次为 200, batch size 设置为 8, 输入图像的大小为 640×640 像素, 网络优化器为 SGD, 学习率固定为 0.01。

2.2 试验评价指标

为综合验证本文算法的性能, 采用 COCO 评价指标, 选取了五个指标来全方位评估模型, 分别是 AP@50 : 95、AP@50、AP@75、模型参数量 (Params, Parameters) 和每秒帧数 (FPS, frames per second)。其中平均精确度 (AP, average precision) 用于衡量模型预测为正样本的结果中, 实际为正样本的比例, 其计算公式如式 (10) 所示。具体而言, 真正例 (TP, true positive) 是指模型正确识别为正类的样本数量, 而假正例 (FP, false positive) 则是指模型错误地将负类预测为正类的样本数量。AP@50 : 95 在 10 个交并比 (IoU, intersection over union) 阈值 (0.5 ~ 0.95, 区间为 0.05) 上取精度平均值, 类似的, AP@50 和 AP@75 分别表示在 IoU 阈值为 0.5 和 0.75 时的平均精确率:

$$Precision = \frac{TP}{TP + FP} \quad (10)$$

2.3 实验数据集

本文主要选择两个基准数据集，自制数据集和 McShips 数据集^[20]，自制数据集所采用的数据由 SeaShips 数据集^[21]中的部分图片以及自行采集的图片组成，共计包含 5 563 张照片，涵盖了常见的六类船舶：矿石船、散货船、杂货船、集装箱船、渔船和客船。数据集中，内河航道的船舶图片占据绝大多数，为正常天气下图片。为评估模型在复杂气象环境下的鲁棒性，对验证集和测试集进行了针对性处理，将原始验证测试集均分为两个对照组，其中实验组采用添加图像噪声的方法使数据集更加贴合真实恶劣天气下的船舶图像，生成了雨天、雪天和雾天天气条件下的船舶图像，各天气类别按等比例生成；对照组则保持原始数据集的正常天气不变。在本实验中，训练集、测试集和验证集的比例分别为 8 : 1 : 1。

McShips 数据集，一共有 7 996 张船舶图像。该数据集具有以下两个特点，首先，由于船舶的船型非常相似，因此船级间差异很小；其次，由于视点变化、天气条件变化、照明变化、比例变化、遮挡、杂乱背景等原因，同一级别的船只可能会有很大差异，因此存在非常大的类内差异。本实验中训练集、测试集和验证集的比例为 5 : 3 : 2。

2.4 GhostNCSP 模块替换实验

将 YOLOv8 原模型中主干网络从浅层到深层不同位置的 C2f 模块替换为 GhostNCSP 模块，如表 1 所示。由实验 6、7、8 可知，替换浅层的 C2f 模块，性能有了不同程度的降低，说明轻量化模块 GhostNCSP 在浅层降低了模型深度，使得网络基础特征提取能力有了下降。由实验 2、3、4、5 可知，用 GhostNCSP 模块替换深层位置的 C2f 模块对模型的精度有了不同程度的提升，采用实验 3 方案时只替换第三层和第四层的 C2f 模块时，模型精度最高，与基准模型相比，分别提升了 0.4%、0.4% 和 0.7%，同时参数量只有原来的 82.5%，因此本文采用实验 3 的方案。以上实验说明要从模型整体结构进行考量来探索高性能的轻量化压缩。

表 1 GhostNCSP 模块替换实验结果

实验编号	替换位置	AP@50 : 95 / %	AP@50 / %	AP@75 / %	Params / M
1	Baseline	60.3	85.3	66.2	11.16
2	4	60.6	84.9	66.8	9.85
3	3/4	60.7	85.7	66.9	9.21
4	2/4	60.4	85.1	66.4	9.69
5	2/3	60.2	84.8	65.9	10.34
6	2/3/4	59.8	84.5	65.3	9.04
7	1/3/4	59.7	84.7	65.6	9.19
8	1/2/3/4	59.2	84.1	65.3	9.03

2.5 对比实验

本文选取已公开代码的主流检测算法 (YOLOv5s^[22], YOLOv6s, YOLOv7-Tiny^[23], YOLOv8s, YOLOv9s^[24], YOLOv10s^[25], YOLOv11s^[26], RT-DETR^[27]) 与 GSPN-YOLO 在自制数据集上进行对比。

各个模型的精度 (AP@50 和 AP@50 : 95) 随训练轮次增加曲线对比如图 6 所示，在训练过程中，GSPN-YOLO 的精度曲线在 75 个训练周期之前达到较高点，表现出最快的拟合速度。当训练周期超过 100 个轮次后，模型精度逐渐趋于稳定。比原模型 YOLOv8s 和其他模型有着更快的收敛速度，说明模型的改进使得模型收敛更快，检测性能更佳。

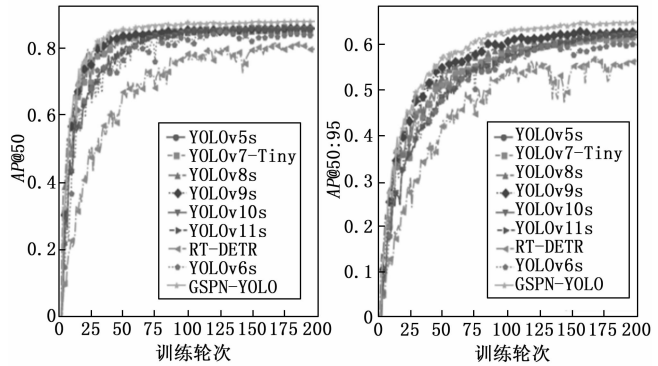


图 6 模型精度曲线对比图

实验对比结果见表 2，实验 A 是保持原始数据集正常天气不变的对照组，实验 B 是添加图像噪声模拟恶劣天气的实验组。YOLO 系列算法的性能也随着迭代次数的增加而逐步提升。在 YOLO 的各个版本中，YOLOv8s 在参数量和精度之间取得了较好的平衡，既不像 YOLOv6s 那样参数过多，也不像 YOLOv11s 那样精度较低。因此，本文选择在 YOLOv8s 架构的基础上进行改进，以进一步提升算法性能。所以本文在 YOLOv8s 的架构上进行改进，以获得更好的算法性能。在实验 B 中，所有模型均出现显著性能衰减，例如 YOLOv8s 的 AP@50 : 95 指标下降 13.5%。这种现象验证了目标检测模型对环境干扰的敏感性。值得注意的是，GSPN-YOLO 的 AP@50 : 95 指标仅下降 11.7%，比原模型 YOLOv8s 在 AP@50 : 95、AP@50 和 AP@75 精度指标上分表高出 2.1%、3.7% 和 2.5%，衰减幅度较基准模型减少 13%，说明改进后的网络具有更优的鲁棒性。在表中可以看出 GSPN-YOLO 无论是实验 A 还是实验 B，在评价指标 AP@50 : 95 上均领先于其他对比算法。从精度效率方面分析，GSPN-YOLO 在实现性能突破的同时，参数量压缩至 6.06M，仅为 YOLOv8s 的 54.6%。虽然 FPS 略低于 YOLOv8s，但显著高于其它轻量级模型，相比 YOLOv7-Tiny 提速 24.2%。

表 2 对比实验结果

模型	实验 A			实验 B			Params/M	FPS
	AP@50 : 95/%	AP@50/%	AP@75/%	AP@50 : 95/%	AP@50/%	AP@75/%		
YOLOv5s	72.3	96.7	81.7	60.4	84.7	68	9.11	222
YOLOv6s	73.6	97.4	80.8	60.8	85	68.7	16.29	234
YOLOv7-Tiny	72.5	96.5	81.8	57.6	83.2	67.9	6.01	157
YOLOv8s	73.8	97.5	82.3	60.3	85.3	66.2	11.12	239
YOLOv9s	73.9	96.9	83.1	60.3	85.4	66.5	7.3	99
YOLOv10s	70.3	96.4	77.2	58.8	83	65.9	7.22	201
YOLOv11s	72.8	96.7	81.9	60	84.4	65.6	9.41	202
RT-DETR	71.8	95.1	78.7	57.2	80.7	64.7	28.45	79
GSPN-YOLO	74.1	97.3	83.1	62.4	88	68.7	6.06	195

综上所述, 本文所提出的模型在减少参数量条件下, 检测性能依然具备优势, 证明了 GSPN-YOLO 算法的优越性。

在 McShips 数据集上评估了 GSPN-YOLO, 并将其与其他最先进的方法进行了比较。结果如表 3 所示, 从实验结果可以看出, GSPN-YOLO 在多个关键指标上均表现出色。与基线 YOLOv8s 相比, GSPN-YOLO 将 AP@50 : 95 从 64.5% 提高到 65.5%。仅次于 YOLOv9s 的 65.6%, 显著高于其他模型, 如 YOLOv11s 的 64.5% 和 RT-DETR 的 62.6%。这表明 GSPN-YOLO 在整体检测精度上具有明显优势。虽检测指标略低于 YOLOv9s, 但 GSPN-YOLO 参数量仅为 6.06 M, 为 YOLOv9s 的 83%, 显示出其在保持高性能的同时具有较高的计算效率。综上所述, GSPN-YOLO 在检测精度和模型效率之间取得了良好的平衡, 是一种高效且可靠的目标检测模型。

表 3 McShips 数据集对比实验结果

模型	AP@50 : 95 /%	AP@50 /%	AP@75 /%	Params /M
YOLOv5s	64	90.8	70.9	9.11
YOLOv6s	64.4	90.4	71	16.29
YOLOv7-Tiny	63.6	90.4	70.8	6.01
YOLOv8s	64.5	91	72.5	11.12
YOLOv9s	65.6	91.2	73.6	7.3
YOLOv10s	63.5	89.8	70.6	7.22
YOLOv11s	64.5	90.5	72	9.41
RT-DETR	62.6	87.9	69.9	28.45
GSPN-YOLO	65.5	90.9	73.5	6.06

为了更直观地展示所提算法 GSPN-YOLO 与对比算法在目标检测效果上的差异, 在自制数据集上进行了检测结果的可视化展示。具体结果如图 7 所示, 其中虚线框表示漏检的目标。图中第一列是 YOLOv8s 算法的检测结果, 第二列是 YOLOv11s 算法检测的结果, 第三列是 GSPN-YOLO 算法检测的结果。由第一行和第二行横向对比检测结果为可知, 在雨雪天气下,

YOLOv8s 和 YOLOv11s 出现了漏检现象, 说明 GhostNCSP 模块效提升模型的特征提取能力。由第三行横向对比检测结果为可知, GSPN-YOLO 保持着最高的准确度, 说明 SFPN 特征融合网络可以增强网络的表征能力, 由第四行横向对比检测结果为可知, 在遮挡和密集目标的检测场景中, YOLOv8s 的重复检测的情况, 说明所提算法相对于基准 YOLOv8s 算法对复杂目标检测效果有了明显提升。综上, 本文算法在恶劣天气场景下对船舶具有较好的检测效果。




图 7 可视化结果对比

2.6 消融实验

以 YOLOv8s 为基础模型, 表 4 展示了 GSPN-YOLO 的消融实验结果。由表 4 可知, 在骨干网络加入 Ghost 模块后, 各项有着不同程度的提升, 同时参数量有了一定的减少, 表明 Ghost 模块通过使用线性变换从现有特征图生成更多特征图, 相较于依赖额外的卷积层, 减少了所需的计算量, 增强了特征的有效性。在骨干网络加入 Ghost 模块和 GhostNCSP 模块后, 精确度指标有所下降, 但参数量只有原来的 76.1%。基础模型在引入 GhostNCSP 模块和 SFPN 模块后, 模型精度表现不佳, 但参数量有了大量减少。基础模型在引入 Ghost 模块和 SFPN 模块后, 模型 AP@50 : 95 相比基准模型提升了 1%, 同时参数量减少了 28%。最后, 在加入所有改进模块后, 模型 AP@50 : 95 和 AP@50 指

标达到了最优，参数量达到了最低，网络总体在性能和资源消耗之间取得了良好的平衡。综上所述，本文提出的改进方法均能有效提高恶劣天气下船舶检测精度。

表 4 消融实验结果

模型	Ghost Conv	Ghost NCSP	SFPN	AP@50 : 95/%	AP@ 50/%	AP@ 75/%	Params /M
YOLOv8s				60.3	85.3	66.2	11.12
	✓			62.4	87.3	70.2	10.43
	✓	✓		60.9	84.9	68.6	8.47
		✓	✓	60.5	86.1	65.5	6.79
	✓		✓	61.3	88.2	67.6	8.01
	✓	✓	✓	62.4	88	68.7	6.06

图 8 展示了基准模型在引入 GhostConv、GhostNCSP 和 SFPN 模块后 GradCAM 热力图的变化。热力图中的颜色强度反映了每个像素或区域相对于预测目标类别的重要性，颜色越深表示对预测结果的影响越大。从图中可以看出，引入 GhostConv 模块后，模型对遮挡目标的响应性显著提高；加入 GhostNCSP 模块后，虽然对目标的关注度有所下降，但模型的参数量大幅减少；最后，引入 SFPN 模块后，模型对图像中的各个目标表现出清晰的关注。这表明 GSPN-YOLO 模型能够在复杂场景中有效地聚焦并准确定位目标。




图 8 热力图效果对比

3 结束语

在船舶检测领域中，船舶尺寸变化大、场景信息复杂且受天气影响显著，而当前基于深度学习的网络模型普遍面临参数量庞大、抗干扰能力不足的问题，提出了一种基于幽灵卷积和通道重排自适应多尺度特征金字塔的船舶检测模型 GSPN-YOLO。首先，GSPN-YOLO 用 GhostConv 替换了主干网络中的普通卷积，使然后利用简单的线性操作生成额外的幽灵特征图。这些幽灵特征图与初始特征图具有相似的表达能力，但计算成本却大大降低。其次，GSPN-YOLO 在主干网络中引入了 GhostNCSP 模块，通过结合幽灵卷积和残差连接，在减少模型参数量的同时有效提升了梯度流动。最后，提出了通道重排自适应多尺度特征金字塔，通过重排特征

融合网络，增加模型检测头，增强了多尺度特征提取能力。实验证明，GSPN-YOLO 在恶劣天气下具有更强的检测性能和鲁棒性以及更少的参数量，同时具有很好的泛化能力。未来的工作将引入红外图像数据集，通过多模态融合技术，提高模型的检测性能。

参考文献：

- [1] KULKARNI K, GOERLANDT F, LI J, et al. Preventing shipping accidents; Past, present, and future of waterway risk management with Baltic Sea focus [J]. Safety science, 2020, 129: 104798.
- [2] YU C, SHIN Y. SAR ship detection based on improved YOLOv5 and BiFPN [J]. ICT Express, 2024, 10 (1): 28 - 33.
- [3] LI K, WAN G, CHENG G, et al. Object detection in optical remote sensing images: A survey and a new benchmark [J]. ISPRS journal of photogrammetry and remote sensing, 2020, 159: 296 - 307.
- [4] ZHANG T, ZHANG X, LI J, et al. SAR ship detection dataset (SSDD): Official release and comprehensive data analysis [J]. Remote Sensing, 2021, 13 (18): 3690.
- [5] LI J, XU C, SU H, et al. Deep learning for SAR ship detection; Past, present and future [J]. Remote Sensing, 2022, 14 (11): 2712.
- [6] BO L I, XIAOYANG XIE, XINGXING WEI, et al. Ship detection and classification from optical remote sensing images: A survey [J]. Chinese Journal of Aeronautics, 2021, 34 (3): 145 - 163.
- [7] HUANG Q, SUN H, WANG Y, et al. Ship detection based on YOLO algorithm for visible images [J]. IET Image Processing, 2024, 18 (2): 481 - 492.
- [8] YASIR M, JIANHUA W, MINGMING X, et al. Ship detection based on deep learning using SAR imagery: a systematic literature review [J]. Soft Computing, 2023, 27 (1): 63 - 84.
- [9] ZHANG T, ZHANG X. Squeeze-and-excitation Laplacian pyramid network with dual-polarization feature fusion for ship classification in SAR images [J]. IEEE Geoscience and Remote Sensing Letters, 2021, 19: 1 - 5.
- [10] LI J, QU C, PENG S, et al. Ship detection in SAR images based on convolutional neural network [J]. Systems Engineering and Electronics, 2018, 40 (9): 1953 - 1959.
- [11] YU M, HAN S, WANG T, et al. An approach to accurate ship image recognition in a complex maritime transportation environment [J]. Journal of Marine Science and Engineering, 2022, 10 (12): 1903.
- [12] GUO J, FENG H, XU H, et al. D3-Net: Integrated multi-task convolutional neural network for water surface

- deblurring, dehazing and object detection [J]. *Engineering Applications of Artificial Intelligence*, 2023, 117: 105558.
- [13] LI Z, DENG Z, HAO K, et al. A Ship Detection Model Based on Dynamic Convolution and an Adaptive Fusion Network for Complex Maritime Conditions [J]. *Sensors*, 2024, 24 (3): 859.
- [14] ZHOU W, PENG Y. Ship detection based on multi-scale weighted fusion [J]. *Displays*, 2023, 78: 102448.
- [15] GHIASI G, LIN T Y, LE Q V. Nas-fpn: Learning scalable feature pyramid architecture for object detection [C] // Long Beach: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 7036 - 7045.
- [16] WANG K, LIEW J H, ZOU Y, et al. Panet: Few-shot image semantic segmentation with prototype alignment [C] // Long Beach: Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019: 9197 - 9206.
- [17] SOHAN M, SAIRAM T, RAMI REDDY C V. A review on yolov8 and its advancements [C] // Singapore: International Conference on Data Intelligence and Cognitive Informatics, 2024: 529 - 545.
- [18] YANG G, LEI J, ZHU Z, et al. AFPN: Asymptotic feature pyramid network for object detection [C] // Vienna: 2023 IEEE International Conference on Systems, Man, and Cybernetics (SMC), 2023: 2184 - 2189.
- [19] LIU S, HUANG D, WANG Y. Learning spatial fusion for single-shot object detection [J]. Eprint: ArXiv, 2019. DOI: arXiv: 1911.09516.
- [20] ZHENG Y, ZHANG S. Mcships: A large-scale ship dataset for detection and fine-grained categorization in the wild [C] // London: 2020 IEEE International Conference on Multimedia and Expo (ICME), 2020: 1 - 6.
- [21] SHAO Z, WU W, WANG Z, et al. Seaships: A large-scale precisely annotated dataset for ship detection [J]. *IEEE Transactions on Multimedia*, 2018, 20 (10): 2593 - 2604.
- [22] ZHANG Y, GUO Z, WU J, et al. Real-time vehicle detection based on improved yolo v5 [J]. *Sustainability*, 2022, 14 (19): 12274.
- [23] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors [C] // Vancouver: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 7464 - 7475.
- [24] WANG A, CHEN H, LIU L, et al. Yolov10: Real-time end-to-end object detection [J]. Eprint: ArXiv, 2024. DOI: ArXiv: 2405.14458.
- [25] WANG C Y, YE H I H, LIAO H Y M. Yolov9: Learning what you want to learn using programmable gradient information [J]. Eprint: ArXiv, 2024. DOI: ArXiv: 2402.13616.
- [26] KHANAM R, HUSSAIN M. Yolov11: An overview of the key architectural enhancements [J]. Eprint: ArXiv, 2024. DOI: ArXiv: 2410.17725.
- [27] ZHAO Y, LV W, XU S, et al. Detsr beat yolos on real-time object detection [C] // Seattle: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2024: 16965 - 16974.
- learning based ultrasonic guided wave pipe crack identification method [J]. *Measurement*, 2023, 206: 112277.
- [16] WEI M, ZHANG Z. Research on defect identification method of oil and gas pipeline based on ultrasonic echo signal [J]. *Nondestructive Testing and Evaluation*, 2025: 1 - 27.
- [17] QI Y, HE Y, QI X, et al. Dynamic snake convolution based on topological geometric constraints for tubular structure segmentation [C] // Proceedings of the IEEE/CVF International Conference on Computer Vision, 2023: 6070 - 6079.
- [18] HE K, ZHANG X, REN S, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition [Z]. 2014: 346 - 361.
- [19] 帅勃宇, 张雅丽. 改进 YOLOv8 的电动自行车电池检测算法 [J]. *电子测量技术*, 2025: 1 - 11.
- [20] YU F, KOLTUN V. Multi-scale context aggregation by dilated convolutions [J]. *Arxiv Preprint Arxiv*: 1511.07122, 2015.

(上接第 137 页)

- [11] YAN Y, LIU D, GAO B, et al. A deep learning-based ultrasonic pattern recognition method for inspecting girth weld cracking of gas pipeline [J]. *IEEE Sensors Journal*, 2020, 20 (14): 7997 - 8006.
- [12] PAN F, TANG D, GUO X, et al. Defect identification of pipeline ultrasonic inspection based on multi-feature fusion and multi-criteria feature evaluation [J]. *International Journal of Pattern Recognition and Artificial Intelligence*, 2021, 35 (11): 2150030.
- [13] GUANGLI X, ZHIHAO, ZHOU, SHUO, XIN, et al. Intelligent identification method for pipeline ultrasonic internal inspection [J]. *Nondestructive Testing and Evaluation*, 2024: 1 - 22.
- [14] LIANG H, CHENG G, ZHANG Z, et al. Research on ultrasonic defect identification method of well control manifold pipeline based on IAFSA-SVM [J]. *Measurement*, 2022, 194: 110854.
- [15] TANG R, ZHANG S, WU W, et al. Explainable deep