

基于空间一通道重构的轻量化遥感图像目标检测

葛芸^{1,4}, 陈金梁¹, 温宁³, 岑钰波¹, 王安妮¹, 王婷^{2,4}

1. 南昌航空大学 软件学院, 南昌 330063;
2. 南昌航空大学 土木与交通学院, 南昌 330063;
3. 上海龙旗科技股份有限公司, 上海 200233;
4. 慧航(江西)数字科技有限公司, 南昌 330038

摘要: 轻量化遥感图像目标检测在遥感数据高效处理与实际场景应用中具有关键价值, 而遥感图像中圆形或类方形目标(如油罐、车辆等)十分常见, 精准检测这类目标对资源监测、城市规划等任务具有重要意义。在遥感图像目标检测精度不断提升的背景下, 模型复杂度相应地显著增加, 现有遥感图像目标检测方法在精度与模型复杂度之间难以实现有效的平衡。针对上述问题, 在已有针对圆形或类方形目标检测网络的基础上, 提出了一种基于空间一通道重构的轻量化遥感图像目标检测方法, 旨在保持高精度的同时, 降低模型复杂度。首先, 针对特征图在空间维度上存在的冗余信息, 采用了空间重构单元, 根据空间特征丰富程度对特征图进行分离, 得到空间信息丰富组与空间信息冗余组, 再对两组进行交叉重构操作以减少空间特征冗余, 并增强遥感图像目标的空间特征表示; 然后, 针对特征图的通道信息冗余, 提出了基于部分卷积的通道重构单元, 将特征图从通道维度分割为两部分, 一部分使用部分卷积进行高效的特征提取, 另一部分使用点卷积获取隐藏的细节信息, 对两部分通道加权重构并拼接, 以更少的计算成本提取特征并增强了重要通道的特征表示。实验结果表明, 所提出的方法有效减少了模型的计算量与参数量, 并保持了良好的检测精度。

关键词: 遥感图像, 目标检测, 圆形目标, 模型轻量化, 重构单元

中图分类号: P2

引用格式: 葛芸, 陈金梁, 温宁, 岑钰波, 王安妮, 王婷. 2026. 基于空间一通道重构的轻量化遥感图像目标检测. 遥感学报, 30(6): 1871-1884

Ge Y, Chen J L, Wen N, Cen Y B, Wang A N and Wang T. 2026. Lightweight remote sensing image target detection based on spatial-channel reconstruction. National Remote Sensing Bulletin, 30(6): 1871-1884 [DOI: 10.11834/jrs.20265395]

1 引言

遥感图像目标检测在资源监测、城市规划等领域具有广泛应用(王宇, 2025)。与自然图像不同, 遥感图像通常覆盖广阔区域, 背景复杂, 且目标具有尺度多变、方向任意、分布密集等特点(Cheng和Han, 2016; Li等, 2025)。其中, 圆形或类方形目标(如油罐、车辆等)作为一类具有旋转不变特性的典型地物, 其精准检测对实际应用具有重要意义。然而, 这类目标在遥感图像中常呈现密集排列的特点, 且传统矩形检测框会引入大量背景干扰, 增加检测难度(Wen等, 2025)。

近年来, 深度学习显著推动了目标检测技术的发展, 但为追求更高精度, 模型复杂度也急剧增加。这在实际计算资源受限的边缘部署场景中面临严峻挑战(Hu等, 2021)。因此, 研究如何在保持精度的同时实现模型轻量化, 已成为遥感图像目标检测领域的关键问题(张省等, 2022; 秦煜等, 2025)。为实现模型轻量化, 研究者们提出了多种方法, 主要包括轻量化卷积与特征去冗余两种方式(李刚等, 2024)。在卷积神经网络中, 卷积层是模型的核心组件, 其计算量和参数数量占据模型的很大比重。因此, 优化卷积操作成为实现模型轻量化的关键(林景栋等, 2020)。常见的轻量化

收稿日期: 2025-09-25; 预印本: 2026-02-03

基金项目: 国家自然科学基金(编号: 42261070, 41801288); 江西省自然科学基金(编号: 20252BAC240256)

第一作者简介: 葛芸, 研究方向为人工智能、计算机视觉、遥感图像智能解译。E-mail: geyun@nchu.edu.cn

通信作者简介: 温宁, 研究方向为遥感图像目标检测。E-mail: wenning2000@foxmail.com

卷积操作包括深度可分离卷积 (Depthwise Separable Convolution) 和分组卷积 (Group Convolution) 等。Chollet (2017) 提出的深度可分离卷积, 将常规卷积拆解为深度卷积与点卷积两步, 能在与传统模型参数数量相近的前提下, 更高效地利用模型参数, 在图像分类等任务中实现精度与效率的平衡, 已成为卷积神经网络架构设计中的重要组件。分组卷积的概念可追溯至早期工作 (Krizhevsky 等, 2012), 其在 AlexNet 中为适配多 GPU 并行训练而被成功应用并广为人知。该操作通过将通道划分为独立分组进行卷积, 有效减少了参数数量和计算量, 为后续多种轻量化网络架构奠定了重要基础。Li 等 (2023) 通过引入空间—通道细化模块, 采用分组与重建策略, 在保持精度的同时有效降低了模型复杂度, 从而实现了效率与性能的平衡。Han 等 (2020) 提出 Ghost 模块, 先利用卷积生成基础特征图, 再以轻量级变换高效生成冗余特征, 在保证特征多样性的同时, 显著降低了计算成本。虽然分组卷积、深度可分离卷积在减少计算量和参数方面取得了一定成效, 但它们增加了网路宽度, 容易降低内存访问效率, 导致模型整体性能提升受限 (Phan 等, 2020)。因此, Chen 等 (2023) 为缓解轻量化卷积的内存访问效率问题, 提出了部分卷积。该模块通过对部分通道施行常规卷积, 再以点卷积整合信息, 协同降低了参数数量与内存访问成本, 从而在保持精度的同时提升了推理速度。

随着深度学习轻量化发展, 遥感图像目标检测领域也出现了许多轻量化工作 (王浩臣 等, 2024)。Xie 等 (2024) 基于 PP-YOLOE-R (Wang 等, 2022) 提出了 CSPPartial-YOLO 模型。其设计的部分混合空洞卷积模块, 通过结合部分卷积与混合空洞卷积, 以较低计算代价获取大感受野与丰富全局信息, 实现了模型轻量化与性能的有效兼顾。Shi 等 (2022) 为兼顾遥感图像分类性能与模型轻量化, 提出了自补偿卷积。该设计借鉴 Ghost 模块思路, 通过交替进行卷积与通道混合操作, 实现了特征的高效利用, 并基于此构建参数更少、分类性能更优的轻量级卷积神经网络。Zhao 等 (2024) 为提升遥感图像小目标检测性能, 设计了简单高效卷积模块。该模块通过融合分组卷积与多尺度卷积, 在扩展特征感受野的同时有效降低了计算冗余, 从而显著增强了模型对多尺度小目标的特征表征能力。这些方法虽然在一定程度上降低了参

数量, 但未能充分抑制特征图本身的空间与通道冗余, 在平衡精度与效率方面仍有提升空间。

特别地, 针对圆形及类方形目标, Ren 等 (2017) 提出的 Faster R-CNN 奠定了基于区域提议的两阶段检测器基础, 但其使用的水平矩形框对于圆形或密集分布的类方形目标会引入大量背景像素, 导致定位不准。Duan 等 (2019) 提出的 CenterNet 作为代表性无锚框方法, 简化了检测流程, 但其核心仍基于关键点建模, 难以精准拟合圆形目标的径向分布特性。Wang 等 (2022) 提出的 PP-YOLOE-R 通过引入旋转框来解决包括类方形目标 (如船舶、车辆) 在内的任意朝向目标的检测问题, 减少了水平框对密集、旋转目标的漏检和定位不准, 但其旋转矩形框对于圆形目标 (如油罐) 的检测效率与精度的提升并不明显, 且模型复杂度较高, 不利于边缘部署。Xie 等 (2024) 提出的 CSPPartial-YOLO 通过部分混合空洞卷积模块在降低参数数量的同时扩大感受野, 在轻量化方面取得了一定进展, 但其检测框架仍基于水平矩形框, 对圆形目标的形状适配性未有根本改善。前期针对圆形或类方形目标的基于自适应圆形感受野的遥感图像目标检测 ACRFNet (Wen 等, 2025) 工作, 通过圆形检测框有效降低背景干扰、适配目标形状特性, 但随着检测精度提升, 模型复杂度较高, 难以满足资源受限场景需求。

为了减少模型参数量, 进一步降低特征图信息冗余以保持模型精度, 提出了基于空间—通道重构的轻量化遥感图像目标检测方法, 在保持其对圆形或类方形目标检测优势的同时, 降低模型计算成本。首先, 针对特征图的空间冗余信息, 采用了空间重构单元, 旨在抑制特征在空间的冗余性, 增强空间特征表达。其次, 提出了基于部分卷积的通道重构单元, 通道重构单元能够重新整合各通道之间的信息, 减少通道维度的信息冗余, 结合部分卷积能够有效减少卷积层参数量并保持良好的特征提取能力。最后将空间—通道重构模块应用在 ACRFNet 中, 实现遥感图像特定目标的高效轻量化检测。

2 研究方法

2.1 空间—通道重构目标检测方法整体框架

ACRFNet 通过将矩形框替换为旋转不变的圆形

边界框, 显著减少背景干扰并简化角度建模; 同时引入自适应圆形卷积与特征金字塔, 增强对多尺度圆形或类方形目标的特征表达。基于ACRFNet提出基于空间—通道重构的轻量化遥感图像目标检测方法, 其整体框架如图1所示。该方法通过构建空间重构单元SRU (Spatial Reconstruction Unit) 以及基于部分卷积的通道重构单元PCR (Partial Convolution-based Channel Reconstruction Unit), 组成基于部分卷积的空间—通道重构单元PSCR (Partial Convolution-based Spatial-Channel Reconstruction Unit), 以实现特征图的空间与通道维度的精细化

重构。空间重构单元负责对输入特征图进行空间维度的重构, 根据空间信息丰富程度对输入特征图进行分组, 之后再对分组特征图进行交叉重建, 降低特征图在空间维度的冗余程度, 从而增强圆形或类方形目标的空间特征表示。随后空间重构特征图输入至通道重构单元, 通道重构单元则针对通道维度的特征进行处理, 根据通道信息丰富程度分割为两组, 信息丰富的通道使用部分卷积提取重要特征并减少参数量, 另一组通道使用点卷积提取具有隐藏细节的特征, 最后融合两组通道特征图得到空间与通道细化后的特征图。




图1 基于空间—通道重构的轻量化遥感图像目标检测

Fig.1 Lightweight remote sensing image target detection based on spatial-channel reconstruction

由于特征金字塔在进行特征融合操作时, 特征图的空间大小与通道数量都在不断地变化, 其空间特征与通道特征存在一定的冗余性。通过对空间与通道特征进行重组得到精细化的特征表示, 模型可以捕捉目标更具判别力的特征, 有助于区分不同目标的类别。但是过度对空间与通道重构容易丢失目标关键的位置信息, 使得模型难以准确学习目标定位参数。

因此, 在ACRFNet中, 首先将空间—通道重构单元PSCR应用于特征金字塔的输出部分以及分类检测头当中。在执行特征冗余抑制的过程中, 通过重构规则的差异化设计, 优先保留圆形目标的轮廓空间分布、类方形目标的结构通道特征, 确保轻量化改进不会过于削弱原模型对这类目标的特征提取能力, 进而维持其在特定目标检测场景下的适配性。其次, 由于ACRFNet当中的半径检测头以及中心点偏置检测头均用于回归圆形预测框, 且提取的特征具有高度相似性, 通过耦合这两个

检测头来高效复用特征, 从而避免因重复提取相似特征而产生的额外计算成本。最后, 为了在降低模型参数数量的同时保留目标的位置信息, 在定位检测头中采用了部分卷积进行特征提取。这种设计有效减少了模型参数量, 并保持了模型的检测精度。

2.2 空间重构单元

空间重构单元SRU用于抑制特征在空间维度的冗余, 增强特征空间信息的代表性 (Li等, 2023)。其流程分为分离阶段和重构阶段, 如图2所示。分离阶段根据输入特征图的空间信息丰富程度分为两组。具体来说, 首先会对输入特征图进行组归一化操作, 组归一化计算公式为

$$X_{out} = GN(X) = \gamma \frac{X - \mu}{\sqrt{\sigma^2 + \epsilon}} + \beta \quad (1)$$

式中, μ 和 σ 分别是输入特征图中的均值和标准差, γ 与 β 均是可训练参数, 添加一个小正数 ϵ 以保持稳定。使用组归一化层中的缩放因子 γ 衡量

输入特征图中空间像素的方差，空间信息越丰富，表明空间像素变化越大，其方差也越大。因此， γ

值越大表明空间信息越丰富。




图2 空间重构单元SRU

Fig.2 Spatial Reconstruction Unit

其次，对输入特征图中的每个通道的 γ 值进行归一化，其计算公式为

$$W_\gamma = \{w_i\} = \frac{\gamma_i}{\sum_{j=1}^C \gamma_j}, \quad i, j = 1, 2, \dots, C \quad (2)$$

式中， C 是输入通道数。首先根据权重 W_γ 对特征图进行加权，然后通过Sigmoid函数将加权后的权重值映射至 $(0, 1)$ 区间，最后通过预设的门限值 t 将映射后的权重进行划分：将高于门限值 t 的通道权重设置为1，得到信息丰富的权重 W_1 ；将低于门限值 t 的通道权重设置为0，得到信息较少的权重 W_2 。

在重构阶段，首先会根据信息丰富的权重 W_1 与信息较少的权重 W_2 分别对输入特征图进行相乘，得到空间信息丰富的 X_1^w 与空间信息较少的 X_2^w 。虽然 X_2^w 空间信息较少，但是直接丢弃可能会损失具有隐藏细节的特征，因此将 X_1^w 与 X_2^w 交叉重构能够补充额外的信息，生成信息更加丰富的空间特征，减少空间特征冗余。交叉重构操作方式为

$$\begin{cases} X_{11}^w \oplus X_{22}^w = X^{w1} \\ X_{21}^w \oplus X_{12}^w = X^{w2} \\ X^{w1} \cup X^{w2} = X^w \end{cases} \quad (3)$$

将 X_1^w 与 X_2^w 分别从各自通道维度按1:1比例分为 X_{11}^w 、 X_{12}^w 与 X_{21}^w 、 X_{22}^w ，然后交叉相加分别得到 X^{w1} 与 X^{w2} ，最后在通道维度进行拼接得到空间细化特征图 X^w 。这种交叉重构与均匀对半划分的设计，既能实现跨组信息交互以打破固有分组局限，又能以极低计算开销完成特征重构，同时还可以保持

特征图尺寸的完整性以方便后续处理。

2.3 基于部分卷积的通道重构单元

为了利用并减少特征图在通道维度的冗余性，提出了基于部分卷积的通道重构单元PCRU，如图3所示。通道重构单元紧接在空间重构单元之后，空间细化特征图被输入至通道重构单元。

通道重构单元主要由分割、变换、融合共3个阶段组成。首先，对空间细化特征图从通道维度进行分割，输入通道数为 C ，拆分后的通道数分别为 αC 和 $(1 - \alpha)C$ ， α 位于区间 $(0, 1)$ 之间。为了提高计算效率，对拆分后的特征图分别使用点卷积对通道数压缩，压缩至原来的一半，分别得到 X_{up} 和 X_{low} 。随后进入变换阶段，变换阶段分为上下两部分，在上变换阶段， X_{up} 特征图用于提取丰富的代表性特征 Y_1 ，采用高效的部分卷积与点卷积的方式代替常规卷积，其中部分卷积作为一种特征筛选机制，通过仅对部分通道进行运算，有效抑制了冗余信息干扰，并强化了关键通道内的空间特征学习，从而能以较低计算代价聚焦于目标的核心判别特征。在下变换阶段， X_{low} 特征图使用低成本点卷积计算，将点卷积得到的特征图与 X_{low} 进行拼接，得到具有隐藏细节的特征图 Y_2 。最后是融合阶段，对 Y_2 使用全局平均池化操作得到各个通道的全局空间信息，其计算公式为

$$S_m = Pooling(Y_m) = \frac{\sum_{i=1}^H \sum_{j=1}^W Y_c(i, j)}{H \times W} \quad (4)$$




图3 基于部分卷积的通道重构单元PCRUC

Fig.3 Partial convolution-based channel reconstruction unit

式中， $m = 1, 2$ ，代表对特征图 Y_1 和 Y_2 进行全局平均池化，对特征图每个通道的像素值相加取平均以代表该通道的全局空间信息，以此得到特征图 Y_1 和 Y_2 的全局空间信息 S_1 和 S_2 ，将 S_1 和 S_2 堆叠并使用SoftMax激活函数生成特征重要性向量 β_1 和 β_2 ，其计算公式为

$$\beta_1 = \frac{e^{s_1}}{e^{s_1} + e^{s_2}}, \beta_2 = \frac{e^{s_2}}{e^{s_1} + e^{s_2}}, \beta_1 + \beta_2 = 1 \quad (5)$$

式中， β_1 和 β_2 中的每个元素分别对应着特征图 Y_1 和 Y_2 中每一个通道，元素的大小反映着该通道在融合过程中重要程度。利用重要性向量 β_1 和 β_2 对特征图 Y_1 和 Y_2 加权，其计算公式为

$$Y = \beta_1 Y_1 + \beta_2 Y_2 \quad (6)$$

加权融合之后得到输出特征图 Y ，因此，模型能够根据各个通道的重要程度，自适应地调整每个通道在最终特征图中的贡献，增强模型对关键特征的学习能力。

在PCRUC的上变换过程中，使用了部分卷积与点卷积方式，以较低计算成本实现特征提取。部分卷积与点卷积的具体实现方式如图4所示。部分

卷积利用了特征图在通道维度的冗余性，只对部分通道进行特征提取，这种方式既降低了计算成本，又保留了较强的特征提取能力。具体来说，为了保持连续的内存访问，提高内存访问效率，部分卷积使用连续的部分通道作为整张特征图 F_1 的代表进行计算。首先对特征图连续的部分通道进行常规卷积，连续的部分通道数为 c_p ，特征图宽高为 w 、 h ，不改变输入输出特征图的大小及通道数。因此，设卷积核大小为 k ，则该部分卷积的浮点运算次数计算公式为

$$FLOPs_{\text{pconv}} = h \times w \times k^2 \times c_p^2 \quad (7)$$

将部分卷积输出的特征图与剩余通道特征图直接拼接得到特征图 F_2 。其次，在特征图 F_2 之后使用点卷积以获得通道与通道之间的特征关联，点卷积产生的浮点运算次数计算公式为

$$FLOPs_{\text{point}} = h \times w \times 1 \times 1 \times c^2 \quad (8)$$

使用点卷积之后得到最终特征图 F_3 ，总体的浮点运算次数计算公式为

$$FLOPs_{\text{All}} = h \times w \times (k^2 c_p^2 + c^2) \quad (9)$$




图4 部分卷积与点卷积的计算流程

Fig.4 The computational process of Partial Convolution and Point Convolution

使用相同大小的常规卷积运算产生的浮点运算次数计算公式为

$$FLOPs_{\text{Conv}} = h \times w \times k^2 \times c^2 \quad (10)$$

部分卷积加点卷积方式与常规卷积方式的浮点运算次数比值计算公式为

$$ratio = \frac{h \times w \times (k^2 c_p^2 + c^2)}{h \times w \times k^2 \times c^2} = \frac{k^2 c_p^2 + c^2}{k^2 c^2} = \frac{c_p^2}{c^2} + \frac{1}{k^2} \quad (11)$$

式中, 卷积核大小 k 一般为3, 当 c_p 与 c 的比值小于 $2\sqrt{2}/3$ 时, $ratio$ 小于1, 通常情况下, 部分通道数 c_p 取原通道数 c 的1/4。因此, 部分卷积加点卷积方式在保持良好的特征提取能力的同时, 计算量远远小于常规卷积。

3 实验与分析

3.1 数据集介绍

为验证本文方法的有效性, 使用公开的光学遥感图像数据集 NWPU VHR-10 (Cheng 和 Han, 2016) 和 DIOR (Li 等, 2020) 进行实验。NWPU VHR-10 数据集由西北工业大学发布。该数据集包含 800 张图像, 使用水平矩形框形式标注。其中 650 张图像含有标注信息, 150 张图像未有标注信息, 共有 3775 个目标实例, 10 个类别, 包括飞机、棒球场、油罐、篮球场、田径场、港口、桥梁、汽车、网球场、船只。DIOR 数据集是用于遥感图像目标检测的大规模光学遥感数据集。由西北工业大学发布, 采用水平矩形框形式标注, 该数据集包含 23463 张图像, 192472 个目标实例, 共 20 个类别。除了上述所提到的 10 个类别外, 还包括机场、烟囱、水坝、高速公路服务区、高速公路收费站、高尔夫球场、天桥、火车站、风磨以及体育场 10 个类别。

此外, 为了充分对比本文方法和其他方法的检测性能, 还在 HRRSD (Zhang 等, 2019) 数据集上进行实验。HRRSD 数据集包含 21761 张图像, 采用水平矩形框形式标注, 共有 55740 个目标实例, 13 个类别, 包括飞机、轮船、桥梁、地面轨迹、停车场、储罐、篮球场、网球场、十字路口、港口、车辆、交叉路口和停车场。

3.2 实验环境和评价指标

实验在 Windows 10 系统环境下进行, 使用的 CPU 为 Intel Xeon (R) Gold 5128R@2.10 GHz。显卡为 Nvidia GeForce RTX 3090, 显存为 24 GB。Python 版本为 3.7, Pytorch 版本为 1.7.1, 使用 CUDA11.2

进行加速训练。将 NWPU VHR-10 数据集、DIOR 数据集和 HRRSD 数据集各自划分为训练集、验证集和测试集, 比例分别为 7:2:1。

采用平均精确率 AP (Average Precision) 和平均精度均值 mAP (mean Average Precision) 进行模型精度的评估。AP 用以评估模型对于单个类别的检测精度, mAP 用以评估模型对于数据集整体的检测精度。AP 以及 mAP 均是在 IOU 阈值设定为 0.5 时所求得的值。模型复杂度使用模型的浮点运算次数 GFLOPs 以及模型参数量 Params 进行评估。

3.3 定位检测头解耦与耦合效果分析

为验证将半径检测头与中心点偏置检测头耦合能够降低计算量与参数量并保持检测精度, 在 NWPU VHR-10 数据集进行实验对比, 实验结果如表 1 所示。在半径与中心点偏置检测头解耦预测时, ACRFNet 的 GFLOPs 为 36.2, Params 为 25.9 M, mAP 为 91.2%。将半径检测头与中心点偏置检测头耦合共享权重后, GFLOPs 与 Params 分别为 34.9、25.8 M, 并且 mAP 为 90.5%, 精度损失很小。表明半径检测头与中心点偏置检测头输出的特征图具有一定的相似性。在共享权重后, 能够在减少计算量与参数量的同时保持良好的检测精度。

表 1 定位检测头解耦与耦合实验结果

Table 1 Experimental results of decoupling and coupling of positioning detection heads

解耦定位检测头	耦合定位检测头	mAP	GFLOPs	Params/M
√	—	91.2	36.2	25.9
—	√	90.5	34.9	25.8

注: 表中“√”代表使用该模块; “—”代表不使用该模块; 加粗字体表示同一列最佳结果。

3.4 空间重构与通道重构的消融分析

为验证空间重构单元 SRU 与基于部分卷积的通道重构单元 PCRU 的有效性, 在 NWPU VHR-10 进行消融实验, 该实验均使用耦合的定位检测头。消融实验结果如表 2 所示, 在仅使用 SRU 而不进行卷积的特征提取时, 虽然 GFLOPs 大幅降低, 降至 24.2, Params 减少了 0.6 M, 但是 mAP 下降至 88.1%, 精度损失较大。在仅使用 PCRU 进行特征提取与通道重构时, 能够看出 mAP 降幅并不大, 并且 GFLOPs 降低了 9.8, Params 降低了 0.6 M。最后, 同时使用 SRU 与 PCRU 时, mAP 比初始值好, 且 GFLOPs 与 Params 均有所降低, 特征在经过空间重构和基于

部分卷积的通道重构之后，增强了空间特征表示和关键通道的学习，不仅降低了计算量与参数量，还能保持良好的检测精度。

表2 SRU和PCRU的消融实验结果
Table 2 The ablation experimental results of SRU and PCRU

SRU	PCRU	mAP	GFLOPs	Params/M
—	—	90.5	34.9	25.8
√	—	88.1	24.2	25.2
—	√	89.8	25.1	25.2
√	√	91.2	25.1	25.2

注：表中“√”代表使用该模块；“—”代表不使用该模块；加粗字体表示同一列最佳结果。

为验证SRU中门限值 t 设置的有效性，对不同 t 值下的模型性能进行对比分析，实验结果如图5所示。图中清晰展示了mAP随 t 值变化的趋势：当 t 从0.1逐步增大至0.5时，mAP由89.9%较稳定地上升至峰值91.2%；而当 t 继续增大至0.9时，mAP则逐步下降至89.9%，整体呈现先升后降的分布规律。这一趋势表明， $t=0.5$ 能够在特征筛选与冗余抑制之间达到最佳平衡，从而获得最优检测性能；而 t 值偏离此最优值时，空间特征的重构效果下降，导致模型性能下降。




图5 SRU中不同门限值 t 对mAP的影响
Fig.5 The impact of different threshold values t in the SRU on mAP

为验证PCRU中分割比例 α 设置的有效性，对不同 α 取值下的模型性能进行对比分析，实验结果如表3所示。从理论角度而言，PCRU中的通道分割比例 α 直接决定了特征图在不同处理路径间的分配，进而影响模型的计算复杂度和参数规模。实验结果表明，当分割比例 α 从0.25提升至0.5时，模型mAP从90.4%显著提升至91.2%，达到最优性能，而GFLOPs和Params分别保持在25.1和25.2 M的相对较低水平；当 α 继续增大至0.75时，mAP下降至90.5%，同时GFLOPs略微上升至25.3，Params维持在25.3 M。这表明适当提高分割比例有助于

增强特征提取能力，但过高的比例会引入冗余计算而降低模型效率。综合结果表明，分割比例 $\alpha=0.5$ 能够在模型复杂度与检测精度之间实现最佳平衡。

表3 PCRU通道分割比例 α 的消融实验结果
Table 3 The ablation experimental results of the PCRU channel splitting ratio α

α	mAP	GFLOPs	Params/M
0.25	90.4	25.1	25.3
0.5	91.2	25.1	25.2
0.75	90.5	25.3	25.3

注：表中加粗字体表示同一列最佳结果。

3.5 部分卷积的性能分析

为验证通道重构单元CRU中部分卷积的有效性，在CRU中分别应用常规卷积和分组卷积进行特征提取，并与部分卷积在精度、计算量以及参数量方面进行对比，结果如表4所示。实验表明，常规卷积与部分卷积在精度上表现相近；与常规卷积比，分组卷积的计算量与参数量分别下降1.4 GFLOPs与0.1 M，不过，其mAP也随之降低1%。相比之下，部分卷积在检测精度、计算复杂度与参数量3项指标上均取得最优性能，表明其通过部分通道所提取的特征能有效代表整体特征图信息，在维持高精度的同时显著降低了计算与参数开销。

表4 CRU中不同卷积方法的有效性验证实验结果
Table 4 Experimental results of the effectiveness validation of different convolution methods in the CRU

常规卷积	分组卷积	部分卷积	mAP	GFLOPs	Params/M
√	—	—	89.7	27.7	25.4
—	√	—	88.7	26.3	25.3
—	—	√	91.2	25.1	25.2

注：表中“√”代表使用该模块；“—”代表不使用该模块；加粗字体表示同一列最佳结果。

3.6 特定目标的检测精度分析

为验证空间—通道重构单元PSCRU是否影响了ACRFNet对特定目标（包括飞机、棒球场、车辆、网球场和油罐5类目标）的检测精度，在NWPU VHR-10以及DIOR数据集进行实验，实验结果如表5所示。在NWPU VHR-10数据集的实验结果显示，在ACRFNet使用PSCRU之后，5个类别的圆形及类方形目标的AP值中，有3类目标精度有所提高，两类降低，总体变化不大。而DIOR数据集规模更大，背景更加复杂，难样本数量更多。在DIOR

数据集的实验结果显示，在使用 PSCRU 之后，4 类目标的 AP 值均有一定幅度的提高，棒球场 AP 值有所下降，但是下降幅度并不大。可以看出，在 ACRFNet 中应用 PSCRU 能够不影响甚至提高目标的检测精度。

表 5 在 NWPU VHR-10 与 DIOR 数据集上关于特定目标的检测精度 (AP) 对比
Table 5 Comparison of detection accuracy (AP) for specific objects on the NWPU VHR-10 and DIOR datasets

类别	NWPU VHR-10		DIOR	
	ACRFNet	本文方法	ACRFNet	本文方法
飞机	99.9	99.0	92.5	93.7
棒球场	99.3	99.7	95.7	95.1
车辆	93.7	94.1	55.9	57.0
网球场	91.6	89.2	92.2	94.7
油罐	97.6	97.7	77.8	79.8

注：表中加粗字体表示同一类别下，ACRFNet 与本文方法的最佳结果。

3.7 本文方法与一些主流方法对比分析

为验证本文方法在精度与复杂度之间实现了较好的权衡，在 NWPU VHR-10 与 DIOR 数据集上与多种主流遥感图像目标检测方法进行精度、计算量与参数量的比较，实验结果如表 6 所示。

表 6 不同方法在 NWPU VHR-10 与 DIOR 数据集上的比较结果
Table 6 The comparison results of different methods on NWPU VHR-10 and DIOR datasets

方法	NWPU VHR-10	DIOR	GFLOPs	Params/M
Faster R-CNN(Ren 等, 2017)	87.6	63.1	134.4	41.1
RetinaNet(Lin 等, 2018)	89.2	65.7	128.7	36.2
CenterNet(Duan 等, 2019)	85.1	73.9	35.1	32.6
YOLOX(Dong 等, 2024)	92.3	66.9	73.8	25.3
YOLOv7(Fan 等, 2024)	92.1	82.5	104.7	36.9
GLFE-YOLOX(Gu 等, 2024)	90.9	78.9	84.2	42.5
PCViT(Li 等, 2024)	96.6	80.3	349.1	112.4
MSNet(Gao 等, 2025)	96.0	75.3	98.1	29.8
QAGA-Net R50(Song 等, 2025)	94.1	69.5	291.0	67.2
SED-DETR(Yin 等, 2025)	94.7	80.3	71.0	52.2
ACRFNet(Wen 等, 2025)	91.2	74.0	36.2	25.9
本文方法	91.2	81.1	25.1	25.2

注：表中加粗字体表示同一列最佳结果。

在 NWPU VHR-10 数据集上的实验结果显示，PCViT 的 mAP 值最高，达到了 96.6%，但其计算量

和参数量高达 349.1 GFLOPs 和 112.4 M。MSNet、QAGA-Net R50 和 SED-DETR 在该数据集上同样表现优异，mAP 较高（分别为 96%、94.1%、94.7%），但计算量（分别为 98.1 GFLOPs、291.0 GFLOPs、71.0 GFLOPs）和参数量（分别为 29.8 M、67.2 M、52.2 M）均明显高于本文方法。相比之下，本文方法在保持 mAP 为 91.2% 的同时，计算量仅为 25.1 GFLOPs，参数量为 25.2 M，展现出明显的效率优势。与 YOLOX（mAP 为 92.3%，计算量为 73.8 GFLOPs，参数量为 25.3 M）相比，本文方法在精度接近的情况下，计算量降低 48.7 GFLOPs，参数量略低 0.1 M。

在 DIOR 数据集上的实验结果显示，YOLOv7 的 mAP 值最高，达到了 82.5%，但其计算量和参数量分别为 104.7 GFLOPs 和 36.9 M。本文方法的 mAP 为 81.1%，仅次于 YOLOv7，同时计算量比 YOLOv7 降低了 79.6 GFLOPs，参数量减少了 11.7 M。值得注意的是，MSNet、QAGA-Net R50 和 SED-DETR 在 DIOR 数据集上的表现均未超越本文方法，进一步证明本文方法在精度与效率之间取得了更佳平衡。

此外，在 HRRSD 数据集上进一步比较了本文方法与其他方法的性能，与 ARST-YOLOv7（周沁坤 等, 2025）、MSNet（Gao 等, 2025）、CenterNet（Duan 等, 2019）以及 ACRFNet（Wen 等, 2025）方法在精度、计算量、参数量以及 5 类特定目标上进行比较，实验结果如表 7 所示。MSNet 的 mAP 值最高，达到了 93.4%，ARST-YOLOv7 的 mAP 值也达到了 93.0%，但二者的计算成本较高，计算量分别为 98.1 GFLOPs 和 170.6 GFLOPs。相比之下，本文方法在保持较高检测精度（mAP 为 92.3%）的同时，仅需 25.1 GFLOPs 的计算量和 25.2 M 的参数，显著优于其他方法。从各类别的检测结果来看，本文方法在“飞机”类别上的检测精度达到 99.3%，在“棒球场”类别上的检测精度与 MSNet 并列最高，在“车辆”类别上也表现出色。虽然在“网球场”和“油罐”类别上的检测精度略低于部分方法，但整体表现均衡稳定。

综上所述，本文方法通过利用特征图的冗余特性，结合空间与通道重构有效增强了特征表达，在多个遥感目标检测数据集上均实现了精度与效率的良好平衡。本文方法在保持与现有方法相近精度的同时，显著降低了计算开销与模型参数量，进一步验证了其在精度与效率之间的优越平衡能力。

表 7 不同方法在 HRRSD 数据集上的比较结果
Table 7 The comparison results of different methods on HRRSD dataset

方法	mAP/%	GFLOP/s	Params/M	飞机/%	棒球场/%	车辆/%	网球场/%	油罐/%
ARST-YOLOv7(周沁坤 等,2025)	93.0	170.6	78.8	100.0	91.0	96.0	99.0	99.0
MSNet(Gao 等,2025)	93.4	98.1	29.8	99.5	94.8	97.3	96.5	97.8
CenterNet(Duan 等,2019)	91.8	35.1	32.6	98.5	94.4	88.5	85.4	94.4
ACRFNet(Wen 等,2025)	92.1	36.2	25.9	98.6	93.8	96.0	93.7	96.1
本文方法	92.3	25.1	25.2	99.3	94.8	96.2	89.0	95.6

注：表中加粗字体表示同一列最佳结果。

3.8 可视化结果分析

为了直观地显示本文方法的效果，进行了一系列的可视化实验结果展示。

图 6 展示了定位检测头解耦与耦合的检测效果。左、右两侧分别为解耦与耦合定位检测头的检测可视化检测结果。第 1 行展示了密集且部分受阴影或树木遮挡的汽车检测情况。解耦检测头在此复杂条件下定位精准，基本无漏检；耦合检测头虽定位效果与解耦检测接近，但出现了部分漏检。第 2 行展示了水域船只与尺度差异明显的圆形油罐检测效果。解耦检测头对不同尺寸的船只和油罐均能完整检出，定位较准确；耦合检测头对大部分目标定位效果较好，但对部分油罐的检测框容易出现尺寸偏大的情况。综合可视化结果与表 1 数据可知，两种检测头在定位精度上表现接近，但耦合检测头在参数量和计算量方面显著更低，展现了更好的计算效率。




图 6 定位检测头解耦与耦合的检测效果图
Fig.6 Detection results visualization of decoupled and coupled localization heads

图 7 直观地展示了 ACRFNet 分别增加 SRU、PCRU 以及同时增加 SRU 和 PCRU 的检测效果。第 1 行展示了排列较为规整但存在一定尺度差异的网球场检测效果，第 2 行展示了小尺度水域船只和密集多尺度的圆形油罐检测效果。第 1 列为 ACRFNet 的检测结果，网球场目标检测完整；水域船只定位准确，圆形油罐检测覆盖较全，但对较小尺度油罐存在轻微漏检。第 2 列为只增加 SRU 的检测结果，网球场出现明显漏检；水域船只定位仍较准确，但圆形油罐漏检增多，尤其对小尺度目标敏感度下降。第 3 列为只增加 PCRU 的检测结果，网球场漏检较 SRU 单独使用时有所改善；水域船只定位保持准确，圆形油罐漏检减少，但较小尺度目标仍未被完全检出。第 4 列为同时增加 SRU 和 PCRU 的检测结果，网球场目标检测完整；水域船只定位准确，各尺度油罐能够完整检测，不过，在左下角出现一例船只误检情况。

SRU 通过空间重构强化了特征的判别性，但在单独使用时可能因过度关注显著区域而降低了对小尺度细节的感知能力；PCRU 通过通道重构提升了特征的多维表达能力，但对极端尺度变化的鲁棒性仍显不足。当二者协同作用时，SRU 增强了空间结构的判别能力，PCRU 则促进了跨尺度的特征融合，形成有效的功能互补。这一联合机制在保持定位精度的同时，显著提升了模型对小尺度目标的敏感度与检出能力。实验表明，空间与通道重构的协同设计能够有效增强模型在多尺度目标检测中的综合性能。

图 8 直观地展示了常规卷积、分组卷积与部分卷积在遥感目标检测中的注意力区域差异，3 列图像分别对应 3 种卷积方法的可视化结果。第 1 行机场场景显示，常规卷积的关注区域较为分散；分组卷积的关注点更为集中；而部分卷积则能精准

聚焦于飞机本身及其核心结构，响应强度最高。第2行的油罐与船只场景表明，常规卷积仅对少量目标有微弱关注；分组卷积的关注范围更广但精度不足；部分卷积则对所有关键目标，尤其是小尺度船只和油罐，都生成了精准且高强度的注意力区域。




图7 SRU和PCRU的消融检测效果图
Fig.7 Detection results visualization of ablation study on SRU and PCRU




图8 CRU中不同卷积方法的检测效果图
Fig.8 Detection results visualization of different convolution methods in CRU

常规卷积因其全连接特性导致注意力分散；分组卷积通过限制组内连接使注意力更为集中，但组间信息隔离限制了其全局感知能力；部分卷积则通过动态权重与特征选择机制，能够自适应地聚焦于不同尺度的关键目标，从而在复杂背景下实现更精准的注意力分配与决策。

图9展示了Faster R-CNN、YOLOv7、YOLOX、CenterNet、ACRFNet以及本文方法在NWPU VHR-10与DIOR数据集上的检测效果。其中，飞机、棒球场、车辆和网球场目标选自NWPU VHR-10数据集，油罐目标选自DIOR数据集。红色箭头标示出了需要重点关注的检测区域。在飞机检测中，CenterNet出现漏检，而本文方法能够完整检测；在棒球场检测中，各方法均表现良好；在车辆检测中，Faster R-CNN、YOLO系列以及CenterNet方法漏检明显，但本文方法表现更优；在网球场检测中，FasterR-

CNN出现误检，YOLOv7存在重复检测，本文方法避免了上述出现的问题；在油罐检测中，各方法对小目标漏检严重，但本文方法检出率更高。

尽管本文方法在多数场景下表现良好，但在部分场景中仍存在一定局限：在极端遮挡的车辆场景下，由于空间—通道重构机制在特征严重缺失时难以恢复有效的判别性信息，导致模型对遮挡目标的识别能力下降；在密集小目标场景中，尽管PCRU模块增强了多尺度特征融合，但对极小油罐等目标的细微特征保持仍显不足，其在深层网络中的特征响应易被背景噪声淹没；此外，当前特征金字塔的跨尺度交互机制对极端尺度变化的目标仍缺乏充分的适应性，影响了模型在复杂场景中的鲁棒性。这些现象表明，本文方法在特征保留与冗余抑制的平衡上仍需进一步优化。




图9 不同方法在NWPU VHR-10与DIOR数据集上关于特定目标的检测效果图

Fig.9 Detection results visualization of different methods for specific targets on the NWPU VHR-10 and DIOR datasets

4 结 论

本文针对遥感图像目标检测中模型轻量化的关键需求,提出了一种创新的空间—通道重构轻量化方法 PSCRU,以优化 ACRFNet 的模型复杂度与检测精度。首先,采用了空间重构单元 SRU,通过衡量特征图的空间信息丰富程度进行分离操作,并使用交叉重构操作抑制特征在空间维度的冗余,增强空间维度的重要特征。其次,提出了基于部分卷积的通道重构单元 PCRU,在通道维度上通过部分卷积和点卷积的协同作用,高效提取重要特征并保留细节信息,从而降低计算成本。实验在 NWPU VHR-10、DIOR 与 HRRSD 数据集上验证了该方法的有效性,结果显示 PSCRU 显著减少了模型的计算量和参数量,同时保持甚至提升了检测精度。这表明本文方法在遥感图像目标检测领域具有重要的应用潜力,能够有效平衡模型精度与复杂度,满足实际场景中对高效、精准检测的需求。

参考文献 (References)

- Chen J R, Kao S H, He H, Zhuo W P, Wen S, Lee C H and Chan S H G. 2023. Run, don't walk: chasing higher FLOPS for faster neural networks//2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Vancouver: IEEE: 12021-12031 [DOI: 10.1109/CVPR52729.2023.01157]
- Cheng G and Han J W. 2016. A survey on object detection in optical remote sensing images. *ISPRS Journal of Photogrammetry and Remote Sensing*, 117: 11-28 [DOI: 10.1016/j.isprsjprs.2016.03.014]
- Chollet F. 2017. Xception: deep learning with depthwise separable convolutions//2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu: IEEE: 1800-1807 [DOI: 10.1109/CVPR.2017.195]
- Dong Y, Yang H T, Liu S L, Gao G S and Li C L. 2024. Optical remote sensing object detection based on background separation and small object compensation strategy. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 19: 3341-3351 [DOI: 10.1109/JSTARS.2024.3351140]
- Duan K W, Bai S, Xie L X, Qi H G, Huang Q M and Tian Q. 2019. CenterNet: keypoint triplets for object detection//2019 IEEE/CVF International Conference on Computer Vision. Seoul: IEEE: 6568-6577 [DOI: 10.1109/ICCV.2019.00667]
- Fan F, Zhang M, Yu D H, Li J J and Liu G W. 2024. Efficient remote sensing image target detection network with shape-location awareness enhancements. *IEEE Sensors Journal*, 24(19): 30654-30667 [DOI: 10.1109/JSEN.2024.3444920]
- Gao T, Xia S L, Liu M K, Zhang J, Chen T and Li Z Q. 2025. MSNet: multi-scale network for object detection in remote sensing images. *Pattern Recognition*, 158: 110983 [DOI: 10.1016/J.PATCOG.2024.110983]
- Gu Q, Huang H S, Han Z G, Fan Q S and Li Y T. 2024. GLFE-YOLOX: global and local feature enhanced YOLOX for remote sensing images. *IEEE Transactions on Instrumentation and Measurement*, 73: 2516112 [DOI: 10.1109/TIM.2024.3387499]
- Han K, Wang Y H, Tian Q, Guo J Y, Xu C J and Xu C. 2020. GhostNet: more features from cheap operations//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle: IEEE: 1577-1586 [DOI: 10.1109/CVPR42600.2020.00165]
- Hu X, Chu L Y, Pei J, Liu W Q and Bian J. 2021. Model complexity of deep learning: a survey. *Knowledge and Information Systems*, 63(10): 2585-2619 [DOI: 10.1007/s10115-021-01605-0]
- Krizhevsky A, Sutskever I and Hinton G E. 2012. ImageNet classification with deep convolutional neural networks//26th International Conference on Neural Information Processing Systems. Lake Tahoe: Curran Associates Inc.: 1097-1105
- Li G, Wang X H, Zhang D, Wu Z Y and Di L J. 2024. A lightweight algorithm for ship target detection in optical remote sensing imagery. *Space Electronic Technology*, 21(6): 50-56 (李刚, 王选宏, 张豆, 武子杨, 邸琳婕. 2024. 一种轻量化的光学遥感图像舰船目标检测算法. *空间电子技术*, 21(6): 50-56 [DOI: 10.3969/j.issn.1674-7135.2024.06.007])
- Li J F, Wen Y and He L H. 2023. SCConv: spatial and channel reconstruction convolution for feature redundancy//2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Vancouver: IEEE: 6153-6162 [DOI: 10.1109/CVPR52729.2023.00596]
- Li J J, Tian P H, Song R, Xu H T, Li Y S and Du Q. 2024. PCViT: a pyramid convolutional vision transformer detector for object detection in remote-sensing imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 62: 5608115 [DOI: 10.1109/TGRS.2024.3360456]
- Li K, Wan G, Cheng G, Meng L Q and Han J W. 2020. Object detection in optical remote sensing images: a survey and a new benchmark. *ISPRS Journal of Photogrammetry and Remote Sensing*, 159: 296-307 [DOI: 10.1016/j.isprsjprs.2019.11.023]
- Li Y S, Wang L L, Wang T Z, Yang X, Luo J W, Wang Q, Deng Y M, Wang W B, Sun X, Li H F, Dang B, Zhang Y J, Yu Y and Yan J C. 2025. STAR: a first-ever dataset and a large-scale benchmark for scene graph generation in large-size satellite imagery. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 47(3): 1832-1849 [DOI: 10.1109/TPAMI.2024.3508072]
- Lin J D, Wu X Y, Chai Y and Yin H P. 2020. Structure optimization of convolutional neural networks: a survey. *Acta Automatica Sinica*, 46(1): 24-37 (林景栋, 吴欣怡, 柴毅, 尹宏鹏. 2020. 卷积神经网络结构优化综述. *自动化学报*, 46(1): 24-37 [DOI: 10.16383/j.aas.c180275])
- Lin T Y, Goyal P, Girshick R, He K M and Dollár P. 2018. Focal loss for dense object detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 42(2): 318-327 [DOI: 10.1109/TPAMI.2018.2858826]
- Phan H H, Ha C T and Nguyen T T. 2020. Improving the efficiency of

- human action recognition using deep compression//2020 International Conference on Multimedia Analysis and Pattern Recognition. Ha Noi: IEEE: 1-6 [DOI: 10.1109/MAPR49794.2020.9237772]
- Qin Y, Lu C X, Liu Y L, Wu Q X, Zhang Q and Zhang X B. 2025. Algorithm for the fast detection of aircraft targets on the basis of optical remote sensing for embedded platforms. *National Remote Sensing Bulletin*, 29(3): 762-775 (秦煜, 陆陈鑫, 刘艳丽, 吴庆学, 张琦, 张小贝. 2025. 面向嵌入式平台的光学遥感飞机目标快速检测算法. *遥感学报*, 29(3): 762-775) [DOI: 10.11834/jrs.20233285]
- Ren S Q, He K M, Girshick R B and Sun J. 2017. Faster R-CNN: towards real-time object detection with region proposal networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(6): 1137-1149 [DOI: 10.1109/TPAMI.2016.2577031]
- Shi C P, Zhang X L, Sun J W and Wang L G. 2022. Remote sensing scene image classification based on self-compensating convolution neural network. *Remote Sensing*, 14(3): 545 [DOI: 10.3390/rs14030545]
- Song H X, Xia H J, Wang W H, Zhou Y, Liu W B, Liu Q and Liu J L. 2025. QAGA-Net: enhanced vision transformer-based object detection for remote sensing images. *International Journal of Intelligent Computing and Cybernetics*, 18(1): 133-152 [DOI: 10.1108/IJICC-08-2024-0383]
- Wang H C, Xin Y L, Guo J and Wang Q Q. 2024. Lightweight remote sensing ship detection algorithm based on YOLOv5s. *Chinese Journal of Ship Research*, 19(5): 200-207 (王浩臣, 辛月兰, 郭江, 王庆庆. 2024. 基于YOLOv5s的轻量化遥感舰船检测算法. *中国舰船研究*, 19(5): 200-207) [DOI: 10.19693/j.issn.1673-3185.03454]
- Wang X X, Wang G Z, Dang Q Q, Liu Y, Hu X G and Yu D H. 2022. PP-YOLOE-R: an efficient anchor-free rotated object detector. *arXiv*: 2211.02386 [DOI: 10.48550/arXiv.2211.02386]
- Wang Y. 2025. An overview of object detection algorithm based on deep learning. *Science & Technology Information*, 23(2): 64-66 (王宇. 2025. 基于深度学习的目标检测算法综述. *科技资讯*, 23(2): 64-66) [DOI: 10.16661/j.cnki.1672-3791.2407-5042-8334]
- Wen N, Ge Y, Yang X Y, Yu M G and Wang T. 2025. Adaptive circular receptive field for remote sensing image target detection. *IEEE Access*, 13: 30155-30166 [DOI: 10.1109/ACCESS.2025.3538575]
- Xie S Y, Zhou M, Wang C L and Huang S S. 2024. CSPPartial-YOLO: a lightweight YOLO-based method for typical objects detection in remote sensing images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 17: 388-399 [DOI: 10.1109/JSTARS.2023.3329235]
- Yin H T, Zhu Z Y and Wang H. 2025. SED-DETR: a scale-enhanced deformable detection transformer for remote sensing images. *IEEE Transactions on Geoscience and Remote Sensing*, 63: 5624412 [DOI: 10.1109/TGRS.2025.3571033]
- Zhang S, Li S S, Wei G F, Zhang X N and Gao J W. 2022. Refined multi-scale feature-oriented object detection of the remote sensing images. *National Remote Sensing Bulletin*, 26(12): 2616-2628 (张省, 李山山, 魏国芳, 张新耐, 高建威. 2022. 面向精细化多尺度特征的遥感图像目标检测. *遥感学报*, 26(12): 2616-2628) [DOI: 10.11834/jrs.20221801]
- Zhang Y L, Yuan Y, Feng Y C and Lu X Q. 2019. Hierarchical and robust convolutional neural network for very high-resolution remote sensing object detection. *IEEE Transactions on Geoscience and Remote Sensing*, 57(8): 5535-5548 [DOI: 10.1109/TGRS.2019.2900302]
- Zhao F Y, Zhang J W and Zhang G P. 2024. FFEDet: fine-grained feature enhancement for small object detection. *Remote Sensing*, 16(11): 2003 [DOI: 10.3390/rs16112003]
- Zhou Q K, Zhou H P, Sun K L and Deng B. 2025. ARST-YOLOv7: small target detection network for aerial remote sensing images. *Computer Engineering and Applications*, 61(12): 232-242 (周沁坤, 周华平, 孙克雷, 邓彬. 2025. ARST-YOLOv7: 用于航空遥感图像的小目标检测网络. *计算机工程与应用*, 61(12): 232-242) [DOI: 10.3778/j.issn.1002-8331.2406-0167]

Lightweight remote sensing image target detection based on spatial-channel reconstruction

GE Yun^{1,4}, CHEN Jinliang¹, WEN Ning³, CEN Yubo¹, WANG Anni¹, WANG Ting^{2,4}

1. School of Software, Nanchang Hangkong University, Nanchang 330063, China;

2. School of Civil Engineering and Transportation, Nanchang Hangkong University, Nanchang 330063, China;

3. Shanghai Longcheer Technology Company Ltd., Shanghai 200233, China;

4. Huihang (Jiangxi) Digital Technology Company Ltd., Nanchang 330038, China

Abstract: In the field of computer vision, lightweight target detection in remote sensing images is an academically challenging research topic. With the continuous improvement in the accuracy of remote sensing target detection, the complexity of models has increased significantly. Existing remote sensing object detection methods struggle to strike a good balance between accuracy and model complexity. Unlike conventional natural images, remote sensing images have a large imaging area, limited available information, and a multitude of target types. The vast amount of background information can easily interfere with detection, and the excessive number of target categories

makes it difficult to achieve high-precision detection of specific targets. Moreover, targets in remote sensing images are densely packed and arbitrarily rotated and exhibit significant scale variations, posing a great challenge for target localization. While the accuracy continues to improve in remote sensing image target detection, models have become increasingly complex in pursuit of high precision. These complex models' heavy computational load and large parameter count severely restrict practical application on resource-constrained devices; model lightweighting has become a key factor in promoting technological application.

To address the aforementioned issues, this study proposes a lightweight remote sensing image target detection method based on spatial-channel reconstruction, aiming to maintain high-precision detection of circular and rectangular targets while reducing model complexity. First, in response to the redundant information within feature maps at the spatial dimension, a spatial reconstruction unit is adopted. It separates feature maps on the basis of the richness of spatial features (i.e., into groups with abundant spatial information and groups with redundant spatial information) and then performs cross-reconstruction operations on the two groups to reduce spatial feature redundancy and enhance the spatial feature representation of remote sensing image targets. Subsequently, to address the redundancy of channel information in feature maps, a partial convolution-based channel reconstruction unit is proposed. It divides feature maps into two parts along the channel dimension: One part uses partial convolution for efficient feature extraction, and the other part uses pointwise convolution to obtain hidden detailed information. The two parts are weighted, reconstructed, and then concatenated to extract features at a decreased computational cost and enhance the representation of important channels.

The lightweight method based on spatial-channel reconstruction is applied to ACRFNet, an adaptive circular receptive field network for remote sensing image target detection. Experimental results on the NWPU VHR-10, DIOR, and HRRSD datasets verify its performance. Specifically, the method can maintain or even improve detection accuracy while significantly reducing the model's computational load and parameter volume. Compared with other mainstream methods for remote sensing image target detection, the proposed method demonstrates obvious advantages in balancing detection accuracy and model complexity, especially for circular and rectangular targets that are difficult to detect.

The proposed method effectively solves the core problem of balancing detection accuracy and model complexity. By reducing feature redundancy, it overcomes the deployment limitations of complex models on resource-constrained devices, retains good adaptability to typical targets, and provides reliable technical support for the practical application of remote sensing target detection technology.

Key words: remote sensing imagery, object detection, circular target, model lightweighting, reconstruction unit

Supported by National Natural Science Foundation of China (No. 42261070, 41801288); Jiangxi Provincial Natural Science Foundation (No. 20252BAC240256)