

基于 YOLO 的目标检测模型在军用飞机遥感图像中的性能分析与军事应用研究

王一凡¹ 樊登华¹ 吴 栋¹
WANG Yifan FAN Denghua WU Dong

摘 要

随着对地观测技术的快速发展,高分辨率遥感图像已成为军事侦察与态势感知的核心数据源。军用飞机目标检测作为遥感图像解译的关键任务,对国防安全、战场监控、情报收集及火力打击具有重大战略意义。文章基于 MAR20 数据集,系统对比分析了 YOLOv8、YOLOv11 及 YOLOv13 三种模型在军用飞机检测任务中的性能表现,综合分析了模型在检测准确率、召回率、mAP@0.5 及 mAP@0.5:0.95、推理速度等多维度模型性能指标;首次系统性地对比了最新 YOLO 系列模型在军事飞机遥感图像检测任务中的性能,深入分析了不同模型在军事侦察、战场监控和火力打击场景中的适用性,为军事遥感应用中目标检测模型的选型提供了实证依据。

关键词

YOLO; 目标检测; 遥感图像; 军事应用

doi: 10.3969/j.issn.1672-9528.2026.07.006

0 引言

随着对地观测技术的飞速发展,高分辨率遥感图像已成为军事侦察和态势感知的重要数据源。其中,军用飞机目标检测作为遥感图像解译的核心任务,对国防安全、战场监控、情报搜集和火力打击具有至关重要的意义。

近年来,基于深度学习目标检测算法,特别是 YOLO 系列模型,在各个领域都取得很好效果。但是应用于军事场景时,还面临着一些亟需解决的问题:一是不同军用飞机种类繁多并且有较大差别使得分类非常困难;二是战场环境对于算法实时性和准确性有很高要求;三是模型复杂度过高以及对硬件设备需求较大也是问题。

杨环宇等^[1]通过引入 CA 机制设计 CA-Stage 模块提升 ConvNeXt 网络对于背景和前景的区分能力,并使用数据增强和迁移学习的策略提高模型的泛化能力。周韩莲等^[2]提出一种融合重参数化和细节增强的轻量级军用飞机目标检测方法 YOLOv8-MA,结合群范卷积和细节增强减少模型参数和计算量。王耀领等^[3]通过改进条件生成对抗网络生成样本遥感飞机图像,提高生成样本中飞机区域的图像质量,解决了识别任务中样本不足的问题。党玉龙等^[4]提出一种基于 Fast-er R-CNN 的轻量化检测模块,使用残差拆分注意力网络、可变形卷积提升模型表征能力和提高模型识别速度,使用非极大值抑制算法去掉相同目标的重复候选框降低密集分布目标

漏检率。陈铁明等^[5]提出一种基于改进 YOLOv3 的红外末制导目标检测方法,从红外制导背景出发提高网络定位和分类能力。刘子洋等^[6]引入基于 Transformer 结构的 Bi-Former 注意力机制,加强对小目标的检测性能,引入 GSConv 模块在保证性能的前提下减小算法规模。目前军事目标数据集的短缺并且缺乏高质量细粒度标注数据集也是亟待解决的问题,柏栋等^[7]收集并标注了军用车辆细粒度检测遥感数据集,包含 3 000 幅遥感图像共计 32 626 个实例。

MAR20 数据集^[8]作为目前规模最大的遥感图像军用飞机目标识别数据集,为相关研究提供了宝贵的数据支撑。该数据集包含 3 842 张高分辨率遥感图像,涵盖 20 种军用飞机型号,共计 22 341 个实例,且同时提供水平边界框和旋转边界框两种标注方式,适合进行细粒度目标检测研究。

本文以 MAR20 数据集为基础,对比分析 YOLOv8、YOLOv11 及 YOLOv13 三种模型在军事飞机检测任务中的性能表现,从检测准确率、速度、模型复杂度等多维度进行评估,旨在为军事遥感应用中目标检测模型的选择提供实证依据,并结合模型性能表现深入分析了军用飞机遥感图像目标检测在军事侦察、战场监控和火力打击三个场景下的适用性研究分析,最后探讨未来研究方向。

1 相关工作

1.1 MAR20 数据集

本研究采用的 MAR20 数据集包含 3 842 张高分辨率遥

1. 陆军兵种大学郑州校区 河南郑州 450052

感图像，涵盖 20 类军用飞机型号，实例总数达 22 341 个。数据集中的图像主要采集自美国、俄罗斯等国家的 60 个军用机场。包括俄罗斯空军基地的 6 种军用飞机的常见型号，SU-35 战斗机、TU-160 轰炸机、TU-22 轰炸机、TU-95 轰炸机、SU-34 战斗轰炸机、SU-24 战斗轰炸机，以及美国空军基地的 14 种常见军用飞机的型号，包括 C-130 运输机、C-17 运输机、C-5 运输机、F-16 战斗机、E-3 预警机、B-52 轰炸机、P-3C 反潜机、B-1B 轰炸机、E-8 战场联合监视机、F-15 战斗机、KC-135 空中加油机、F-22 战斗机、F/A-18 战斗攻击机、KC-10 空中加油机。本数据集将 SU-35、C-130、C-17、C-5、F-16、TU-160、E-3、B-52、P-3C、B-1B、E-8、TU-22、F-15、KC-135、F-22、FA-18、TU-95、KC-10、SU-34、SU-24 飞机型号简称为 A1~A20。

1.2 YOLOv8 模型

YOLOv8、YOLOv11 以及 YOLOv13 都以网络深度和宽度的不同划分为 n、s、m、l、x 五个不同大小的模型。YOLOv8 模型^[9]结构主要包括：骨干网络（Backbone）、颈部网络（Neck）和检测头部（Head）三部分组成。骨干网络采用 C2f 模块（cross-stage feature fusion）替代 YOLOv5 的 C3 模块。在 C2f 中加入了跳层连接和 Split 操作，将输入特征图分成两份，一份直接送入 Bottleneck，另一份先经过 Bottleneck 再与前面一份合并。C2f 的计算过程是 Conv1→Split→Bottleneck→Concat→Conv2，这样可以节省大约 30% 的计算量并且有利于特征学习，颈部使用改进版 PANet（panoptic feature pyramid network），删除 YOLOv5 中的 1×1 卷积下采样层，用上采样和 Concat 操作来实现不同尺度的特征图之间的融合，得到更加丰富的特征金字塔，PANet 的双路路径（自顶向下以及自底向上）可以让低层的信息更便捷地传播到高层从而解决小目标检测的问题。检测头部从耦合头（Coupled Head）变为解耦头（Decoupled Head），将分类以及回归分开。采用 Anchor-Free 的方式，不需要预先设定锚点。回归分支使用 DFL（distribution focal loss）的方法，把预测的结果由一个数值变为一个概率分布，提高检测框的位置准确性。检测头部还有 Task-Aligned Assigner，在预测结果的基础上进行正负样本的匹配，使训练更好。

1.3 YOLOv11 模型

YOLOv11 保持了 YOLO 系列模型高效性基础上，还提出了一系列改进使其性能更上一层楼。使用 Transformer 作为骨干网络，可以较好地学习到长距离信息，在小目标检测上具有较大优势；它具有可变头部，可以根据图片难易程度自动调节不同部分所占比例；并且支持无 NMS 训练，极大地

降低了计算量。

相比于 YOLOv8，YOLOv11 以更少参数取得了更好的效果，在资源有限的边缘设备上具有很强的优势，YOLOv11 使用复杂单阶段无锚方法，同时兼顾速度和准确性，简化网络结构降低参数量和计算量，因此推理速度快并且消耗内存小，可以部署在资源有限的边缘设备上。

1.4 YOLOv13 模型

YOLOv13 引入 HyperACE（基于超图的自适应关联增强）和 FullPAD（全流程聚合与分发范式）两大机制。HyperACE 机制利用超图计算建模像素间复杂的“多对多”高阶关系，突破传统卷积和自注意力仅能处理局部或“两两之间”关系的限制。FullPAD 范式将经过 HyperACE 增强后的高级特征重新分发到网络的不同深度和模块，实现更精细化的特征融合加强梯度传播，尤其有助于提升小目标检测精度。DS-C3k2 模块利用深度可分离卷积替换传统大核卷积，设计轻量级模块，在不牺牲性能的前提下减少参数和计算复杂度。

2 实验与结果分析

2.1 实验环境与参数设置

所有实验均在配备 NVIDIA GTX3090 GPU、Xeon Platinum8260C CPU 和 86 GB 内存的计算平台上进行。软件环境基于 Ubuntu20.04 操作系统，使用 PyTorch1.12.1 深度学习框架，YOLO 模型采用 Ultralytics 官方代码库实现。实验参数设置如表 1 所示。

表 1 实验参数设置

Parameter	Value
Img-size	640×640
Epochs	100
Batch-size	32
Optimizer	AdamW
lr	0.01
hsv_h	0.015
hsv_s	0.4
fliplr	0.5

2.2 评估指标

为全面评估模型性能，采用以下评估指标：准确率 precision 和召回率 recall 的计算如式（1）~（2）所示，mAP@0.5 为交并比（IoU）阈值为 0.5 时的平均精度均值，mAP@0.5:0.95 为 IoU 阈值从 0.5 到 0.95（步长 0.05）的平均精度均值，模型大小（Size）为模型占用内存大小，参数量（Parameters）为模型总参数数量，推理速度（Inference

time) 为 GPU (NVIDIAGTX3090) 上的单张图像处理时间, FPS 为每秒处理图片数量。

$$\text{precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (1)$$

$$\text{recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (2)$$

式中: TP 代表真正例, FN 代表假负例, FP 代表假正例。

2.3 预测准确率对比与预测结果可视化分析

为全面评估三种 YOLO 模型在 MAR20 数据集上的检测性能, 本文分别在验证集上计算了准确率 precision、召回率 recall、mAP@0.5 和 mAP@0.5:0.95 指标, 结果如表 2 所示。从表 2 可以看出。在准确率上, YOLOv11s 模型以 0.986 9 的最高值领先, 比最低值 YOLOv13n 模型高 1.71%。在召回率上, YOLOv13s 模型以 0.9815 的最高值领先, 比最低值 YOLOv13n 模型高 1.98%。在 mAP@0.5 上, YOLOv11s 模型以 0.990 4 的最高值领先, 比最低值 YOLOv13n 模型高 0.64%。在 mAP@0.5:0.95 上, YOLOv11s 模型展现出最优异的性能, 其 mAP@0.5:0.95 值达到 0.835 1, 比最低值 YOLOv13n 模型高 2.97%。

表 2 三种 YOLO 模型在 MAR20 数据集上的检测准确率对比

单位: %				
模型	precision	recall	mAP@0.5	mAP@0.5:0.95
YOLOv8n	0.972 9	0.977 4	0.987 3	0.818 7
YOLOv8s	0.982 8	0.980 7	0.988 4	0.827 1
YOLOv11n	0.973 9	0.974 2	0.987 0	0.809 6
YOLOv11s	0.986 9	0.976 1	0.990 4	0.835 1
YOLOv13n	0.970 3	0.962 4	0.984 1	0.811 0
YOLOv13s	0.982 4	0.981 5	0.988 4	0.832 1

图 1 显示了三种 YOLO 模型的预测的结果图, 从图中可以看出在第 456 号图片中只有 YOLOv13s 模型对左侧的 A20 目标飞机做出了正确的预测, 表明其模型结构中的 HyperACE 机制能够自适应地增强目标特征, 对于小目标检测的效果较好。但在第 434 号图片中, 右侧存在疑似目标飞机的图像, 但在标签图片中并没有进行标注, YOLOv11n 和 YOLOv13n 模型都对其做出了错误预测, 只有 YOLOv8n 模型没有对其做出错误预测。说明 YOLOv11 和 YOLOv13 模型虽然对于微小目标的识别具备较为敏感的特点, 但有可能出现误判情况。

2.4 检测速度与模型效率分析

实时性在军事应用中至关重要, 为此对比了三种模型在相同 GPU (NVIDIA GTX3090) 上的推理速度, 深度学习框架使用 PyTorch, 输入图片尺寸大小选择 640 px×640 px, 结

果如表 3 所示。




图 1 三种模型在图像中的检测结果

表 3 三种 YOLO 模型的推理速度与效率对比

模型	Size/MB	参数量 /10 ⁶	Inference time /(ms·image ⁻¹)	FPS /(帧·s ⁻¹)
YOLOv8n	6.2	3.2	9.54	104.85
YOLOv8s	21.5	11.2	9.94	100.57
YOLOv11n	5.4	2.6	12.35	80.98
YOLOv11s	18.4	9.4	12.30	81.28
YOLOv13n	10.1	2.5	23.06	43.36
YOLOv13s	35.2	9.0	23.46	42.62

表 3 对 YOLOv8、YOLOv11 以及 YOLOv13 这三类模型进行比较分析。主要从三个方面进行比较, 模型大小、参数量、单张图片上推理所需时间和每秒可以处理帧数 (FPS)。

模型大小以及所占内存空间是终端部署的基础,在模型参数量上 YOLOv13n 参数量最少可用于部署到边缘计算设备上。参数量较大的模型虽然不适合部署在终端设备上,但是对准确率有较高要求并且有足够计算能力的设备也可以采用。

从推理时间来看,三种模型在其各自不同规格之间推理时间差异不大,但是不同模型之间因为所采用的设计方案不同导致它们之间的推理速度有较大区别。YOLOv8 系列具有非常明显的优势,而 YOLOv13 则采用了 HyperACE 结构,在设计上更注重提高模型表示能力和检测准确率而不是推理的速度。

YOLOv8n 推理延迟为 9.54 ms/image,相当于每秒处理图像数量为 104.85 帧/s,而 YOLOv11n 帧率为 80.98 帧/s, YOLOv8n 比 YOLOv11n 推理速度快约 29.5%,进一步与 YOLOv13n 相比,其推理速率为 43.36 帧/s, YOLOv8n 帧率为 YOLOv13n 帧率的 2.4 倍。

3 军事应用研究

3.1 军事侦察场景的模型适用性分析

军事侦察一般使用卫星或者无人机等进行,但这些设备计算能力较弱,因此就需要模型具有较高的识别准确率的同时尽可能减少其开销。在这种情况下, YOLOv13n 由于其全局高阶建模能力和小型化的设计使其是最优解,尤其是对于复杂的背景下小目标识别。比如隐身无人机在遥感影像中往往只是一个很小的像素点并且很容易被误认为是背景,而 YOLOv13n 中的 HyperACE 可以提高对这种小目标的响应从而提高检测召回率。在边缘设备上部署时, YOLOv13n 的参数量只有 2.5×10^6 , 要比 YOLOv8n (3.2×10^6) 减少约 22%, 且比 YOLOv11n (2.6×10^6) 更小。

但是, YOLOv13 在 NVIDIA GTX3090 GPU 上推理速度 (43.36 帧/s) 低于 YOLOv8n (104.85 帧/s)。这主要是由于超图建模带来的额外开销。如果侦察任务对实时性要求很高并且可以牺牲一些检测精度,那么使用 YOLOv8n 可能会更好一些。但是对于需要检测小目标且精度要求很高的情况(例如隐形飞机检测),则 YOLOv13 更高的精度会更有利,在这种情况下漏检会造成严重后果。除此之外, YOLOv13 FullPAD 方法实现全过程跨尺度特征传递,在军事侦察中对目标大小变化有较大帮助。

从检测精度上看, YOLOv11s 在 MAR20 上 mAP@0.5 达到 0.990 4, 精度为 0.986 9, 在六个模型中最高。但模型大小以及参数量并未比 YOLOv8n、YOLOv11n、YOLOv13n 小。

3.2 战场监控场景的模型适用性分析

战场监控系统一般要处理大量高清视频流,实时发现、跟踪目标并对威胁作出迅速判断,在运动战场情况下对模型提出较高要求。

对于多任务需求,在战场监控中可能要完成目标检测、损伤判断以及威胁感知等工作,而 YOLOv11 的优势在于其可以实现多个任务的一体化处理,即目标检测、实例分割、图像分类、姿态估计、旋转框检测(OBB)五个任务都可以用一个模型来处理,这对既要识别飞机又要对其损伤情况进行分析的战场评估非常有利;但是 YOLOv13 目前只针对目标检测研究较多,在其他领域如分割等方面还未有相关工作开展。

战场监控系统还需要应对恶劣环境以及不同光线下带来的挑战困难,例如低照度或者光学畸变等问题。Ci 等^[10]基于 YOLOv8,在此基础上添加 SCI-Gamma 图像增强子网络进行自适应低照度图像改善,这也说明其对于类似军事遥感中的复杂光照条件有着很好的鲁棒性。

战场监控系统一般部署在车载 GPU 或者固定位置上,硬件资源比较丰富,所以可以选择使用 YOLOv11 或者 YOLOv13 这类大模型来提高检测准确率以及得到更好的表征效果;但是如果系统要同时对多个视频进行处理时,则需要考虑模型大小以及运行效率之间的关系,选取合适的参数模型版本。

3.3 火力打击场景的模型适用性分析

火力打击场景对于目标检测模型要求最高,在光学制导、红外制导等都有所应用,模型需要对识别率、检测速度以及鲁棒性三个方面进行考虑,这三点直接影响到打击的效果以及作战成功率。

在检测精度上, YOLOv11 使用加权 RMSE 损失,除了中心点坐标误差之外,还加入宽度与高度的比例影响因素,从而使模型对于边界框回归更准确。在准确率、mAP@0.5 以及 mAP@0.5:0.95 三个评估指标中, YOLOv11s 得分最高。而对于军事遥感图像中的飞机目标来说,这个准确的定位是十分重要的,因为直接影响到制导武器命中率。值得注意的是 YOLOv13n 模型在召回率上最高,而召回率是指把假负例误判成正例的能力,在敌我识别中是很重要的,所以在选取模型时需兼顾准确性和召回率这两个方面。YOLOv11 以及 YOLOv13 在这两方面都比较优秀。

从检测速度来看, YOLOv8 表现良好,推理时延仅 9.54 ms/image,等效帧率为 104.85 帧/s,这在一定程度上对于一些需要快速做出反应的情况是有帮助的,比如在防空导弹上安装光学或红外制导武器,由于决策以及打

击都需要尽可能快地进行。但是 YOLOv11n 的速度比不上 YOLOv8n。而 YOLOv13 虽然利用 DS-C3k2 提升计算效率，但是由于其采用超图方式进行建模，在低端设备上会带来较大的负担，从而降低实时性。

对于鲁棒性，火炮打击系统还应具有良好的模型鲁棒性。战场上会有很多干扰物，例如烟雾或者电磁干扰等，都可能造成目标检测出错。YOLOv11 利用改进 SEAM 模块解决遮挡问题，即提升未被遮挡部分检测结果以弥补被遮挡部分损失；而 YOLOv13 采用 HyperACE 方法能够自主发现潜在高阶关系，在有干扰情况下也能取得较好检测效果。

3.4 未来研究方向

YOLO 系列模型在军事飞机遥感图像检测方面还有很大的发展空间，在以下几方面可以进一步研究。

(1) 多模态融合与超图建模的深度结合

未来工作可研究如何利用超图建模以及多源遥感信息（包括可见光、红外、SAR 等），从而形成更为优秀的军事目标探测器。例如，引入激光雷达点云信息，以更好地发现隐身飞机；或者加入高光谱信息，以便更准确地分辨目标材质和状态。而这种多源信息融合可以使基于 YOLOv13 超图建模得到进一步应用到更多复杂战场环境中，从而极大地改善其探测效果。

(2) 边缘设备上的自适应优化与部署

军事侦察系统一般部署在边缘设备上，今后可研究如何让模型在边缘端进行自我优化的方法，比如根据设备算力的变化改变模型的深浅，在推理时根据实际情况改变超图建模的复杂程度等。还可以研究对模型进行压缩的技术（如知识蒸馏、量化等），以保证检测的效果尽可能减少模型所占空间大小及计算量，符合边缘设备的条件。

(3) 军事专用数据集的构建与优化

目前公开的军事遥感数据集数量有限并且缺乏多样性，后续工作可以建立更大规模、更具多样性的军事专用数据集，包括各种环境、各种光照条件下飞机目标，以使模型具有更强鲁棒性；也可以进行数据增强的研究，在考虑军事遥感图像特点的基础上（如小目标、复杂背景、目标形变等）提出针对性的数据增强方式，进一步提升模型鲁棒性。

(4) 实时性与精度的平衡优化

军事侦察与监视系统对时效性和检测准确性有要求，在此方面未来工作可尝试改进网络结构，例如进一步优化深度可分离卷积单元或者设计专门的小型化网络以加快推理速度；另外也可以进行模型剪枝以及量化，在不影响检测准确率的情况下大幅度减少运算量满足不同军事设备条件。

(5) 泛化能力与时序信息利用

MAR20 数据集为军事飞机遥感图像，对于对地机场类

目标打击有较高的研究价值，对于对空目标，识别目标有更多的姿态角度，并且目标姿态实时变化，对于目标识别准确率有更高的挑战。并且数据获取方式更加困难，需要模型具备更高的泛化能力。可以利用时序信息跟踪飞机动态，增强行为理解和意图判断能力。

4 结论

本研究通过系统对比分析 YOLOv8、YOLOv11 及 YOLOv13 三种目标检测模型在 MAR20 数据集上的性能表现，为军事遥感图像中军用飞机目标检测提供参考。研究发现，不同模型在关键指标上表现出明显的性能差异：YOLOv11s 在检测准确率 precision、mAP@0.5 和 mAP@0.5:0.95 三个指标上表现最优，YOLOv8n 在推理速度上领先（104.85 帧/s），YOLOv13n 在参数量上最小（ 2.5×10^6 ）。

首次系统对比了最新 YOLO 系列模型在军事飞机遥感图像检测任务中的性能；深入分析了军事侦察、战场监控、火力打击三个方面场景下模型的适用性；提出了未来研究方向，包括多模态融合与超图建模的深度结合、边缘设备上的自适应优化、军事专用数据集的构建与优化、实时性与精度的平衡优化以及泛化能力与时序信息利用。

然而，本研究也存在一些局限性：MAR20 数据集主要涵盖已知型号的军用飞机，对新型号或隐身飞机的检测能力有待验证；实验主要在 GPU 平台进行，未充分考虑不同军事平台的硬件限制；未来研究将着重于构建更全面的军事专用数据集，提高模型在复杂环境下的泛化能力，以及探索更高效的专用模型架构设计，在保证检测精度的同时进一步提升实时性，为军事应用提供更可靠的技术支撑。

参考文献：

- [1] 杨环宇,王军,吴祥,等.一种坐标通道注意力深度学习网络的军用飞机识别方法[J].兵工学报,2024,45(7):2128.
- [2] 周韩莲,叶青,刘文祺.复杂背景下的轻量级遥感军用飞机目标检测[J].光电工程,2025,52(2):89-104.
- [3] 王耀领,王宏琦,许滔.CGAN 样本生成的遥感图像飞机识别[J].中国图象图形学报,2021,26(3):663-673.
- [4] 党玉龙,叶成绪.基于 Faster R-CNN 的轻量化遥感图像军用飞机检测模型[J].激光杂志,2024,45(7):111-117.
- [5] 陈铁明,付光远,李诗怡,等.基于 YOLO v3 的红外末制导典型目标检测[J].激光与光电子学进展,2019,56(16):155-162.
- [6] 刘子洋,徐慧英,朱信忠,等.Bi-YOLO:一种基于 YOLOv8n 改进的轻量化目标检测算法[J].计算机工程与科学,2024,46(8):1444-1454.

基于多模型集成的代码语义理解优化方法研究

门汝熹¹
MEN Ruxi

摘要

针对代码语义理解中多维特征难以统一建模的问题,文章提出一种基于多模型集成的优化方法。构建由文本、结构与交互语义编码器组成的多通道特征提取模块,通过注意力引导的动态加权机制实现融合表示。引入联合训练策略以实现异构语义空间的协同优化。在代码智能理解评估基准(CodeXGLUE)数据集上进行代码分类、缺陷检测与克隆检测实验。相较主流单模型与集成方法,在准确率、 F_1 值及平均准确率均值(mean average precision, mAP)等指标上表现更优。消融实验表明,结构建模与语义交互模块贡献显著,融合与优化策略增强模型稳定性,验证方法在复杂语义场景下的有效性与适应性。

关键词

代码语义理解;多模型集成;异构特征建模;动态融合机制;联合训练;抽象语法树

doi: 10.3969/j.issn.1672-9528.2026.07.007

0 引言

近年来,代码语义理解在软件缺陷检测、代码克隆分析与智能审计中发挥关键作用。源代码同时具备语言序列、结构拓扑与上下文依赖等多重语义,单一建模策略难以全面捕捉其深层信息,限制模型的泛化与迁移能力。为提升语义建模能力,多模型融合与异构语义集成成为研究重点。

魏政等^[1]提出结合语义还原机制与大模型知识迁移可提升混淆代码识别精度,验证深层语义建模在安全分析中的有效性。周放等^[2]基于源代码迁移设计编译优化策略,强调结构语义对迁移过程的稳定支撑。王彦昕等^[3]在跨形态相似性识别中指出结构建模对语义保持与对齐的重要性。张璐等^[4]构建多元语义图模型,实现对二进制语义的高精度建模,为

多模态集成提供路径参考。

在此基础上,整合文本、结构与交互三类语义通道,构建多通道编码器架构,设计注意力引导的动态融合机制,提出统一的多模型集成优化框架,增强语义空间的协同建模能力与表达一致性,以期为复杂代码语义理解任务提供具备可扩展性与鲁棒性的建模方案。

1 多模型集成概述

多模型集成通过构建多元表征空间,缓解单一模型在编码粒度与语义视角上的局限。在代码语义理解任务中,语言模型建构序列上下文语义,结构模型捕捉抽象语法结构的拓扑依赖,交互模型建模多通道间的语义协同。模型间的异构性带来特征空间的不一致,需通过融合策略进行对齐与调控。集成方式涵盖输入共享、编码耦合、输出对齐,融合机制包

1. 南宁市勘测设计院集团有限公司 广西南宁 530000

[7] 柏栋,于英,宋亮,等.面向军用车辆细粒度检测的遥感图像数据集构建与验证[J].中国图象图形学报,2024,29(12):3564-3577.

[8] 禹文奇,程堪,王美君,等.MAR20:遥感图像军用飞机目标识别数据集[J].遥感学报,2023,27(12):2688-2696.

[9] Sohan M, Sai Ram T, Rami Reddy C V. A review on YOLOv8 and its advancements[C]//International Conference on Data Intelligence and Cognitive Informatics. Berlin:Springer,2024:529-545.

[10] Ci Wenyan, Hou Hongyi, Lu Shan, et al. Multi-module enhanced low-light object detection: from image enhancement

to adaptive feature fusion[J]. Advanced Engineering Informatics, 2026, 69: 104097.

【作者简介】

王一凡(1997—),男,河南郑州人,硕士,助教,研究方向:深度学习、计算机视觉。

樊登华(1997—),男,河南新乡人,硕士,助教,研究方向:通信工程、计算机。

吴栋(1990—),男,河南商丘人,硕士,助教,研究方向:控制工程。

(收稿日期:2025-12-01 修回日期:2026-07-08)