CN 51-1346/O4 ISSN 1003-501X (印刷版) ISSN 2094-4019 (网络版)

光电工程
Opto-Electronic Engineering

中文核心期刊 中国科技核心期刊
Scopus CSCD

融合视觉中心机制和并行补丁感知的遥感图像检测算法

梁礼明，陈康泉，王成斌，冯耀，龙鹏威

引用本文:

梁礼明，陈康泉，王成斌，等. 融合视觉中心机制和并行补丁感知的遥感图像检测算法[J]. 光电工程，2024， **51**(7): 240099.

Liang L M, Chen K Q, Wang C B, et al. Remote sensing image detection algorithm integrating visual center mechanism and parallel patch perception[J]. *Opto-Electron Eng*, 2024, **51**(7): 240099.

https://doi.org/10.12086/oee.2024.240099

收稿日期: 2024-05-01; 修改日期: 2024-07-10; 录用日期: 2024-07-10

相关论文

特征协同与细粒度感知的遥感图像小目标检测
肖振久，张杰浩，林渤翰
光电工程 2024, **51**(6): 240066 doi: 10.12086/oee.2024.240066

面向遥感图像检索的级联池化自注意力研究
吴刚，葛芸，储珺，叶发茂
光电工程 2022, **49**(12): 220029 doi: 10.12086/oee.2022.220029

结合遥感卫星及深度神经决策树的夜间海雾识别
李涛，金炜，符冉迪，李纲，尹曹谦
光电工程 2022, **49**(9): 220007 doi: 10.12086/oee.2022.220007

基于多尺度特征融合的遥感图像小目标检测
马梁，苟于涛，雷涛，靳雷，宋怡萱
光电工程 2022, **49**(4): 210363 doi: 10.12086/oee.2022.210363

更多相关论文见光电期刊集群网站

OEE 光电工程 Opto-Electronic Engineering
http://cn.oejournal.org/oee

OE_Journal
Website

Opto-Electronic Engineering
光 电 工 程

Article

2024 年, 第 51 卷, 第 7 期

DOI: 10.12086/oee.2024.240099

融合视觉中心机制和并行补丁感知的遥感图像检测算法

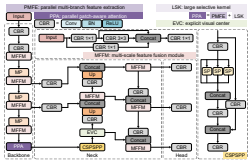

梁礼明，陈康泉*，王成斌，冯　耀，龙鹏威

江西理工大学电气工程与自动化学院，江西 赣州 341000

摘要：针对遥感图像存在复杂背景干扰、目标多尺度差异和微小目标提取难的问题，本文基于 YOLOv7-tiny 模型提出一种融合视觉中心机制和并行补丁感知的遥感图像检测算法。该算法一是引入显式视觉中心机制，构建像素点间的长距离依赖关系，丰富图像的整体语义信息，同时提升对目标纹理的提取性能；二是改进并行补丁感知模块，调整特征提取感受野，以适应不同目标尺度；三是设计多尺度特征融合模块，实现对多层特征的高效融合，提升模型推理速度。在公共数据集 RSOD 上进行实验，所提算法的准确率、召回率和平均准确率均值相较 YOLOv7-tiny 分别提升 1.5%、2.4% 和 2.4%，此外在 NWPU VHR-10 和 DOTA 数据集上进行泛化性验证，结果表明本文算法具备较强的泛化性能。通过与不同算法对比分析，进一步体现本文算法性能的优越性。

关键词：遥感图像；目标检测；YOLOv7-tiny；显式视觉中心机制；并行补丁感知

中图分类号：TP391　　**文献标志码：**A

梁礼明，陈康泉，王成斌，等. 融合视觉中心机制和并行补丁感知的遥感图像检测算法 [J]. 光电工程，2024，**51**(7): 240099
Liang L M, Chen K Q, Wang C B, et al. Remote sensing image detection algorithm integrating visual center mechanism and parallel patch perception[J]. *Opto-Electron Eng*, 2024, **51**(7): 240099

Remote sensing image detection algorithm integrating visual center mechanism and parallel patch perception

Liang Liming, Chen Kangquan*, Wang Chengbin, Feng Yao, Long Pengwei

School of Electrical Engineering and Automation, Jiangxi University of Science and Technology, Ganzhou, Jiangxi 341000, China

Abstract: To address the challenges of complex background interference, multi-scale differences in targets, and the difficulty in extracting small targets from remote sensing images, this paper proposes a remote sensing image detection algorithm based on the YOLOv7-tiny model that integrates the visual center mechanism and parallel patch perception. Firstly, the algorithm introduces an explicit visual center mechanism to establish long-distance dependencies between pixels, enriching the overall semantic information of the image and improving the extraction performance of target textures. Secondly, it improves the parallel patch perception module by adjusting the feature extraction receptive fields to adapt to different target scales. Thirdly, a multi-scale feature fusion module is designed

收稿日期：2024-05-01；修回日期：2024-07-10；录用日期：2024-07-10

基金项目：国家自然科学基金资助项目 (51365017，61463018)；江西省自然科学基金资助项目 (20192BAB205084)；江西省教育厅科学技术研究青年项目 (GJJ2200848)

*通信作者：陈康泉，1136344152@qq.com。

to efficiently fuse multi-layer features, thereby improving the model's inference speed. Experimental results on the RSOD dataset show that the proposed algorithm achieves improvements over YOLOv7-tiny in terms of precision, recall, and mean average precision by 1.5%, 2.4%, and 2.4%, respectively. Additionally, validation on the NWPU VHR-10 and DOTA datasets confirms the strong generalization performance of the proposed algorithm. Comparative analysis with other algorithms further demonstrates the superior performance of the proposed approach.

Keywords: remote sensing images; object detection; YOLOv7-tiny; explicit visual center mechanism; parallel patch perception

1 引　言

光学遥感图像目标检测旨在准确定位和分类感兴趣的目标，适用于情报侦察、目标监视和灾害救援等领域[1-2]。在不同领域的应用场景中，对于多尺度目标和微小目标的定义各有不同。本文基于绝对尺度，将小于 32 pixel×32 pixel 的目标定义为微小目标，将大于等于 32 pixel×32 pixel 且小于等于 96 pixel×96 pixel 的目标定义为中目标，将大于 96 pixel×96 pixel 的目标定义为大目标，将具有不同大小的目标统称为多尺度目标。由于遥感图像存在复杂背景、密集分布和尺度多变等挑战，亟需设计高效准确的检测算法[3-4]。在传统的遥感图像目标检测算法中，一种是基于模板匹配，计算输入图像中特定区域的特征向量与模板特征向量的匹配度；另一种是基于人工先验规则，获取候选区域以建立目标的特征表示。这两种检测算法理论完备、检测精度较高，但难以对多样化任务场景及目标进行充分特征表示，且滑动窗口式效率低下，导致其目标检测的精度和速度难以满足实际需求。随着深度学习的发展，光学遥感图像目标检测取得重大进展。基于深度学习的遥感图像目标检测算法可分为基于候选区域的算法和回归分析的算法。前者又称双阶段算法，第一阶段用于生成可能包含目标的候选区域，第二阶段对候选区域进行分类及边界框回归。其代表算法有 R-CNN[5]、Fast R-CNN[6]、Faster R-CNN[7] 和 Mask R-CNN[8] 等，该类算法检测精度较高但计算量大导致速度难以满足实时性需求。而后者又称单阶段算法，从输入图像的多个位置直接回归分析出目标的边界框和类别。其典型算法有 SSD[9] 和 YOLO[10-12] 系列等，更好地兼顾检测精度和速度。

早期的遥感目标检测器通常基于卷积神经网络 (convolutional neural network, CNN)[13]，其性能受到卷积操作固有局部性的严重限制，只能定位局部最具有代表性的目标区域，且计算复杂度较高。Gao 等[14] 提出用于在卷积神经网络中进行高效的感受野 (receptive field, RF) 搜索算法 RF-Next，该算法通过全局到局部的搜索方案，寻找更好的感受野组合，以提高目标检测的性能，但搜索更好的感受野组合需要更多的计算资源和时间，尤其是当感受野范围较大时。针对复杂背景干扰和小物体特征提取难的问题，文献 [15] 构建一种针对遥感目标检测的全局到局部尺度感知检测网络 GLSANet，引入全局语义学习交互模块来挖掘和强化深度特征图中的高级语义学习，缓解前景对象上复杂背景的障碍；引入局部注意力金字塔抑制较浅特征图中的背景和噪声，突出小物体的特征表示，但该网络对大尺度目标的表现效果欠佳。Zhang 等[16] 在 YOLOv5s 算法[17] 基础上构建一种快速的目标检测算法 SuperYOLO, 该算法通过简单的辅助超分辨率分支来学习高分辨率目标检测，取得较好的检测效果，但在处理复杂背景的遥感图像时仍存在微小目标特征信息丢失的问题。因此，为解决遥感图像目标检测当前存在的技术挑战，本文以 YOLOv7-tiny 为基线模型，提出一种融合视觉中心机制和并行补丁感知的遥感图像检测算法，提升遥感图像目标检测的准确性，主要工作如下：

1) 利用显式视觉中心机制模块 (explicit visual center, EVC)[18]，建立全局长距离依赖关系，以捕获上下文信息的中心特征，同时聚合层内局部区域信息，以捕获局部具有代表性的特征表示，进一步提升对目标纹理的提取性能。

2) 优化并行补丁感知模块 (parallelized patch-aware module, PPA)，动态调整特征提取感受野，捕获不同尺度的特征信息，有效地适应和处理广泛的背景。

3) 设计多尺度特征融合模块 (multi-scale feature fusion module, MFFM)，高效融合来自不同层次的特征，全面捕捉目标的多样化表征，提升检测

速度。

2 本文算法

2.1 YOLOv7-tiny 算法

本研究基于 YOLOv7-tiny 算法进行改进。该算法是一种轻量级的目标检测算法，主要由三个核心组件构成：Backbone 网络、Neck 网络和 Head 层。其中，Backbone 网络包括卷积计算单元、高效层聚合网络 (efficient layer aggregation networks, ELAN) 和最大池化层，用于从输入图像中提取特征。Neck 网络用于融合 Backbone 提取的多尺度特征。Head 层则负责根据融合特征层进行目标检测的分类和回归预测。在此基础上，本文对 YOLOv7-tiny 算法进行改进，以提高其在遥感图像目标检测中的性能。

2.2 算法设计

为了增强网络全局信息感知能力以及聚合丰富的细节信息，针对遥感图像复杂背景、目标多尺度和微小目标的特点，本文基于 YOLOv7-tiny 模型提出一种融合视觉中心机制和并行补丁感知的遥感图像检测算法，其整体结构如图 1 所示。首先引入显式视觉中心机制，通过轻量级多层感知机 (lightweight multilayer perceptron, LMLP) 模块实现全局长距离遥感建模，着眼于全局的关键特征，同时使用可学习的视觉中心机制 (learnable visual center, LVC) 模块聚合输入图像的局部关键区域，捕获局部极具区分性的特征表示，提升对目标纹理的提取性能；其次改进并行补丁感知模块，动态调整特征提取感受野，丰富上下文特征语义信息，获取多尺度特征信息；最后设计多尺度特征融合模块，实现对多层特征的高效融合，不仅有效降低计算时间，而且满足高精度的检测需求。

2.3 显式视觉中心机制模块

标准 CNN 骨干网络在目标检测方面取得初步成功，但受限于有限的感受野，仅能定位局部特征区域。为解决 CNN 中有限局部特征的问题，引入显式视觉中心机制模块以建立图像全局长距离依赖关系，同时关注层内局部区域特征，其结构如图 2 所示，EVC 模块主要包括 LMLP 块和 LVC 块两条分支。对于给定输入特征X_{in}，该模块首先使用 Stem 模块提取初始特征并划分，然后将划分后的特征图X_{in}^1和X_{in}^2输入到 LMLP 块和 LVC 块这两条分支进行特征优化，最后利用拼接操作和1×1的标准卷积融合两个分支的结果，其计算过程分别如下：

$$X_{\text{in}}^1, X_{\text{in}}^2 = Split(X_{\text{in}}), \tag{1}$$

$$X_{\text{o}} = C_{1\times1}(Cat(LLMP(X_{\text{in}}^1), LVC(X_{\text{in}}^2))), \tag{2}$$

其中：$LMLP(\cdot)$表示轻量级 MLP，$LVC(\cdot)$表示可学习的视觉中心机制，$Cat(\cdot)$表示拼接操作，$C_{1\times1}(\cdot)$表示1×1卷积操作，X_{o}表示 EVC 模块的输出。

LMLP 块主要强调空间中每个像素点之间的远程

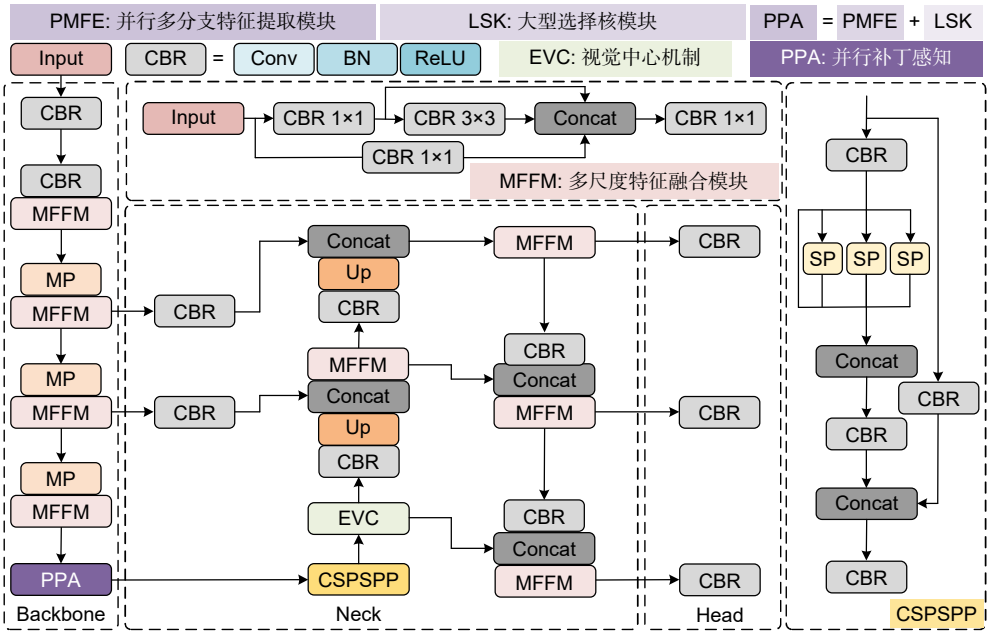

图 1 融合视觉中心机制和并行补丁感知的遥感图像检测模型

Fig. 1 Remote sensing image detection model integrating visual center mechanism and parallel patch perception

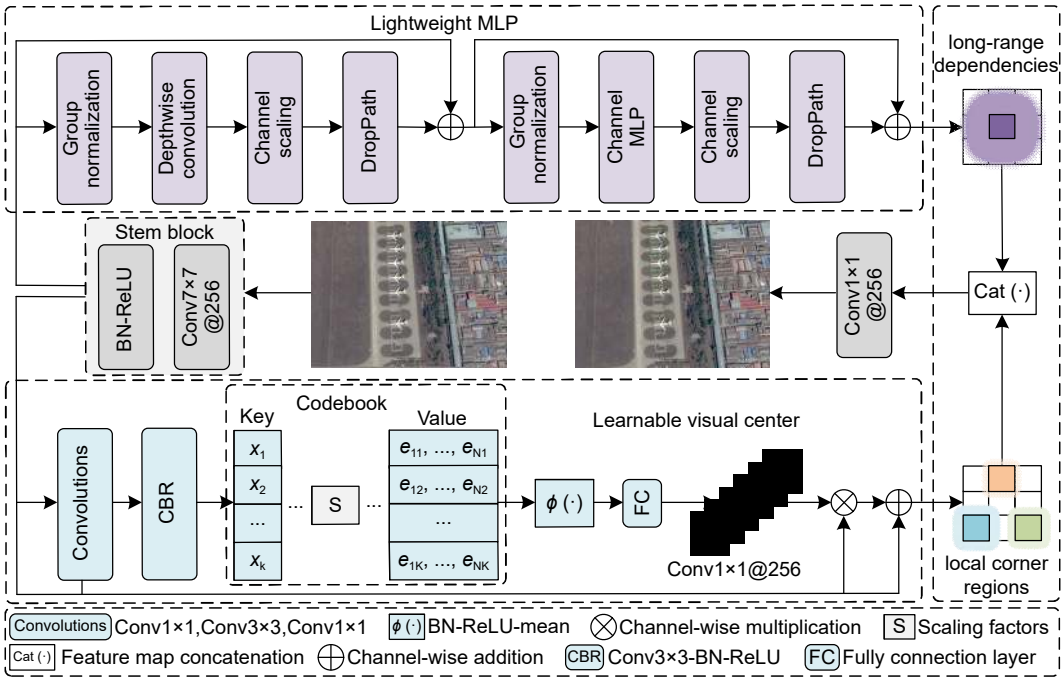

图 2 显式视觉中心机制

Fig. 2 Explicit visual center mechanism

依赖关系，填补局部细节信息生成分支的语义空白。给定输入特征X_{in}^{1}，首先对其进行组归一化操作消除尺度差异，并使用深度可分离卷积操作实现降维；其次采用通道缩放增强特征的多样性；再次经过正则化减少过拟合风险；最后将正则化输出特征与给定输入特征X_{in}^{1}进行逐元素加法操作，以增强特征交互。上述输出特征经过组归一化、通道 MLP、通道缩放和正则化操作，并与该特征进行逐元素加法操作。其过程分别表述为

$$X_{\text{in}}^{1'}=DP(SC(DC(GN(X_{\text{in}}^{1}))))\oplus X_{\text{in}}^{1}, \tag{3}$$

$$LMLP_{\text{o}}=DP(SC(CMLP(GN(X_{\text{in}}^{1'}))))\oplus X_{\text{in}}^{1'}, \tag{4}$$

其中：$GN(\cdot)$表示组归一化，$DC(\cdot)$表示1×1深度卷积操作，$SC(\cdot)$表示通道缩放，$DP(\cdot)$表示正则化，$\oplus$表示逐元素加法，$CMLP(\cdot)$表示通道 MLP 操作，$LMLP_{\text{o}}$表示 LMLP 块的输出。

LVC 块分支主要是在训练过程中通过反向传播算法对参数进行优化，从给定特征图中挖掘感兴趣的局部细节特征。首先对其经过一个1×1、一个3×3和一个1×1卷积操作调整特征维度，并进行批归一化和激活函数结合操作以消除梯度消失问题；然后采用编码映射捕获数据之间的关系；再后经过批归一化、正则化和均值池化组合操作，以提升特征表达能力，并通过全连接层和1×1卷积整合特征信息；最后将上述输出特征与给定输入特征进行逐元素乘法和加法操作。其具体表达式分别为

$$X_{\text{in}}^{2'}=CBR(C_{1\times1}(C_{3\times3}(C_{1\times1}(X_{\text{in}}^{2})))), \tag{5}$$

$$e_k=\sum_{i=1}^{n}\frac{\mathrm{e}^{-s_k\left\|x_i^{2'}-b_k\right\|^2}}{\sum^{K}\mathrm{e}^{-s_k\left\|x_i^{2'}-b_k\right\|^2}}(x_i^{2'}-b_k), \tag{6}$$

$$e=C_{1\times1}\left(FC\left(\sum_{k=1}^{K}\phi(e_k)\right)\right), \tag{7}$$

$$LVC_{\text{o}}=X_{\text{in}}^{2}\oplus(X_{\text{in}}^{2}\otimes e), \tag{8}$$

其中：$C_{3\times3}(\cdot)$表示3×3卷积操作，$CBR(\cdot)$表示批归一化和激活函数结合操作，$X_{\text{in}}^{2'}$表示第 i 个像素点，b_k表示第 k 个码字，s_k表示第 k 个缩放因子，$x_i^2-b_k$表示像素位置对应的码字信息，K表示可视化中心的总数，$FC(\cdot)$表示全连接层操作，$\otimes$表示逐元素乘法操作，LVC_{o}表示 LVC 模块的输出。

2.4 并行补丁感知模块

为解决微小目标定位难和识别难的挑战，引入并行补丁感知模块。该模块由并行多分支特征提取模块 (parallel multi-branch feature extraction module, PMFE)[19] 和大型选择核模块 (large selective kernel module, LSK)[20] 组成。PPA 模块使用并行多分支特征提取策略，捕获不同尺度及层次特征信息，从而提高小目标检测的准确性；采用大型选择核模块自适应增

强小目标的特征表示，保留下采样后的关键信息。

2.4.1 并行多分支特征提取模块

PMFE 模块包含全局、局部和串行卷积分支，每个分支负责不同尺度的特征提取，结构如图 3 所示。该模块首先通过逐点卷积将给定输入特征张量 $\boldsymbol{F}\in R^{H'\times W'\times C}$ 调整为 $\boldsymbol{F}'\in R^{H'\times W'\times C'}$；然后通过3×3卷积计算得到串行卷积特征张量 $\boldsymbol{F}_{\text{conv}}\in R^{H'\times W'\times C'}$；其次通过不同大小的补丁感知子块实现全局和局部特征信息的提取与交互，分别得到全局特征张量 $\boldsymbol{F}_{\text{global}}\in R^{H'\times W'\times C'}$ 和局部特征张量 $\boldsymbol{F}_{\text{local}}\in R^{H'\times W'\times C'}$；最后将并行多分支结果叠加得到输出特征张量 $\tilde{\boldsymbol{F}}\in R^{H'\times W'\times C'}$。其计算式为

$$\tilde{\boldsymbol{F}}=\boldsymbol{F}_{\text{global}}+\boldsymbol{F}_{\text{local}}+\boldsymbol{F}_{\text{conv}}\,, \tag{9}$$

其中：补丁感知子块的全局和局部特征信息提取与交互通过空间维度聚合与移位非重叠补丁实现。该过程首先展开并重塑，将 $\boldsymbol{F}'$ 划分为空间连续的补丁 $p\times p,\frac{H'}{p},\frac{W'}{p},C'$；然后经过通道方向平均化处理，得到 $p\times p,\frac{H'}{p},\frac{W'}{p}$；其次使用前馈神经网络进行线性计算，应用激活函数 *Softmax* 获取特征的概率分布，并调整其权重，*Softmax* 激活函数计算式为

$$Softmax(z_i)=\frac{e^{z_i}}{\sum_j^K e^{z_j}}\,, \tag{10}$$

其中：$Softmax(z_i)$ 表示第 i 个元素的概率值，e表示自然对数的底，K 表示向量的长度；最后使用特征选择从标记和通道中捕获重要特征。

2.4.2 大型选择核模块

LSK 模块的主要任务是动态调整特征提取感受野，处理多样化的背景，提高小目标的检测性能。在模块中添加跳跃连接，进一步丰富特征语义信息，其结构如图 4 所示。对于给定输入特征 X，首先利用两个大核选择块 (LK selection, LK)[21] 扩大感受野，然后将不同感受野的特征拼接以扩大感受野覆盖范围，最后经过平均和最大池化及卷积处理丰富特征多样性。其计算式分别为

$$U_0=X,\ \widetilde{U}_1=F_1^{1\times1}(U_0),\ \widetilde{U}_2=F_2^{1\times1}(U_0)\,, \tag{11}$$

$$\widetilde{U}=[\widetilde{U}_1;\widetilde{U}_2]\,, \tag{12}$$

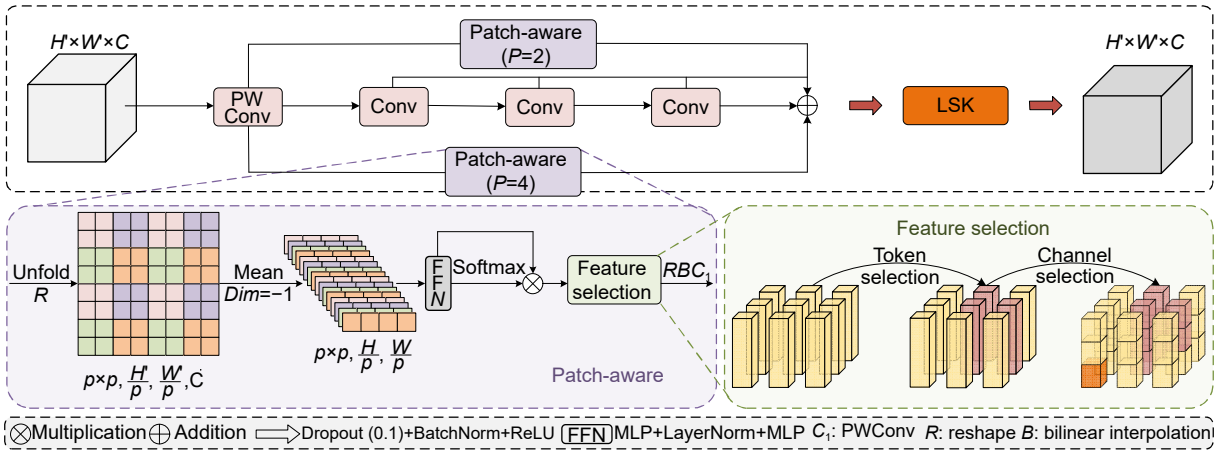

图 3 并行多分支特征提取模块

Fig. 3 Parallel multi-branch feature extraction module

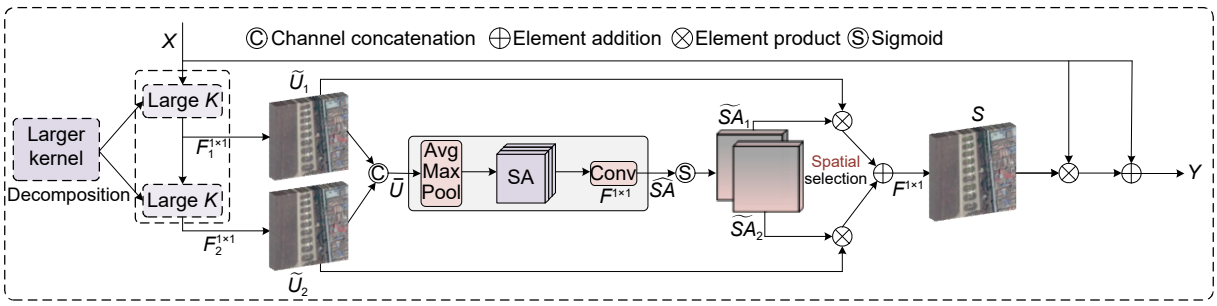

图 4 大型选择核模块

Fig. 4 Large selective kernel module

$$SA_{\text{avg}} = P_{\text{avg}}(\widetilde{U}),\ SA_{\max} = P_{\max}(\widetilde{U}), \tag{13}$$

$$\widehat{SA} = F^{1\times1}([SA_{\text{avg}}; SA_{\max}]), \tag{14}$$

$$\widetilde{SA}_1 = \sigma(\widehat{SA}_1),\ \widetilde{SA}_2 = \sigma(\widehat{SA}_2), \tag{15}$$

其中：$F_1^{1\times1}(\cdot)$、$F_2^{1\times1}(\cdot)$和$F^{1\times1}(\cdot)$均表示1×1卷积操作，$P_{\text{avg}}(\cdot)$和$P_{\max}(\cdot)$分别表示平均和最大池化，$\sigma(\cdot)$表示sigmoid函数。

将上述输出特征图$\widetilde{SA}_1$和$\widetilde{SA}_2$分别与$\tilde{U}_1$和$\tilde{U}_2$进行空间逐元素乘法，然后通过卷积处理，最后将输出特征与给定输入特征进行逐元素乘法和加法操作。其具体过程分别为

$$S = F^{1\times1}\left(\sum_{i=1}^{2}(\widetilde{SA}_i \otimes \tilde{U}_i)\right), \tag{16}$$

$$Y = X \oplus (X \otimes S). \tag{17}$$

2.5 多尺度特征融合模块

设计高效、高质量的网络架构是深度学习领域[22]中一项重要的研究课题。本文在ELAN模块的基础上，设计一种多尺度特征融合模块，结构如图5所示。

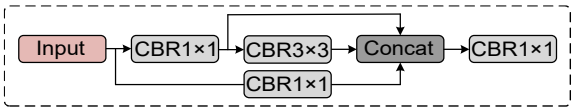

图 5 多尺度特征融合模块

Fig. 5 Multi-scale feature fusion module

MFFM模块实现对多层特征的高效融合，加速梯度传播和模型训练。该模块首先利用并行多分支卷积捕获不同尺度的特征信息；然后通过Concat融合多层特征信息；最后进行卷积处理以增强网络特征学习能力。其具体过程可分别表述为

$$C_{ixi}(P_1) = Cat\begin{bmatrix} C_{1\times1}(P_1), C_{1\times1}(P_1), \\ C_{3\times3}(C_{1\times1}(P_1)) \end{bmatrix}, \tag{18}$$

$$MFFM_{\text{O}} = C_{1\times1}(C_{ixi}(P_1)), \tag{19}$$

其中：P_1表示多尺度特征融合模块的输入；$Cat[\cdot]$表示多层特征融合操作；$MFFM_{\text{O}}$表示多尺度特征融合模块的输出。

3 实 验

3.1 实验环境及参数设置

本文实验基于64位Windows 11操作系统，使用Python编程语言在Pytorch框架中搭建，主要硬件配置如下：处理器为AMD Ryzen 9 7945HX with Radeon Graphics、显卡为NVIDIA GeForce RTX 4060、显存8 GB。实验参数设置如表1所示。

表 1 参数设置

Table 1 Parameter setting

参数	参数值
输入图像分辨率	640×640
初始学习率	0.01
动量参数	0.937
权重衰减系数	0.0005
训练轮次	300
批量大小	16

3.2 实验数据集

本文实验使用RSOD、NWPU VHR-10和DOTA数据集。其中RSOD数据集[23]由武汉大学标注，包含976张遥感图像，涵盖飞机(aircraft)、油桶(oil tank)、操场(playground)和立交桥(overpass)四种不同类型目标。随机抽取781张图像作为训练集，195张图像用作验证集。

NWPU VHR-10数据集[24]由西北工业大学标注，包含800张遥感图像，其中含目标图像共650张，仅含背景图像共150张。该数据集共10个目标类别，包括：飞机(airplane)、船只(ship)、油罐(storage)、棒球场(baseball diamond)、网球场(tennis court)、篮球场(basketball court)、田径场(ground track field)、港口(harbor)、桥梁(bridge)和车辆(vehicle)。随机抽取640张图像作为训练集，160张图像用作验证集。

DOTA数据集[25]由清华大学标注，选取3717张遥感图像，其中包含飞机(plane)、棒球场(baseball-diamond)、桥梁(bridge)、田径场(ground-track-field)、小车(small-vehicle)、大车(large-vehicle)、船只(ship)、网球场(tennis-court)、篮球场(basketball-court)、油罐(storage-tank)、足球场(soccer-ball-field)、环岛(roundabout)、海港(harbor)、游泳池(swimming-pool)和直升机(helicopter)。随机抽取2974张图像作为训练集，743张图像用作验证集。

3.3 实验评价指标

目标检测中使用准确率(precision, P)、召回率(recall, R)、平均准确率(average precision, AP)、参数量(params, Par)和平均准确率均值(mean average precision, mAP)等指标来评价检测结果，其计算式分

别为

$$P=\frac{TP}{TP+FP}, \tag{20}$$

$$R=\frac{TP}{TP+FN}, \tag{21}$$

$$AP=\int_0^1 P(R)\mathrm{d}R, \tag{22}$$

$$mAP=\frac{1}{N}\sum_{i=1}^{N}AP_i, \tag{23}$$

其中：TP 表示将真实正样本预测为正样本的数量，TN 表示将真实负样本预测为负样本的数量，FP 表示将真实负样本预测为正样本的数量，FN 表示将真实正样本预测为负样本的数量。此外，使用帧速度 (frames per second, FPS) 评估检测的速度，即每秒处理的图片数量。

3.4 LSK 模块实验

3.4.1 不同注意力对比实验

本文将 PPA 模块中原有的 CBAM 注意力模块替换为 LSK 模块，并结合 PMFE 模块重新构建了 PPA 模块。为验证 LSK 模块的优越性，将其置于并行补丁感知模块中，在 RSOD 数据集上与 CBAM、SE、EMA、CA 注意力进行对比，实验结果如表 2 所示，其中加粗字体表示该项指标的最优值。

表 2 不同注意力对比实验

Table 2 Experiments on contrasting attentional differences

注意力	参数量/M	FPS	mAP@0.5/%
CBAM	11.3	92	96.1
SE	**11.1**	90	93.4
CA	**11.1**	92	96.2
EMA	**11.1**	**93**	95.6
LSK	11.5	92	**96.5**

分析表 2 可知，综合考虑三个指标，在增加极少参数量的情况下，LSK 的 mAP@0.5 值最优，达到 96.5%，比原注意力 CBAM 提升 0.4%，同时，其 FPS 值仅次于 EMA，与 CBAM 和 CA 平齐，高于 SE。实验结果表明，LSK 模块的整体性能优秀。

3.4.2 不同大小感受野的有效性验证

为获取优异的检测性能，本文通过调整 LSK 模块中深度可分离卷积的大小扩展有效感受野，以提升多尺度目标识别精度。将大内核分解为两个深度可分离卷积，在 RSOD 数据集上进行实验，其结果如表 3 所示，其中k_i表示第 i 个卷积核的大小，d_i表示第 i 个卷积核的扩张率，加粗字体表示该项指标的最优值。

表 3 大内核分解为两个深度可分离卷积的有效性

Table 3 Effectiveness of decomposing a large kernel into two sequences of depth-wise separable kernels

(k_1, d_1)	(k_2, d_2)	RF	FPS	mAP@0.5/%
(3, 1)	(5, 2)	11	104	92.0
(5, 1)	(7, 3)	23	**105**	**95.0**
(7, 1)	(9, 4)	39	88	94.7

由表 3 分析可知，过小或过大的感受野会限制模型的性能，大小为 23 的感受野同时具有良好的检测速度和检测精度。因此，本文算法采用感受野大小为 23 的 LSK 模块做进一步改进。

3.5 MFFM 模块实验

本文在 ELAN 模块的基础上，去掉一个卷积层，构成 MFFM 模块。为验证 MFFM 模块的有效性和合理性，在 RSOD 数据集上与 ELAN 模块进行对比，实验结果如表 4 所示，其中加粗字体表示该项指标的最优值。

表 4 MFFM 与 ELAN 对比实验

Table 4 Comparison of experiments between MFFM and ELAN

模块	参数量/M	FPS	mAP@0.5/%
ELAN	6.0	88	**94.6**
MFFM	**4.8**	**126**	94.2

分析表 4 可知，与 ELAN 相比，MFFM 的 mAP 指标仅减少 0.4%，但其 Par 值降低 1.2 M，同时 FPS 值提高 38 f/s，高达 126 f/s。综合考虑三个指标，MFFM 在牺牲极少量精度的情况下，换取更低的参数量和更快的检测速度。

3.6 消融实验

为证明本文模型的优越性，使用 RSOD 数据集进行消融实验，其结果如表 5 所示，其中加粗字体表示此项指标的最优值。M1 表示基线模型 YOLOv7-tiny；M2 表示在 M1 基础上引入 EVC 模块；M3 表示在 M2 基础上添加 PPA 模块；M4 表示设计 MFFM 模块替换 M3 模型中 ELAN 模块，即本文模型。

分析表 5 可知，基线模型 YOLOv7-tiny 在遥感图像目标检测方面表现出色，平均准确率均值达到 94.6%。其中飞机、油桶和操场的平均准确率较高，但立交桥的平均准确率较低，仅 85.0%。此外，在模型结构固定的情况下，其准确率和召回率仍有提升空

表 5 消融实验数据

Table 5 Ablation experimental data

模型	准确率*P*/%	召回率*R*/%	平均准确率*AP*/%				平均准确率均值 mAP@0.5/%
			飞机	油桶	立交桥	操场	
M1	90.3	93.1	**97.9**	97.8	85.0	97.7	94.6
M2	**92.6**	91.2	97.7	98.5	88.5	98.4	95.8
M3	92.0	95.2	97.8	**98.8**	91.4	**99.5**	96.9
M4	91.8	**95.5**	97.7	98.6	**93.0**	98.8	**97.0**

间。因此，本文在初始模型的基础上进行改进。通过在初始模型 M1 的 Neck 网络中引入 EVC 模块，整体指标有所提升，其中平均准确率均值提升 1.2%，准确率达到最优值，说明 EVC 模块不仅能够建立像素点间的长距离依赖关系，而且有效关注局部区域特征，对遥感图像目标检测具有较强的多尺度特征捕捉能力。在 M2 的 Backbone 网络底下添加 PPA 模块，平均准确率均值提升 1.1%，各目标类别的平均准确率均有所提升，其中油桶和操场的平均准确率达到各项指标的最优值，说明 PPA 模块可以充分提取和丰富特征语义信息。最后设计 MFFM 模块替换 M3 中 ELAN 模块，召回率和立交桥的平均准确率达到各项指标的最优值，其中立交桥的平均准确率相较于初始模型提升 8.0%，说明 MFFM 模块能够充分融合多尺度特征信息，有效检测复杂背景下的立交桥遥感目标。虽然卷积层的去除，导致前一层信息的丢失，可能会导致模型的训练不足，进而造成飞机、油桶和操场的平均准确率略微降低，但是可以简化网络结构，减少网络的层数，以减少模型的参数量和计算复杂度，从而减少模型过拟合的风险，提高模型在新数据上的表现稳定性，使得模型取得更好的泛化能力。消融实验结果表明，本文所提模型的合理性和有效性。

3.7 多种模型检测结果与分析

3.7.1 定量分析

为了验证本文算法的优越性，将 Faster R-CNN、SSD、YOLOv3-tiny、YOLOv4-tiny、YOLOv5s、YOLOv5m、YOLOv7-tiny、YOLOv8s、YOLOv8m 和本文算法置于同一实验环境进行对比实验，其实验结果如表 6 所示，其中加粗字体表示该项指标的最优值。

分析表 6 可知，本文模型相较于 Faster R-CNN、SSD、YOLOv3-tiny、YOLOv5m 和 YOLOv8m 算法，在参数量、FPS 和 mAP@0.5 这三个指标上表现优异，其中 mAP@0.5 达到此项指标的最优值，FPS 值仅次于 YOLOv3-tiny，高达 85 帧，满足实时性需求。与 YOLOv5s 和 YOLOv8s 算法相比，在参数量略增的情况下，本文算法的 mAP@0.5 分别提高 1.5% 和 2.7%。与 YOLOv4-tiny 和 YOLOv7-tiny 算法比较，本文算法的参数量表现略微逊色，但 FPS 相较 YOLOv7-tiny 基本保持不变，相较 YOLOv4-tiny 大幅增长，mAP@0.5 分别提升 14.6% 和 2.4%。

表 6 不同算法检测数据对比

Table 6 Comparison of detection data from different algorithms

模型	参数量/M	FPS	平均准确率*AP*/%				平均准确率均值 mAP@0.5%
			飞机	油桶	立交桥	操场	
Faster R-CNN	72.0	10	71.0	98.0	85.0	**100.0**	88.5
SSD	24.4	43	79.0	98.0	73.0	**100.0**	87.5
YOLOv3-tiny	12.1	**104**	94.2	96.4	76.9	98.5	91.5
YOLOv4-tiny	6.1	50	70.7	97.3	61.7	99.1	82.4
YOLOv5s	9.1	90	97.4	97.8	87.4	99.3	95.5
YOLOv5m	25.0	56	97.0	96.8	89.4	99.2	95.6
YOLOv7-tiny	**6.0**	88	**97.9**	97.8	85.0	97.7	94.6
YOLOv8s	11.1	97	97.6	97.2	82.8	99.4	94.3
YOLOv8m	25.8	53	97.2	98.1	84.3	99.5	94.8
ours	11.5	85	97.7	**98.6**	**93.0**	98.8	**97.0**

对比不同类别的平均准确率可知，本文模型在包含多尺度和微小目标的飞机类别检测中表现出色，AP 高达 97.7%，仅次于 YOLOv7-tiny；在油桶类别检测中，平均准确率为 98.6%，达到该项最优指标；在复杂背景下的立交桥类别检测中表现卓越，平均准确率高达 93.0%，远优于其他算法。

3.7.2 定性分析

为直观显示本文模型的检测性能，将本文模型同其他目标检测算法在遥感图像上进行预测，可视化结果分别展示原图、Faster R-CNN、SSD、YOLOv3-tiny、YOLOv5s、YOLOv5m、YOLOv7-tiny、YOLOv8s、YOLOv8m 和本文算法的检测效果，如图 6 所示。其中图 6(a, d) 表示微小目标遥感图像；图 6(b, e) 表示背景复杂遥感图像；图 6(c, f) 表示多尺度目标遥感图像。

观察图 6(a, d) 可知，在微小目标的检测结果中，SSD 算法存在重叠框问题，即对同一物体进行重复预测；YOLOv3-tiny 算法存在目标漏检的情况；Faster R-CNN、SSD、YOLOv5s、YOLOv5m、YOLOv7-tiny、YOLOv8s 和 YOLOv8m 算法均出现非目标误检的现象，其中 Faster R-CNN、YOLOv5s 和 YOLOv8s 算法误检率较高；而本文算法表现出众，有效实现对微小目标的准确预测。

在图 6(b, e) 复杂背景目标的检测结果中，Faster R-CNN、SSD、YOLOv3-tiny、YOLOv5s、YOLOv5m、YOLOv7-tiny、YOLOv8s 和 YOLOv8m 算法表现欠佳，均出现立交桥目标类别漏检的现象；Faster R-CNN 算法存在非目标误检的状况；SSD 算法

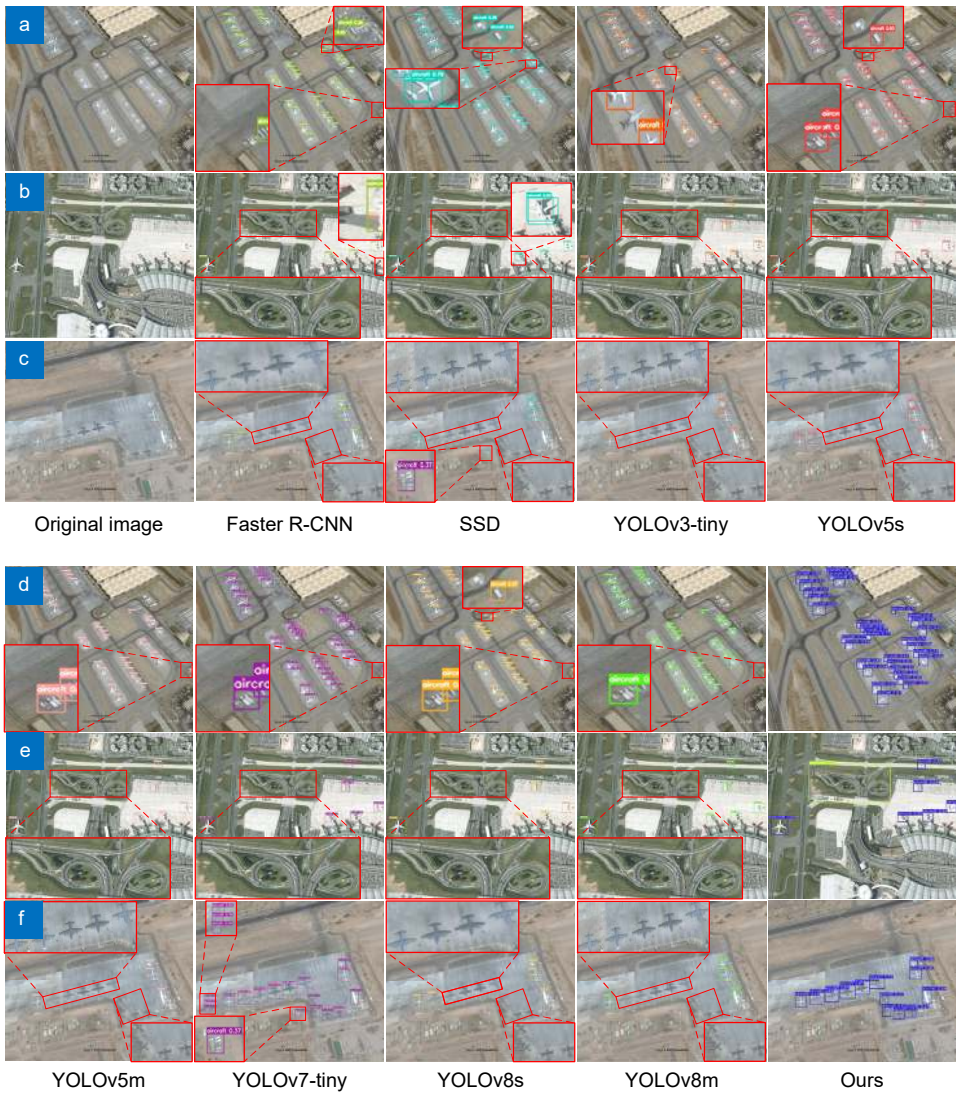

图 6 不同算法遥感目标检测结果

Fig. 6 Remote sensing target detection results of different algorithms

存在重叠框问题；而本文算法具有较强的背景噪声抗干扰能力，有效识别复杂背景下的立交桥目标。

在图 6(c, f) 多尺度目标检测结果中，针对图像中较大尺度和较小尺度的物体，Faster R-CNN、SSD、YOLOv3-tiny、YOLOv5s、YOLOv5m、YOLOv8s 和 YOLOv8m 算法表现不佳，均出现不同程度的目标漏检情况；针对图像中较小尺度的物体，SSD 和 YOLOv7-tiny 算法均存在无关物体误检的现象；而本文算法有效地检测出图像中包含的全部目标。

综上所述，本文算法在面对遥感图像中微小目标、复杂背景和多尺度目标时，取得优秀的检测成绩，尤其是针对复杂背景下的立交桥目标类别检测。

3.8 泛化性验证

本文采用涵盖更多不同类型和场景的 NWPU VHR-10 和 DOTA 数据集对所提算法进行泛化性验证，NWPU VHR-10 和 DOTA 数据集实验结果分别如表 7 和表 8 所示，其中加粗字体表示相应指标的最优值。

分析表 7 和表 8 可知，与基线模型 YOLOv7-tiny 相比，尽管本文算法的参数量略有增加，但 FPS 基本保持不变，满足实时性需求。同时，本文算法在 NWPU VHR-10 和 DOTA 数据集上的 mAP@0.5 指标分别提升 3.0% 和 1.3%，显示出高精度和高效率的特点。

实验结果表明，本文算法不仅在 RSOD 数据集中表现优异，而且在包含更多不同类型和场景的数据集上也取得出色的成绩，展示了良好的泛化能力。

4 结　语

针对遥感图像存在复杂背景干扰、目标多尺度差异和微小目标提取难问题，本文基于 YOLOv7-tiny 模型提出一种融合视觉中心机制和并行补丁感知的遥感图像检测算法，以提高遥感图像目标的检测性能。本文算法在 RSOD、NWPU VHR-10 和 DOTA 数据集上均具有较高的 mAP@0.5 值，相较于基线算法 YOLOv7-tiny 分别提高 2.4%、3.0% 和 1.3%，表明本文算法对遥感图像目标检测的有效性和泛化性。在后续研究中，本文将朝着低参数的方向对模型做进一步改进和优化，使其能更有效地应用于遥感图像目标检测。

参考文献

[1] Ma L, Gou Y T, Lei T, et al. Small object detection based on multi-scale feature fusion using remote sensing images[J]. *Opto-Electron Eng*, 2022, **49**(4): 210363.
马梁, 苟于涛, 雷涛, 等. 基于多尺度特征融合的遥感图像小目标检测[J]. 光电工程, 2022, **49**(4): 210363.

[2] Yuan J H, Zhang N F, Ruan J S, et al. Detection of prohibited items in X-ray images based on modified YOLOX algorithm[J]. *Laser Technol*, 2023, **47**(4): 547−552.
袁金豪, 张南峰, 阮洁珊, 等. 基于改进 YOLOX 算法的 X 射线图像违禁品检测方法[J]. 激光技术, 2023, **47**(4): 547−552.

[3] Ming Q, Miao L J, Zhou Z Q, et al. CFC-Net: a critical feature capturing network for arbitrary-oriented object detection in remote-sensing images[J]. *IEEE Trans Geosci Remote Sens*, 2022, **60**: 5605814.

[4] Cong R M, Zhang Y M, Fang L Y, et al. RRNet: relational reasoning network with parallel multiscale attention for salient object detection in optical remote sensing images[J]. *IEEE Trans Geosci Remote Sens*, 2022, **60**: 5613311.

[5] Girshick R, Donahue J, Darrell T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]//*Proceedings of 2014 IEEE Conference on Computer Vision and Pattern Recognition*, Columbus, 2014: 580–587. https://doi.org/10.1109/CVPR.2014.81.

[6] Girshick R. Fast R-CNN[C]//*Proceedings of 2015 IEEE International Conference on Computer Vision*, Santiago, 2015: 1440–1448. https://doi.org/10.1109/ICCV.2015.169.

[7] Ren S Q, He K M, Girshick R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. *IEEE Trans Pattern Anal Mach Intell*, 2017, **39**(6): 1137−1149.

表 7　NWPU VHR-10 数据集上检测结果对比

Table 7　Comparison of detection results on NWPU VHR-10 dataset

模型	准确率*P*/%	召回率*R*/%	参数量/M	FPS	mAP@0.5/%
YOLOv7-tiny	88.7	**88.4**	**6.0**	**83**	90.7
Ours	**92.5**	87.6	11.5	79	**93.7**

表 8　DOTA 数据集上检测结果对比

Table 8　Comparison of detection results on DOTA dataset

模型	准确率*P*/%	召回率*R*/%	参数量/M	FPS	mAP@0.5/%
YOLOv7-tiny	78.2	70.4	**6.0**	**82**	74.7
Ours	**80.0**	**71.2**	11.5	77	**76.0**

[8] He K M, Gkioxari G, Dollár P, et al. Mask R-CNN[C]// *Proceedings of 2017 IEEE International Conference on Computer Vision*, Venice, 2017: 2961–2969. https://doi.org/10.1109/ICCV.2017.322.

[9] Liu W, Anguelov D, Erhan D, et al. SSD: single shot MultiBox detector[C]//*Proceedings of the 14th European Conference*, Amsterdam, 2016: 21–37. https://doi.org/10.1007/978-3-319-46448-0_2.

[10] Zhao L Q, Li S Y. Object detection algorithm based on improved YOLOv3[J]. *Electronics*, 2020, **9**(3): 537.

[11] Gai R L, Chen N, Yuan H. A detection algorithm for cherry fruits based on the improved YOLO-v4 model[J]. *Neural Comput Appl*, 2023, **35**(19): 13895−13906.

[12] 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]//*Proceedings of 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Vancouver, 2023: 7464–7475. https://doi.org/10.1109/CVPR52729.2023.00721.

[13] Salehi A W, Khan S, Gupta G, et al. A study of CNN and transfer learning in medical imaging: advantages, challenges, future scope[J]. *Sustainability*, 2023, **15**(7): 5930.

[14] Gao S H, Li Z Y, Han Q, et al. RF-Next: efficient receptive field search for convolutional neural networks[J]. *IEEE Trans Pattern Anal Mach Intell*, 2023, **45**(3): 2984−3002.

[15] Gao T, Niu Q Q, Zhang J, et al. Global to local: a scale-aware network for remote sensing object detection[J]. *IEEE Trans Geosci Remote Sens*, 2023, **61**: 5615614.

[16] Zhang J Q, Lei J, Xie W Y, et al. SuperYOLO: super resolution assisted object detection in multimodal remote sensing imagery[J]. *IEEE Trans Geosci Remote Sens*, 2023, **61**: 5605415.

[17] Wang L, Liu X B, Ma J T, et al. Real-time steel surface defect detection with improved multi-scale YOLO-v5[J]. *Processes*, 2023, **11**(5): 1357.

[18] Quan Y, Zhang D, Zhang L Y, et al. Centralized feature pyramid for object detection[J]. *IEEE Trans Image Process*, 2023, **32**: 4341−4354.

[19] Xu S B, Zheng S C, Xu W H, et al. HCF-Net: hierarchical context fusion network for infrared small object detection[Z]. arXiv: 2403.10778, 2024. https://arxiv.org/abs/2403.10778.

[20] Li Y X, Li X, Dai Y M, et al. LSKNet: a foundation lightweight backbone for remote sensing[Z]. arXiv: 2403.11735, 2024. https://arxiv.org/abs/2403.11735.

[21] Li X, Wang W H, Hu X L, et al. Selective kernel networks[C]//*Proceedings of 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Long Beach, 2019: 510–519. https://doi.org/10.1109/CVPR.2019.00060.

[22] Liang L M, Zhan T, Lei K, et al. Multi-resolution fusion input U-shaped retinal vessel segmentation algorithm[J]. *J Electron Inf Technol*, 2023, **45**(5): 1795−1806.
梁礼明, 詹涛, 雷坤, 等. 多分辨率融合输入的 U 型视网膜血管分割算法[J]. 电子与信息学报, 2023, **45**(5): 1795−1806.

[23] Chen Y X, Lin M W, He Z, et al. Consistency-and dependence-guided knowledge distillation for object detection in remote sensing images[J]. *Expert Syst Appl*, 2023, **229**: 120519.

[24] Zhao D W, Shao F M, Liu Q, et al. A small object detection method for drone-captured images based on improved YOLOv7[J]. *Remote Sens*, 2024, **16**(6): 1002.

[25] Xia G S, Bai X, Ding J, et al. DOTA: a large-scale dataset for object detection in aerial images[C]//*Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Salt Lake City, 2018: 3974–3983. https://doi.org/10.1109/CVPR.2018.00418.

作者简介

梁礼明 (1967-)，男，硕士，教授，硕士生导师，主要研究方向为机器学习、医学影像和系统建模等公开发表学术论文百余篇，其中被 SCI、EI、ISTP 收录论文二十余篇。获得中国发明专利六项 (排名第一)、出版研究生教材一部。

E-mail：lianglm67@163.com

【通信作者】陈康泉 (1995-)，男，硕士研究生，主要研究方向为机器学习、模式识别与图像处理。

E-mail：1136344152@qq.com

扫描二维码，获取PDF全文

Remote sensing image detection algorithm integrating visual center mechanism and parallel patch perception

Liang Liming, Chen Kangquan*, Wang Chengbin, Feng Yao, Long Pengwei

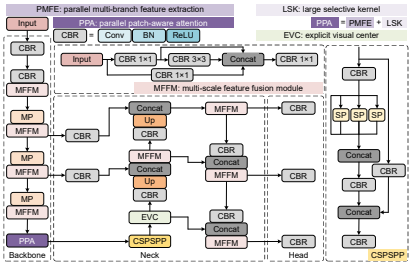

Remote sensing image detection model integrating visual center mechanism and parallel patch perception

Overview: In response to challenges posed by complex background interference, multi-scale variations of targets, and difficulties in extracting small targets in remote sensing images, this paper proposes a novel remote sensing image detection algorithm based on the YOLOv7-tiny model. The algorithm integrates a visual centering mechanism and parallel patch perception to enhance target detection performance. The algorithm introduces three main innovations. Firstly, it introduces an explicit visual centering mechanism that uses a lightweight multi-layer perceptron to establish long-distance dependencies between pixels, focusing on capturing central features of contextual information to enrich the overall semantic information of images, including scene structures and contextual details. Simultaneously, a trainable visual centering mechanism aggregates local area information within layers to capture locally representative feature representations, thereby further improving the extraction performance of target textures. This approach effectively extracts and utilizes the overall semantic information of images, accurately capturing global features of targets to enhance recognition of target textures and shapes during detection. Secondly, the algorithm improves the parallel patch perception module by dynamically adjusting the feature extraction receptive field to adapt to different target scales and capture diverse scale feature information, effectively handling varied backgrounds. In practical applications, targets in remote sensing images often exhibit different scales and complex environmental backgrounds, where traditional methods may struggle to distinguish or ignore these differences. By dynamically adjusting the receptive field, the algorithm flexibly perceives targets of different scales while maintaining high accuracy and low error rates in complex background scenarios. Finally, the algorithm designs a multi-scale feature fusion module to efficiently integrate multi-level and multi-scale feature information, comprehensively capturing diverse representations of targets and further enhancing model inference speed while meeting high-precision detection requirements. This fusion method significantly enhances the algorithm's effectiveness in static image detection tasks. Experimental results on the RSOD dataset demonstrate improvements in accuracy, recall, and mean average precision by 1.5%, 2.4%, and 2.4%, respectively, compared to YOLOv7-tiny. Additionally, generalization validation on the NWPU VHR-10 and DOTA datasets shows commendable results, with average precision mean values increasing by 3.0% and 1.3%, respectively, compared to baseline models. These findings illustrate the algorithm's outstanding performance not only on the RSOD dataset but also on datasets encompassing diverse types and scenes, highlighting its robust generalization capability. Through comparative analysis with different algorithms, the superiority of the proposed algorithm's performance is further underscored.

Liang L M, Chen K Q, Wang C B, et al. Remote sensing image detection algorithm integrating visual center mechanism and parallel patch perception[J]. *Opto-Electron Eng*, 2024, **51**(7): 240099; DOI: 10.12086/oee.2024.240099

Foundation item: Project supported by National Natural Science Foundation of China (51365017, 61463018), Natural Science Foundation of Jiangxi Province (20192BAB205084), Jiangxi Provincial Department of Education Science, and Technology Research Youth Project (GJJ2200848)

School of Electrical Engineering and Automation, Jiangxi University of Science and Technology, Ganzhou, Jiangxi 341000, China
* E-mail: 1136344152@qq.com