

中图法分类号: TP18; TP391.4 文献标识码: A 文章编号: 1006-8961(2026)02-0433-15

论文引用格式: Wu Z L, Lian X N, Zhao Z S and Meng Q. 2026. ST1.0: a synthetic dataset for military tank detection in drone imagery. Journal of Image and Graphics, 31(2):0433-0447(吴正龙, 连细南, 赵忠实, 孟奇. 2026. ST1.0: 无人机视角下坦克目标检测仿真数据集. 中国图象图形学报, 31(2):0433-0447)[DOI:10.11834/jig.250080]

ST1.0: 无人机视角下坦克目标检测仿真数据集

吴正龙, 连细南*, 赵忠实, 孟奇

陆军炮兵防空兵学院兵器工程系, 合肥 230031

摘要: 目的 随着计算机仿真技术的迭代演进, 仿真图像数据正逐步成为许多数据稀缺领域的有效替代资源。但在实战图像样本更为匮乏的军事目标检测任务中, 基于仿真数据及其融合策略训练的检测模型能否在真实战场中实现有效泛化, 仍缺乏实证支撑。为此, 制作了包含不同仿真域数据、作战场景和坦克型号的无人机视角坦克目标检测仿真数据集(synthetic tank, ST)1.0版本, 包括ST1、ST2和ST3三个子数据集。**方法** 通过构建仿真数据与实战场景检验框架, 基于不同仿真数据分别训练 Cascade R-CNN(cascade region-based convolutional neural network)、YOLOv10(you only look once version 10)和 RT-DETR(real-time detection Transformer) 3类异构检测器后, 在公开数据集与俄乌实战图像中展开跨域测试。系统探究了仿真域差异性(实验1)、混合仿真域组合效应(实验2)及数据增广策略(实验3)对模型泛化性能的影响。**结果** 实验中所有模型的平均精度(average precision, AP)均值均随测试数据趋近真实作战场景呈下降趋势, 其中 RT-DETR 模型在跨域检测中具有更强鲁棒性, 在两个测试集上的AP最高达到 54.50% 与 42.30%; 具备视觉真实性、目标域属性适配且可视化特征分布相近的仿真数据表现更佳; 混合或增广优质仿真数据可显著提升模型性能。**结论** 仿真图像数据能在一定程度上缓解实战图像数据稀缺问题, 为武器平台的实战运用提供支持。但仍存在跨域泛化局限性, 需结合其他源域及域泛化技术等进一步提升。

关键词: 坦克目标检测; 无人机(UAV); 仿真数据; 单源域泛化; 实战运用

ST1.0: a synthetic dataset for military tank detection in drone imagery

Wu Zhenglong, Lian Xinan*, Zhao Zhongshi, Meng Qi

Department of Ordnance Engineering, PLA Army Academy of Artillery and Air Defense, Hefei 230031, China

Abstract: Objective The continuous evolution of computer simulation technology has made synthetic data an effective solution for data-scarce domains. However, in military target detection—where battlefield samples are exceptionally sparse—the cross-domain generalization of models trained on synthetic data remains empirically unverified. This research aims to explore the mechanisms underlying the cross-domain generalization of synthetic data, with a particular emphasis on tank target detection from unmanned aerial vehicle (UAV) perspectives. A key contribution of this study is the development of the synthetic tank (ST) 1.0 dataset, which comprises three distinct subsets (ST1, ST2, and ST3), each containing 1 600 images. These subsets are differentiated by their data sources and exhibit varying levels of simulation precision and scenario realism. This tiered design enables the deconstruction of the “domain gap” to quantify the effect of different types of synthetic data on model generalization. Ultimately, this research seeks to provide quantitative and qualitative insights into how synthetic data can be leveraged to train object detectors for practical deployment in modern weapon systems. **Method** To rigorously evaluate the cross-domain generalization of models trained on synthetic data, this study proposes a multilay-

收稿日期: 2025-02-28; 修回日期: 2025-07-15; 预印本日期: 2025-07-23

* 通信作者: 连细南 lianxinan18@163.com

ered validation framework and a structured experimental design. The three-level validation framework systematically assesses performance across domains: 1) synthetic domain: models are tested on reserved synthetic subsets (e. g. , models trained on ST1 are evaluated on the ST1 test set), establishing a performance benchmark in a controlled “ideal” setting to quantify basic synthetic-domain capabilities. 2) Real domain: performance is evaluated using public real-world military tank datasets comprising 41 images, with 11 sourced from ImageNet and 30 from Open Images V7. This step quantifies the initial synthetic-to-real domain discrepancy, elucidating the challenges in transitioning from controlled synthetic environments to real-world scenarios. 3) Combat domain: models are evaluated on a proprietary dataset consisting of UAV-acquired imagery collected from combat areas. This dataset contains 1 000 images depicting complex combat scenarios and is designed to serve as a rigorous benchmark for assessing model generalization and battlefield adaptability. To mitigate architecture-specific biases, we evaluate three representative heterogeneous object detectors: cascade R-CNN is a two-stage anchor-based model that enhances proposal accuracy through cascaded regression and classification. YOLOv10 is a single-stage detector optimized for latency-sensitive applications while maintaining competitive precision. RT-DETR is a real-time Transformer-based architecture that leverages global self-attention to model long-range dependencies. Furthermore, we incorporate a contemporary state-of-the-art detector, YOLOv12, as an additional performance benchmark. The experimental design is structured around three research inquiries: 1) synthetic domain discrepancy: this inquiry analyzes how model performance varies when trained on ST1, ST2, or ST3 and evaluated using the three-level validation framework, directly assessing the influence of different synthetic domains on generalization. 2) Mixed synthetic strategies: this aspect investigates the effects of training on mixed datasets, aiming to determine whether combining samples from multiple synthetic domains can enhance model robustness and generalization capabilities. 3) Data augmentation efficacy: this inquiry examines the effectiveness of using data from one synthetic domain to augment training on another. This approach systematically assesses whether cross-domain data augmentation can further improve generalization and mitigate domain-specific biases. **Result** Experimental investigations provided insights into the intricate relationship between synthetic data and real-world model performance. First, across all evaluated architectures, model performance—as measured by average precision—declined significantly when moving from controlled synthetic environments to real-world scenarios and further to the highly unpredictable combat domain. This trend clearly highlights the pronounced effect of the domain gap. Second, among the three detectors, RT-DETR consistently exhibited greater cross-domain robustness, with performance degrading more gradually in real-world and combat domains in comparison with the other detectors. Third, the generalization capability of models can be substantially enhanced through the incorporation of high-quality synthetic data. Such data are characterized by three critical attributes: photorealistic fidelity, adaptability to target-domain attributes, and close alignment with the feature distribution of real-world data. These qualities collectively ensure that synthetic data not only visually resemble real data but also effectively capture the underlying characteristics and variability of the target domain, thereby facilitating improved model robustness and transferability across diverse operational scenarios. Fourth, model performance can be further improved by incorporating high-quality synthetic data through data mixing or augmentation strategies. These methods effectively reduce overfitting on dataset-specific characteristics by introducing data distributions that closely mirror those of the target domain. **Conclusion** Research has demonstrated that synthetic data can partially alleviate the scarcity of real-world data in the military domain, providing critical support for the practical deployment of weapon systems. However, synthetic data continue to exhibit inherent limitations in cross-domain generalization. Future research should prioritize the collaborative construction of multisource heterogeneous datasets and the deep integration of domain generalization techniques while broadening the research scope to encompass a wider array of military target categories and model architectures. Furthermore, investigating the security boundaries of intelligent data fusion in decision-making processes is essential to establish more scientific and reliable methodologies for constructing military object detection datasets.

Key words: military tank detection; unmanned aerial vehicle (UAV); synthetic data; single-source domain generalization; operational application

0 引言

随着无人机(unmanned aerial vehicle, UAV)技术的快速发展,无人机在军事领域的应用越来越广泛。坦克作为陆战场的重要装甲力量,其在无人机视角下的快速准确检测,对战术部署和火力打击至关重要。

近年来,基于深度学习的目标检测算法取得了显著成果,包括二阶段检测 Faster R-CNN (faster region-based convolutional neural network) 算法(Ren 等, 2017)等,一阶段目标检测 YOLOv3(you only look once version 3)(Redmon 和 Farhadi, 2018)等,以及基于 Transformer 架构的目标检测算法(Carion 等, 2020)等。这些算法通过深度神经网络高效提取图像特征,大幅提升目标检测准确性和效率。然而实际应用中,算法性能往往受限于数据集的构建。特别是军事目标检测领域,数据稀缺性尤为突出。在实战应用场景下,既无法采集到并未发生的战场图像,也难以通过日常侦察情报活动获得充足的图像

数据。因此,随着仿真图像数据的发展和有效应用(薛振锋, 2021; Gao 等, 2023; 胡学敏 等, 2024),其在军事领域开始得到关注。研究者主要依托仿真引擎或军事游戏等方式构建目标仿真数据,表 1 汇总了包含坦克装甲目标仿真图像的军事目标检测数据集及本文构建的 ST1.0 数据集。

表 1 中大部分研究在相同仿真域下训练与测试,部分研究使用仿真与真实混合数据进行训练与测试。Truong 等人(2024)考察了真实与仿真混合数据训练后的模型在真实场景中的效果,Truong 等人(2025)进一步研究了仿真数据风格迁移后混合真实数据训练的模型在真实场景中的性能,但上述研究并未解耦仿真数据的真实应用效果。少部分研究仅使用仿真数据训练、真实场景测试。如朱凯(2019)使用少量演训基地图像进行测试,但在数据构建中并未说明成像视角。Hartnett 等人(2020)分别考察了机载视角下仿真(640 幅训练图像)、真实(418 幅训练图像)及混合数据训练的模型在真实场景中的检测效果(214 幅测试图像),但该研究数据量小,仅使用单一仿真域数据,在真实数据测试中,结果近乎为零。

表 1 代表性军事目标检测数据集与 ST1.0
Table 1 Representative military target detection datasets and ST1.0

数据集	图像数量/幅	平台	训练数据	测试数据	类别	坦克图像	坦克实例
张奔等人(2021)	2 191	弹载	仿真	仿真	1	自行火炮	6 436
王少博等人(2022)	400	弹载	仿真	仿真	6	-	-
Luo 等人(2023)	2 000	-	仿真	仿真	3	787	-
Zeng 等人(2024)	5 238	机载	仿真	仿真	5	-	6 598
田宗浩等人(2022)	8 000	弹载	混合	混合	8	> 800	-
Meng 等人(2020)	11 536	-	混合	混合	1	11 536	30 132
Meng 等人(2022)	11 036	-	混合	混合	4	3 000	-
Truong 等人(2024)	3 600	-	混合	真实	5	1 063	-
Truong 等人(2025)	3 238	-	混合	真实	5	-	-
朱凯(2019)	2 000	-	仿真	仿真+真实	1	-	-
Hartnett 等人(2020)	1 272	机载	仿真+真实	真实	1	1 272	-
ST1.0(本文)	4 800	机载	仿真	仿真+真实	1	4 800	19 503

注:“-”表示未提及。

上述研究除 Truong 等人(2024, 2025)和 Hartnett 等人(2020)外,多集中于算法优化研究,较少分析仿真数据的构建与实践运用效果。同时,也应注意到不同数据类型及成像视角等均会使数据分布产生差

异。目前,基于机载平台的仿真数据在真实乃至实战场景中的应用实效如何,尚未获得充分的研究支持。鉴于此,本文研究基于构建的 ST1.0 和两个真实数据集(公共数据集与俄乌实战场景中机载下视

坦克图像数据集)开展实验分析,具备以下突出特点:1)构建了专门适用于机载视角下坦克目标检测的仿真图像数据集。该数据集包含多种不同仿真数据域,可评测不同仿真域效果差异。数据集图像样本量与坦克目标实例数充足,覆盖丰富多样化作战场景及目标尺度区间。2)首次从大型公开数据集中获取机载视角的坦克目标图像,构建公平测试基准。同时,采集俄乌实战场景下坦克图像测试,检验仿真坦克图像数据在实战应用中的性能。3)设计多样化实验方案,将ST1.0划分为不同实验组,运用不同架构的代表性目标检测算法,对数据基准性能展开全面评估,建立仿真图像数据跨域泛化性能的基本视图。

本文探究了仿真坦克图像数据在实战场景中的应用价值,为未来实战中军事目标检测任务的数据构建提供思路和参考。

1 ST1.0数据集构建

1.1 构建流程

数据集构建主要包括数据收集、数据清洗、数据标注和数据划分4个步骤。本文数据主要来源包括自建仿真场景模拟器、军事游戏及互联网资源等。本研究对不同原始数据实施定制化清洗后,依据标注指南,统一标注校对并划分。总体构建流程如图1所示,列出了不同数据源及主要处理步骤。




图1 数据构建总体流程

Fig. 1 Overall process of data construction

构建的 ST1.0 数据集,涵盖 3 个子数据集,囊括不同仿真条件与场景,为研究奠定仿真数据基础。PUAVtank41 和 RUUAVtank1000 是分别从大型公开数据集和俄乌实战图像资源中,通过专家先验筛选构建而成的无人机视角下的坦克图像,作为真实测试数据基准。

1.2 数据收集

1.2.1 自建仿真场景模拟器仿真坦克图像数据

ST1 子数据集由实验室自建的仿真系统生成。系统允许预设飞行高度、俯仰角、偏航角和滚转角,以模拟各种下视成像情况。场景涵盖沙漠、林地、平原和山谷等环境,并考虑了不同场景下的环境参数,如林地环境季节变化和林木密度、高度等。可设定天气和时段,天气包含阴晴云雾雨条件,其中,雨、

雪天可设定 0~1.1 mm/h 和 0~22 mm/h 范围的不同雨雪量,雾天分为轻雾、雾、大雾、浓雾、强浓雾 5 个等级,云包含少云、疏云、多云 3 个等级,时间段范围涵盖全天时不同照度。目标层面可根据作战场景构想,设定不同坦克类型、生存状态、运动状态和坦克群分布等。图2展示了不同场景与目标尺度的仿真坦克示例,本节图像中,坦克目标均叠加红色标注框以指示位置与尺度。

1.2.2 军事主题游戏仿真坦克图像数据

选取具有真实度和丰富场景的军事主题游戏作为数据源。其中,ST2 子数据集样本全部来自 Arma 3 军事主题游戏。首先通过环境配置,安装必要地图、坦克和无人机等模组,利用游戏内置接口和屏幕捕捉技术,在游戏运行过程中录制采集。设定相机相




图2 ST1子数据集样本

Fig. 2 Samples of ST1

对位置和角度变化等,尽可能涵盖坦克在不同场景、视角和光照下的图像。录制完成后,按固定间隔抽取,剔除重复数据等,保留无人机视角成像数据。

ST3子数据集采用更为复杂的数据采集策略。混合多个不同军事游戏,如 War Thunder、Warning Order 和 World of Tanks 等,但不包括 Arma 3,这些数据的采集主要通过网络爬取互联网资源完成。此外,还采集了 CGTrader 等部分仿真数据平台中的坦克图像以进一步丰富数据。两个子数据集的图像示例如图3所示。

1.2.3 互联网资源真实坦克图像数据

首先,考虑大型公开数据集中的坦克图像。机器视觉领域中 Pascal VOC(pattern analysis, statistical

modeling and computational learning visual object classes)(Everingham 等,2010)、ImageNet(Deng 等,2009)、Microsoft COCO(Microsoft common objects in context)(Lin 等,2014)、Open Images(Kuznetsova 等,2020)和 Objects365(Shao 等,2019)等大型公开数据集备受推崇,但仅有 ImageNet 和 Open Images 数据集中包含坦克目标数据。同时,大多数公开专业领域数据集主要针对民用领域,而坦克目标属于国防军事领域,公开可用的坦克目标数据集几乎没有。因此,研究首先从 ImageNet 和 Open Images 数据集中获取坦克目标图像(ImageNet 中 601 幅,Open Images 中 1 246 幅)及标注。经排重与人工遍历筛选后,保留符合无人机成像视角的图像,并校对原始标注。构建了 PUAvtank41 数据集,包含 41 幅无人机视角的坦克图像,ImageNet 中 11 幅,Open ImagesV7 中 30 幅。

其次,为收集具有代表性和多样性的实战场景下坦克图像数据,基于预定义词表广泛遍历查询。词表涵盖多样化地形(如城市、丛林等)、天气(如雪天、晴天等)及天时(如黎明、黄昏等)等。通过搜索引擎及军事信息平台等渠道,获取俄乌实战场景下的坦克图像。为确保数据质量,在剔除重复、低质量及非坦克目标等数据后,使用人工遍历方式,保留具有无人机视角特征的图像,构建 RUUAVtank1000 数据集。PUAvtank41 与 RUUAVtank1000 图像示例如图4所示。

1.3 清洗标注

数据清洗是确保数据质量和一致性的关键步




图3 ST2和ST3子数据集样本

Fig. 3 Samples of ST2 and ST3




图4 PUAvtank41和RUUAVtank1000数据集样本

Fig. 4 Samples of PUAvtank41 and RUUAVtank1000

骤,直接影响后续图像处理与分析的可靠性。针对各数据集特性,实施定制化清洗。特别是网络爬取数据,普遍存在数据污染,如图像重复、质量不一等。研究主要采用以下清洗策略:1)统一图形格式、通道数以简化后续处理;2)对视频数据跨帧采样,减少冗余;3)通过文件名比较、哈希算法与人工审阅去除重复或相似图像;4)人工筛选,研究关注无人机视角下坦克目标检测的实战运用效果,除可控仿真图像生成外,均由人工判别,保留符合成像视角的图像。

清洗后遵循标注指南,标注边界框与类别。为确保标注准确性与一致性,数据由具备军事领域知识的成员标注。针对复杂图像数据,采用集中处理和多人交叉验证方式标注。标注完成后,采取随机抽查与专家评审相结合方法检查质量。

1.4 数据集划分

研究按照8:1:1比例将仿真坦克图像划分为训练集、验证集和测试集。此外,从RUUAVtank1000数据集中筛选出41幅代表性图像,构成RUUAVtank41测试集,便于比较分析公开数据集中坦克图像数据与俄乌实战中坦克图像数据的检测效果差异。为简化行文,将PUAVtank41、RUUAVtank41和RUUAVtank1000分别记为PU41、RU41和RU1000。表2展示了不同数据集中图像数量分布情况。

2 实验测试

2.1 问题建模

实验研究仿真数据在真实及实战场景中的运用效果,这种数据域分布差异会产生域偏移现象。为解决域偏移问题,相关理论应运而生。




图5 研究方向分类

Fig. 5 Taxonomy of research directions

2.2 实验设置

2.2.1 基本情况

实验采用3类异构代表性目标检测算法,包括

表2 数据集图像数量分布

数据	总数/幅	训练集/幅	验证集/幅	测试集/幅
ST1	1 600	1 280	160	160
ST2	1 600	1 280	160	160
ST3	1 600	1 280	160	160
ST1.0	4 800	3 840	480	480
PU41	41	0	0	41
RU41	41	0	0	41
RU1000	1 000	0	0	1 000

定义 $\mathcal{D} = \{\mathcal{X}, \mathcal{Y}, P(x, y)\}$ 为一个数据域,其中, $P(x, y)$ 表示数据域中一个样本输入 x 和输出 y 服从的概率分布, $\mathcal{X}, \mathcal{Y}$ 分别表示数据所处的特征空间和标签空间,对于任意样本 (x_i, y_i) ,都有 $x_i \in \mathcal{X}, y_i \in \mathcal{Y}$ 。通常将具有丰富数据和标签的域称为源域 $\mathcal{D}_s$ (source domain),而缺少数据或标签的域称为目标域 $\mathcal{D}_t$ (target domain)。根据能否应用目标域数据进行迁移、标签特征空间与源域数量差异等,可将相关研究划分为如图5所示的不同方向。

目前,在域泛化方向,主要集中于多源域泛化,常采取数据操作手段、特征学习和优化策略3种方式提高模型在未知目标域的泛化能力(操晓春等,2025)。本文关注仿真数据域在真实及实战场景中的运用效果,将问题定义为同构单源域泛化问题(史彩娟等,2024),即源域与目标域标签空间相同,模型训练时仅使用仿真域数据,但无法应用真实目标域数据用于迁移学习的情况。其任务是利用有标签的源域仿真数据学习一个足够好的函数,以预测真实目标域数据上的标签。

Cascade R-CNN(Cai和Vasconcelos,2021)、YOLOv10(you only look once version 10)(Wang等,2024)和RT-DETR(real-time detection Transformer)(Zhao等,

2024), 以提供仿真数据泛化性能的基准视图, 并使用最新的 YOLOv12 算法(Tian 等, 2025)作为性能参考。为提高实验结论的普适性, 在遵照原文设置基础上并未改进检测器或采用其他学习策略。

实验环境在 Windows10 操作系统上搭建, CPU 参数为 Inter(R) Core(TM) i9-11900H, GPU 参数为 NVIDIA GeForce RTX 3080, 专用显存 16 384 MiB, pytorch 版本 2.0.1, CUDA 版本 11.8。

2.2.2 超参设置

因采用不同架构的目标检测算法, 在预训练模型选择与参数设置上, 根据实验环境计算能力水平, 遵循算法原文设置超参数。如 YOLOv10 算法, 加载 COCO 数据集上的 YOLOv10x 预训练权重, 批大小为 8, 使用随机梯度下降(stochastic gradient descent, SGD)作为网络优化器, 预热为 3 轮次, 动量参数为 0.937, 初始学习率 10^{-2} , 最终学习率 10^{-4} 等。

2.2.3 评价指标

采用平均精度(average precision, AP)评估检测算法核心性能表现, 其指在不同召回率(recall, R)水平下精度(precision, P)的平均值。通过设定不同交并比(intersection over union, IoU)阈值可以衡量模型在不同定位精度下的性能, 实验中 AP 是计算 IoU 在 0.5 到 0.95(步长 0.05)下 AP 的平均值。

2.3 实验结果

2.3.1 实验 1: 考察仿真域差异

运用 Cascade R-CNN、YOLOv10 以及 RT-DETR 3 类异构目标检测算法, 分别于 ST1、ST2 和 ST3 上训练, 尔后在不同测试集上评估模型平均精度。实验结果如表 3 所示, AP^{Self} 指模型在自身仿真测试集中的 AP 值, AP^{PU41} 指模型在 PU41 公共数据测试集中的 AP 值, AP^{RU41} 和 AP^{RU1000} 则指在不同俄乌实战图像数量测试下模型的 AP 值。

将不同仿真数据集与模型在不同测试数据上的实验结果绘制成分簇散点图 6, 横轴代表不同测试数据, 纵轴为 AP 指标, 图中标注点表示经不同仿真数据训练后, 3 类异构模型在不同测试数据上的 AP (为避免 AP 间数值重叠, 施加 $[-0.2, 0.2]$ 范围的水平随机偏移), 五角星标识代表各测试数据下 AP 的均值。

图 6 中, 同分布仿真数据测试时, 模型均能获得较高的精度, AP^{Self} 最低 59.10%, 最高达 84.30%, 但模型在真实图像测试上泛化性能显著下降。 AP^{Self}

表 3 实验 1 的 AP 测试结果
Table 3 AP test results for experiment 1

数据	目标检测算法	/%			
		AP^{Self}	AP^{PU41}	AP^{RU41}	AP^{RU1000}
ST1	Cascade R-CNN	66.00	22.90	7.60	3.60
	YOLOv10	76.70	22.30	3.43	3.14
	RT-DETR	74.90	40.00	9.40	6.78
	YOLOv12	79.10	20.80	1.80	2.37
ST2	Cascade R-CNN	59.10	10.70	4.90	6.90
	YOLOv10	62.50	12.60	14.60	14.60
	RT-DETR	61.40	40.30	35.40	28.50
	YOLOv12	66.60	27.90	28.10	28.40
ST3	Cascade R-CNN	78.30	40.40	23.90	20.50
	YOLOv10	80.10	45.30	26.50	23.20
	RT-DETR	82.80	51.70	45.50	37.40
	YOLOv12	84.30	48.50	33.90	30.90

注: 加粗字体表示各列最优结果。

均值从 72.65% 降至 AP^{PU41} 均值 31.95%, 降幅达 40.70%。随测试复杂性增加, AP^{RU41} 均值进一步降低至 19.59%, AP^{RU1000} 仅为 17.19%。




图 6 不同测试集上的模型 AP 与 AP 均值

Fig. 6 AP and mean AP of models tested on different test sets

图 7 展示了不同模型经不同仿真数据集训练后在各测试集上的结果, 红绿蓝分别对应 ST1、ST2、ST3(后续绘图颜色指代不变)。结果显示, 尽管采用不同仿真域数据训练, 但 RT-DETR 在跨域测试中均优于 Cascade R-CNN、YOLOv10 及 YOLOv12。

为进一步揭示不同仿真域数据在真实域中的应用效果差异, 整合图 7(a) — (c) 内容绘制图 8。相较于 ST1 与 ST2, ST3 在各测试集上表现更优, 在公共




图7 模型在不同测试集上的AP
Fig. 7 AP of models tested on different test sets ((a) ST1;(b) ST2;(c) ST3)

数据测试集PU41和实战场景中(RU41与RU1000)的AP显著更高。对比ST1与ST2,ST1训练的模型对数据分布变化更敏感,在RU41与RU1000测试数据中性能骤降;ST2训练的模型变化更为平缓,在更复杂场景中甚至呈上升趋势,在RU41与RU1000测试中,AP均值显著优于ST1。




图8 模型在不同测试集上的AP汇总
Fig. 8 Summary of AP for models tested on different test sets

2.3.2 实验2:混合仿真域组合效应

保持与实验1相同样本量,采用混合的仿真数据训练与测试。表4中Mix(ST1 + ST2)包含1 600个样本,其由ST1和ST2的训练、验证、测试集各抽取一半构成,其他数据集构成含义相同。

根据表3和表4相关实验结果绘制点线图9观察分析,图中混合数据的颜色由其构成的仿真数据原色决定。如ST1(红)与ST2(绿)的混合Mix(ST1 + ST2)用黄色表示,Mix(ST1 + ST3)为品红色,Mix(ST2 + ST3)为青色。图9(a)展示了Mix(ST1 + ST2)、ST1、ST2训练后模型的详细测试结果,图9(b)为对应的AP均值。同时,绘制模型在其余仿真数

表4 实验2的AP测试结果
Table 4 AP test results for experiment 2

		/%			
数据	目标检测算法	AP ^{Self}	AP ^{PU41}	AP ^{RU41}	AP ^{RU1000}
Mix (ST1 + ST2)	Cascade R-CNN	62.40	17.40	5.00	5.70
	YOLOv10	69.50	19.80	12.20	11.30
	RT-DETR	68.40	40.40	34.10	25.60
	YOLOv12	74.00	21.00	14.70	23.60
Mix (ST1 + ST3)	Cascade R-CNN	72.10	43.20	24.30	19.00
	YOLOv10	78.90	40.70	32.40	21.70
	RT-DETR	54.90	50.80	37.50	32.40
	YOLOv12	81.60	53.20	32.80	26.20
Mix (ST2+ ST3)	Cascade R-CNN	68.00	38.90	32.50	25.40
	YOLOv10	71.10	45.60	32.50	26.70
	RT-DETR	73.60	51.10	43.50	39.00
	YOLOv12	60.90	54.90	40.90	29.30

注:加粗字体表示各列最优结果。

据集训练后,在不同测试集上的AP均值对比图,如图10所示。

由表4、图9和图10可见,实验现象与实验1保持一致。此外,相同样本量下,基于混合仿真数据训练的模型在跨域泛化能力上与所混合的仿真数据性能呈现出相关性。如表5所示,当混合性能优于自身的数据时,模型的跨域泛化能力得到提升,当混合性能弱于自身的数据集时,模型泛化能力呈现不确定性变化,可能提升,也可能下降。基于ST2与ST3混合数据训练的模型在目标域测试中取得最优值,ST3、ST2与ST1的混合,模型跨域测试性能呈现下降趋势。




图 9 ST1、ST2、Mix (ST1 + ST2)训练后,模型测试结果
Fig. 9 Model test results after trained on ST1, ST2, and Mix (ST1 + ST2) ((a) summary of AP for models tested on different test sets; (b) mean AP of models after trained on ST1,ST2, and Mix (ST1 + ST2))




图 10 不同数据训练后,模型在不同测试集上的 AP 均值
Fig. 10 Average AP for model test results after trained on various datasets ((a) mean AP of models after trained on ST1,ST3, and Mix (ST1 + ST3); (b) mean AP of models after trained on ST2,ST3, and Mix(ST2 + ST3))

表 5 混合数据结果对比
Table 5 Comparison of hybrid data results

数据	混合类型	混合数据	评价指标变化趋势			图例来源
			AP ^{PU41}	AP ^{RU41}	AP ^{RU1000}	
ST1	强于自身	Mix(ST1+ST2)	↓	↑	↑	图 9(b)
		Mix(ST1+ST3)	↑	↑	↑	图 10(a)
ST2	强于自身	Mix(ST2+ST3)	↑	↑	↑	图 10(b)
	弱于自身	Mix(ST1+ST2)	↑	↓	↓	图 9(b)
ST3	弱于自身	Mix(ST1+ST3)	↑	↓	↓	图 10(a)
		Mix(ST2+ST3)	↑	↑	↑	图 10(b)

注:“↑、↓”分别表示相较于自身数据训练的模型,混合数据训练的模型在不同测试数据上 AP 均值的升、降趋势。

2.3.3 实验3:仿真数据域增广效果

采用仿真域数据增广样本量后训练并测试模型。其中, Aug(ST1+ST2)的样本量为 3 200,由 ST1

和 ST2 的训练、验证及测试集的全量数据对应叠加构成。 Aug(ST1 + ST2 + ST3)样本量为 4 800 ,其他数据集构成规则相同。实验结果详见表 6。

表 6 实验 3 的 AP 测试结果
Table 6 AP test results for experiment 3

		/%			
数据集	目标检测算法	AP ^{Self}	AP ^{PU41}	AP ^{RU41}	AP ^{RU1000}
Aug (ST1 + ST2)	Cascade R-CNN	66.70	19.80	8.00	7.70
	YOLOv10	72.70	19.50	15.60	14.90
	RT-DETR	61.60	43.30	39.70	28.50
	YOLOv12	76.90	22.20	36.20	28.50
Aug (ST1 + ST3)	Cascade R-CNN	69.50	42.00	22.20	18.50
	YOLOv10	77.30	43.00	28.70	18.60
	RT-DETR	76.00	54.50	44.90	37.60
	YOLOv12	80.40	55.80	34.30	26.40
Aug (ST2 + ST3)	Cascade R-CNN	67.80	38.20	25.30	19.60
	YOLOv10	72.10	46.60	30.50	28.90
	RT-DETR	71.90	53.90	49.40	39.00
	YOLOv12	76.90	57.20	31.70	33.00
Aug(ST1 + ST2 + ST3)	Cascade R-CNN	67.20	37.70	19.90	17.00
	YOLOv10	74.20	48.10	39.50	29.30
	RT-DETR	71.60	53.30	50.50	42.30
	YOLOv12	78.40	53.50	36.30	34.30

注:加粗字体表示各列最优结果。

表 6 中,模型在 PU41、RU41 和 RU1000 测试数据上的最高 AP 分别为 57. 20%、50. 50% 和 42. 30%。使用 Aug (ST1+ST2+ST3)数据训练的 RT-DETR 模型,在 RU41 和 RU1000 测试数据中均取得最优 AP 测试性能。结果表明,仅使用仿真图像数据训练已能够使模型在真实及实战场景中取得良好的检测结果。计算增广数据在不同测试集上的 AP 均值后,绘制图 11。表 6 和图 11 显示,实验结果与实验 1 和实验 2 具有一致性。使用性能更优的数据提升样本量时,模型泛化效果显著提升,目标域评价指标变化趋势与表 5 完全一致;采用性能较弱的数据增加样本量时,评价指标变化趋势同样存在不确定性。如表 7 所示,Aug(ST1 + ST3)在 RU1000 测试数据上 AP 均值呈下降趋势,其余为上升趋势。

2.4 实验分析

2.4.1 性能差异分析

为探究不同数据集及策略对模型预测结果的影响,从视觉感官差异、数据基本属性和数据特征 3 个维度分析。

1)分析视觉感官差异。视觉真实感上,自建仿真系统能实施定制化数据生产,但相较于 ST2 与 ST3,ST1 图像在主观视觉感受上失真感较强。实验中,视觉真实性对仿真数据跨域迁移表现为正向作用。

2)分析数据属性差异。统计数据集中图像平均尺寸和目标平均尺寸等基本信息于表 8 所示。

仿真域数据效果差异可能与目标尺寸和实例密度两方面相关。ST3 与目标域具备尺寸相似性和密度相似性,低密度大目标,ST2 次之,ST1 差距最大,高密度小目标。

目标尺寸上,ST3 目标平均尺寸显著大于 ST2 和 ST1,模型能捕捉到目标更多细节和特征,同时,大小接近目标域目标平均尺寸。ST1 和 ST2 目标尺寸较小,ST1 中目标平均尺寸仅为 55 × 40 像素,模型难以捕获到足够特征,且与目标域目标尺寸不适配。实例密度上,ST3 每幅图像平均实例数(1. 84)与目标域(PU41: 1. 80、RU41: 1. 29、RU1000: 1. 37)密度更接近,ST1 每幅图像平均实例数(7. 12),模型可




图 11 不同数据训练后,模型在不同测试集上的 AP 均值

Fig. 11 Mean AP of models on different test sets after trained on various datasets ((a) ST1, ST2, Aug(ST1 + ST2); (b) ST1, ST3, Aug(ST1 + ST3); (c) ST2, ST3, Aug(ST2 + ST3); (d) ST1, ST2, ST3, Aug(ST1 + ST2 + ST3))

表 7 增广数据结果对比

Table 7 Comparison of augmented data results

数据	增广类型	增广数据	评价指标变化趋势			图例来源
			AP ^{PU41}	AP ^{RU41}	AP ^{RU1000}	
ST2	弱于自身	Aug(ST1 + ST2)	↑	↑	↑	图 11(a)
ST3	弱于自身	Aug(ST1 + ST3)	↑	↑	↓	图 11(b)
		Aug(ST2 + ST3)	↑	↑	↑	图 11(c)

注:“↑”、“↓”分别表示相较自身数据训练的模型,混合数据训练的模型在不同测试数据上 AP 均值的升、降趋势。

能过度偏向密集场景,在目标稀疏的跨域数据上难以有效检测。

3) 分析不同仿真数据预训练的 ResNet 提取 ST1、ST2、ST3 (不含测试数据) 及 PU41、RU41 的图像特征,然后应用主成分分析 (principal component analysis, PCA) 和 t-分布随机邻域嵌入 (t-distributed stochastic neighbor embedding, t-SNE) 进行降维分析。图 12 中,目标域数据特征以橙色 (PU41) 和棕色 (RU41) 标注,并局部放大显示。

在两类方法的降维空间中,可视化均呈现出仿

真数据域与目标域存在相近性。ST2 和 ST3 仿真域聚簇更加显著,且分布逼近 PU41 和 RU41 目标域,有聚类倾向。相比之下,ST1 数据特征分布明显偏离目标域。同时,相较于 ST3,ST1 更偏向于 ST2。

通过上述推断,实验 2 和实验 3 中,采用较弱数据混合或增广时,不同组合呈现差异化表现,有其潜在成因。实验 2 中,ST3 混合弱于自身的数据时,ST2 更接近目标域,ST1 显著偏离目标域分布。Mix (ST2 + ST3) 呈现性能上升趋势, Mix (ST1 + ST3) 和 Mix (ST1 + ST2) 均表现为下降趋势。实验 3 结果显

表 8 不同数据集基本属性
Table 8 Basic attributes of different datasets

数据集	图像平均尺寸/像素	目标平均尺寸/像素	总计实例数	每幅图像平均实例数
ST1	1 280 × 1 024	55 × 40	11 394	7.12
ST2	1 436 × 1 077	84 × 73	3 664	2.29
ST3	1 432 × 836	212 × 131	2 951	1.84
PU41	898 × 648	401 × 252	74	1.80
RU41	1 210 × 787	262 × 251	53	1.29
RU1000	1 263 × 781	225 × 187	1 367	1.37




图 12 仿真域与目标域特征降维可视化
Fig. 12 Feature dimensionality reduction visualization of simulation domain and target domain
((a) visualization of PCA dimensionality reduction; (b) visualization of t-SNE dimensionality reduction)

示,当ST2、ST3都采用弱于自身的ST1数据增广时, Aug(ST1 + ST2)在跨域测试中AP均值均值为提升趋势, Aug(ST1 + ST3)在PU41上AP均值提升2.35%,在RU41上AP均值提升0.07%,在RU1000上AP均值降低2.73%。表明数据存在“分布相容性”边界,在边界内引入低性能辅助数据有增益,反之会导致性能退化。值得注意的是,该边界与数据特性强相关,通过量化计算得到的边界值不具备普适性。

综上所述,实验中,具备视觉真实性优势、数据基本属性与目标域适配、特征分布相近于目标域的仿真数据表现出更好的泛化性能。其次,具有强数据增益效应,混合或增广泛化能力比自身强的数据均能提升模型性能。弱数据混合条件性增益,若混合性能弱于自身但与目标域分布相近的数据,模型泛化能力仍可提升。此外,采用性能较弱的数据增加样本量时,在数据与目标域或自身分布相近条件下,模型性能可得到提高。

2.4.2 目标检测效果展示

图 13 展示了使用ST1.0训练的 RT-DETR 模型

在不同测试集上的检测效果(置信度阈值设为0.5)。除图 13(c)右上角及图 13(e)各漏检1个坦克目标外,模型在其余测试样本中均表现出优异的检测性能。

3 结 论

在构建的ST1.0数据集上,使用3类异构代表性目标检测算法训练,而后测试模型在真实及实战场景中的应用性能。首次验证了仿真数据在实战应用场景中的有效性。

研究发现:1)仿真数据与目标域适配性是跨域泛化取得良好效果的关键;2)不同仿真数据混合或增广策略对模型性能影响呈现规律性;3)跨域泛化中,模型性能具有阶梯式特征;4)模型架构存在跨域鲁棒性差异。

研究结果启示:尽管在实际场景中难以获取未知的实战场景图像,但通过仿真数据构建策略能在一定程度上缓解数据稀缺问题。具体实施时,应建立场景驱动逻辑,基于武器平台的任务场景,预判目




图13 RT-DETR模型在不同测试上检测结果

Fig. 13 Object detection results of RT-DETR model across multiple test sets ((a) all targets correctly detected in ST2; (b) all targets correctly detected in ST3; (c) one target undetected in PU41; (d) all targets correctly detected in PU41; (e) one target undetected in RU1000; (f) all targets correctly detected in RU1000)

标分布特征,通过提升仿真数据的视觉真实性与目标域的分布相似度,增强数据与实战场景的适配性。同时,可采用多域协同构建策略,尝试联合其他现有仿真数据域协同构建。在此基础上,借助模型在真实图像中的测试表现,预估其在实战场景中的泛化效果。

研究聚焦特定类型军事目标,对复杂作战场景的建模真实度和复杂性不足。数据组合策略未形成可直接应用的量化边界指标,缺乏同类型公开数据集以验证和推广实验结论。未来工作将拓展研究范畴,涵盖更多类军事目标及检测模型框架;深化技术融合,结合真实数据域和领域泛化技术探索多源域数据协同构建方法;优化数据策略,探索数据智能混合的安全决策边界;为军事目标检测提供可靠的数据构建方案,支撑智能作战系统的实战化应用。

参考文献(References)

Cai Z W and Vasconcelos N. 2021. Cascade R-CNN: high quality object detection and instance segmentation. IEEE Transactions on Pattern

Analysis and Machine Intelligence, 43(5): 1483-1498 [DOI: 10.1109/TPAMI.2019.2956516]

Gao X C, Zhao S C, Wu A M, Liang S Y and Wang L Y. 2025. Challenges and progress of object detection technology in open environments. Journal of Image and Graphics, 30(6): 1616-1637 (操晓春, 赵思成, 武阿明, 梁思源, 王立元. 2025. 目标检测技术在开放环境中的挑战与进展. 中国图象图形学报, 30(6): 1616-1637) [DOI: 10.11834/jig.250004]

Carion N, Massa F, Synnaeve G, Nicolas U, Alexander K and Sergey Z. 2020. End-to-end object detection with transformers//Proceedings of the 16th European Conference on Computer Vision. Glasgow, UK: Springer: 213-229 [DOI: 10.1007/978-3-030-58452-8_13]

Deng J, Wang D, Richard S, Li L J, Li K and Li F F. 2009. ImageNet: a large-scale hierarchical image database//Proceedings of 2009 IEEE Conference on Computer Vision and Pattern Recognition. Miami, USA: IEEE: 248-255 [DOI: 10.1109/CVPR. 2009. 5206848]

Everingham M, Van Gool L, Williams C K I, Winn J and Zisserman A. 2010. The PASCAL Visual Object Classes (VOC) challenge. International Journal of Computer Vision, 88(2): 303-338 [DOI: 10.1007/s11263-009-0275-4]

Gao C, Killeen B D, Hu Y C, Grupp R B, Taylor R H, Armand M, et

- al. 2023. Synthetic data accelerates the development of generalizable learning-based algorithms for X-ray image analysis. *Nature Machine Intelligence*, 5(3): 294-308 [DOI: 10.1038/s42256-023-00629-1]
- Hartnett G S, Menthe L, Léveillé J, Baveye D, Zhang L A, Gold D, et al. 2020. Operationally relevant artificial training for machine learning: improving the performance of automated target recognition systems [EB/OL]. [2025-11-10].
https://www.rand.org/pubs/research_reports/RRA683-1.html
- Hu X M, Huang T Y, Yu Y L, Ren J J, Xie W and Chen L. 2024. Decision technologies of simulation to reality for autonomous driving: a survey. *Journal of Image and Graphics*, 29(11): 3173-3194 (胡学敏, 黄婷玉, 余雅澜, 任佳佳, 谢微, 陈龙. 2024. 仿真到现实环境的自动驾驶决策技术综述. *中国图象图形学报*, 29(11): 3173-3194) [DOI: 10.11834/jig.230780]
- Kuznetsova A, Rom H, Alldrin N, Uijlings J, Krasin I, Pont-Tuset J, et al. 2020. The open images dataset V4: unified image classification, object detection, and visual relationship detection at scale. *International Journal of Computer Vision*, 128(7): 1956-1981 [DOI: 10.1007/S11263-020-01316-Z]
- Lin T Y, Maire M, Belongie S, Hays J, Perona P, Ramanan D, et al. 2014. Microsoft COCO: common objects in context//*Proceedings of the 13th European Conference on Computer Vision*. Zurich, Switzerland: Springer: 740-755 [DOI: 10.1007/978-3-319-10602-1_48]
- Luo S J, Liu Z G, Wang Y T and Liu J L. 2023. Modernized YOLOv4 with large kernels and AVOD2K dataset//*International Symposium on Computer Engineering and Intelligent Communications (ISCEIC 2022)*. Xi'an, China: SPIE: #124621R [DOI: 10.1117/12.2660794]
- Meng F J, Li Y Q, Shao F M, Yuan G H and Dai J Y. 2022. Visual-simulation region proposal and generative adversarial network based ground military target recognition. *Defence Technology*, 18(11): 2083-2096 [DOI: 10.1016/j.dt.2021.07.001]
- Meng F J, Wang X Q, Shao F M, Wang D and Hu X D. 2020. Fast-armored target detection based on multi-scale representation and guided anchor. *Defence Technology*, 16(4): 922-932 [DOI: 10.1016/j.dt.2019.11.009]
- Rudman J and Farhadi A. 2018. YOLOv3: an incremental improvement [EB/OL]. [2025-02-28]. <https://arxiv.org/pdf/1804.02767.pdf>
- Ren S Q, He K M, Girshick R 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]
- Shao S, Li Z M, Zhang T Y, Peng C, Yu G, Zhang X Y, et al. 2019. Objects365: a large-scale, high-quality dataset for object detection//*Proceedings of 2019 IEEE/CVF International Conference on Computer Vision (ICCV)*. Seoul, Korea (South): IEEE: 8429-8438 [DOI: 10.1109/ICCV.2019.00852]
- Shi C J, Zheng Y F, Ren B J, Kong F Y and Duan C Y. 2024. Single-domain generalized breast tumor detection in X-ray images. *Journal of Image and Graphics*, 29(3): 725-740 (史彩娟, 郑远帆, 任弼娟, 孔凡跃, 段昌钰. 2024. 单域泛化 X-ray 乳腺肿瘤检测. *中国图象图形学报*, 29(3): 725-740) [DOI: 10.11834/jig.230279]
- Truong T T H, Nguyen D V, Luong D H, Nguyen A T, Nguyen N S, Vu H K, et al. 2025. Impact of style transfer approaches on synthetic data for military camouflaged object detection//*Proceedings of the 13th International Symposium on Information and Communication Technology*. Danang, Vietnam: Springer: 27-41 [DOI: 10.1007/978-981-96-4288-5_3]
- Truong T T H, Tran T K, Nguyen C T, Phan T H H, Nguyen A T and Nguyen N S. 2024. An approach of generating synthetic data in military camouflaged object detection//*Proceedings of 2024 International Conference on Multimedia Analysis and Pattern Recognition (MAPR)*. Danang, Vietnam: IEEE: 1-6 [DOI: 10.1109/MAPR63514.2024.10660900]
- Tian Y J, Ye Q X and Doermann D. 2025. YOLOv12: attention-centric real-time object detectors [EB/OL]. [2025-02-28].
<https://arxiv.org/pdf/2502.12524.pdf>
- Tian Z H, Guo J H, Sun S S and Shen Q. 2022. Small objects of on-board images detection algorithm based on improved Yolo v3. *Fire Control and Command Control*, 47(4): 34-42 (田宗浩, 郭佳晖, 孙姗姗, 申倩. 2022. 基于改进 Yolo v3 的弹载图像弱小目标检测算法. *火力与指挥控制*, 47(4): 34-42) [DOI: 10.3969/j.issn.1002-0640.2022.04.006]
- Wang A, Chen H, Liu L H, Chen K, Lin A J, Han J G, et al. 2024. YOLOv10: real-time end-to-end object detection [EB/OL]. [2025-02-28]. <https://arxiv.org/pdf/2405.14458.pdf>
- Wang S B, Zhang C, Su D and Ji R J. 2022. A target detecting algorithm for spinning projectile based on improved YOLOv3 and KCF. *Acta Armamentarii*, 43(5): 1032-1045 (王少博, 张成, 苏迪, 冀瑞静. 2022. 基于改进 YOLOv3 和核相关滤波算法的旋转弹目标探测算法. *兵工学报*, 43(5): 1032-1045) [DOI: 10.12382/bgxb.2021.0283]
- Xue Z F. 2021. Generation and Optimization of Synthetic Dataset and Its Application in Rock Analysis. Hangzhou: Zhejiang University (薛振锋. 2021. 合成数据集的生成与优化方法及其在岩渣分析中的应用. 杭州: 浙江大学) [DOI: 10.27461/d.cnki.gzjdx.2021.003294]
- Zeng B H, Gao S, Xu Y L, Zhang Z X, Li F and Wang C H. 2024. Detection of military targets on ground and sea by UAVs with low-altitude oblique perspective. *Remote Sensing*, 16(7): #1288 [DOI: 10.3390/rs16071288]
- Zhang B, Xu F, Li X T and Zhao Y D. 2021. Research on the improved YOLOv3 algorithm for military cluster targets. *Fire Control and Command Control*, 46(5): 81-85 (张奔, 徐锋, 李晓婷, 赵彦东.

2021. 针对军事集群目标的YOLOv3改进算法研究. 火力与指挥控制, 46(5): 81-85 [DOI: 10.3969/j.issn.1002-0640.2021.05.015]

Zhao Y A, Lyu W Y, Xu S L, Wei J M, Wang G Z, Dang Q Q, et al. 2024. DETRs beat YOLOs on real-time object detection//Proceedings of 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition (2024). Seattle, USA: IEEE: 16965-16974 [DOI: 10.1109/CVPR52733.2024.01605]

Zhu K. 2019. Research on Armored Vehicle Recognition Technology Based on Deep Learning. Nanjing: Nanjing University of Science and Technology (朱凯. 2019. 基于深度学习的装甲车辆识别技术研究. 南京: 南京理工大学) [DOI: 10.27241/d.cnki.gnjgu.2019.000348]

作者简介

吴正龙,男,教授,主要研究方向为弹药毁伤效能分析、火力毁伤评估、弹药作战运用、火控理论与技术。

E-mail: zhenglongwu2023@163.com

连细南,通信作者,男,博士研究生,主要研究方向为目标检测、作战数据构建和数据域适应。

E-mail: lianxinan18@163.com

赵忠实,男,讲师,主要研究方向为火控理论与技术和大语言模型。E-mail: 171504994@qq.com

孟奇,男,博士研究生,主要研究方向为智能武器系统技术和大语言模型。E-mail: 171504994@qq.com