光电技术及应用

DOI：10.16818/j.issn1001－5868.2023061401

基于GSR-YOLOv7的探地雷达回波图像识别的研究

钟运杰[1]，李　康[1]，莫思特[1*]，李碧雄[2]
（四川大学 1. 电气工程学院；2. 水利水电学院，成都 610065）

摘　要： 针对探地雷达回波图像特征不突出，工作人员现场解译时间长，准确率不高的问题，提出一种基于YOLOv7改进的回波图像识别方法GSR-YOLOv7。首先使用GhostConv替换YOLOv7卷积层的卷积核以减小参数量；引入SimAM注意力机制提高特征学习能力；通过对感受野模块RFB卷积核的复用，增大感受野；同时引入改进EIoU损失函数提高模型分类能力和回归精度。基于道路回波图像数据集的实验结果表明，改进后的模型MAP_{50}达到了97.57%，$MAP_{50:95}$达到了73.13%，较YOLOv7分别提高2.13%和8.46%，模型大小减小了35%。所提出的GSR-YOLOv7模型对于回波目标的检测效果较好，适用于移动端系统，对于体积小、算力低的平台具有较大应用价值。

关键词： YOLOv7；探地雷达；SimAM；Ghost；EIoU；目标检测
中图分类号： TN957.52；P631　**文章编号：** 1001－5868(2023)05－0767－08

Research on GPR Echo Image Recognition Based on GSR-YOLOv7

ZHONG Yunjie[1], LI Kang[1], MO Site[1], LI Bixiong[2]
(1. School of Electrical Engineering; 2. College of Water Resources and Hydropower, Sichuan University, Chengdu 610065, CHN)

Abstract: In order to address the problems of indistinct features, time-consuming field interpretation, and low accuracy in Ground Penetrating Radar (GPR) echo image recognition, an improved method called GSR-YOLOv7 based on YOLOv7 is proposed in this study. First, GhostConv was used to replace the convolutional kernels in the YOLOv7 convolutional layers, thus reducing the number of parameters. Second, the SimAM attention mechanism was introduced to improve the feature learning capabilities. Third, the reuse of the receptive field block (RFB) convolutional kernel was implemented to enlarge the receptive field. Finally, an improved EIoU loss function was employed to improve model classification and regression accuracy. Experimental results on a dataset of road echo images demonstrate the effectiveness of the proposed approach. The GSR-YOLOv7 model achieves a MAP_{50} score of 97.57% and a $MAP_{50:95}$ score of 73.13%, showing improvements of 2.13% and 8.46%, respectively, over YOLOv7. In addition, the model size is reduced by 35%. The GSR-YOLOv7 model exhibits excellent detection performance for echo targets and is suitable for use on mobile systems. It has significant value for platforms with limited processing power and small form factors.

Key words: YOLOv7; GPR; SimAM; Ghost; EIoU; object detection

收稿日期：2023－06－14.
*通信作者：莫思特　**E-mail：**851397693@qq.com

0 引言

探地雷达(GPR)是一种无损检测方法,利用电磁波的传输特性来探测地下的结构和物质,目前广泛应用于道路病害检测,地下管线、隧道空洞探测等[1-5]。地下目标检测是探地雷达应用的典型案例之一,它可以有效地探测出地下结构的空洞和钢筋等目标[6-7]。然而,目前该技术大多数研究还停留在延时估计与辨识层位方面[8-10]。由于 GPR 在探测过程中产生的回波图像数据量很大,因此需要人工对数据进行解释和分析,这个过程通常需要耗费大量的时间和精力。

目前关于机器学习领域的研究发展迅速,基于深度学习的目标检测算法在探地雷达回波图像识别的研究成为热点。马王鹏等[11]使用 YOLOv1 对探地雷达图像异常进行了识别,测试了深度学习方法的有效性,但其速度慢、准确率较低。Hou 等[12]利用改进后的 R-CNN 识别地下目标,在一定程度上提高了准确率但仍存在准确率较低的问题。Kafedziski 等[13]使用 Fast R-CNN(Fast Region-based CNN)从探地雷达数据中探测分类地雷[14],但该方法具有一定的局限性,主要应用于地雷探测领域。赵迪等[15]提出 Grad-CAM 与 CNN 结合的方法,能够有效检测公路地下目标。

当前的目标检测算法根据是否提前生成候选区域可以分为单阶段和双阶段目标算法。以 Fast R-CNN 为代表的双阶段目标检测算法尽管准确度较高,但检测过程十分耗时,不适用于移动端部署。相比之下,YOLO 系列目标检测算法是典型的单阶段算法,具有快速的检测速度,但准确率稍低。YOLOv7[16]是目前YOLO系列较优的算法模型,YOLOv7 采用高效聚合网络(ELAN)来加强网络提取特征的能力,并对 Backbone 的最后阶段进行了改进,优化了 SPP 模块以避免图像失真等问题。YOLOv7 算法虽然准确度有进一步的提高,但模型参数量较大,结构比较复杂,不太适用于低算力移动端的部署。

本文提出的 GSR-YOLOv7 模型,在 YOLOv7 基础上进行了改进:(1)使用 Ghost 卷积[17]替换常规卷积,减少模型参数量和计算量,更适应于小体积低功耗低算力运算平台;(2)引入 SimAM[18]机制,进一步细化特征;(3)改进 RFB 模块[19-20],提高了在浅层中提取高级语义特征的能力;(4)使用改进 EIoU[21]损失函数替换原有损失函数,提高模型收敛能力,加强对小目标的检测,提高模型准确率。

1 YOLOv7 算法介绍及改进

1.1 YOLOv7

YOLOv7 相较于以往的 YOLO 系列,在准确率和检测速度方面表现更优秀。其网络结构主要由 Input,Backbone 和 Head 三部分组成。Input 负责对输入数据进行预处理,将其送入主干网络 Backbone。Backbone 由多个卷积层、ELAN(Exponential Linear Attention Network)和 MP(Max Pooling)等模块组成,用于提取处理后的图像数据的特征。Head 部分负责特征的融合处理,以及对目标位置和类别的预测。

1.2 YOLOv7 算法改进

本研究对 YOLOv7 网络结构模型分别从四个方面进行了优化和改进,更适应回波图像数据集的目标检测工作,改进后的网络结构图如图 1 所示。

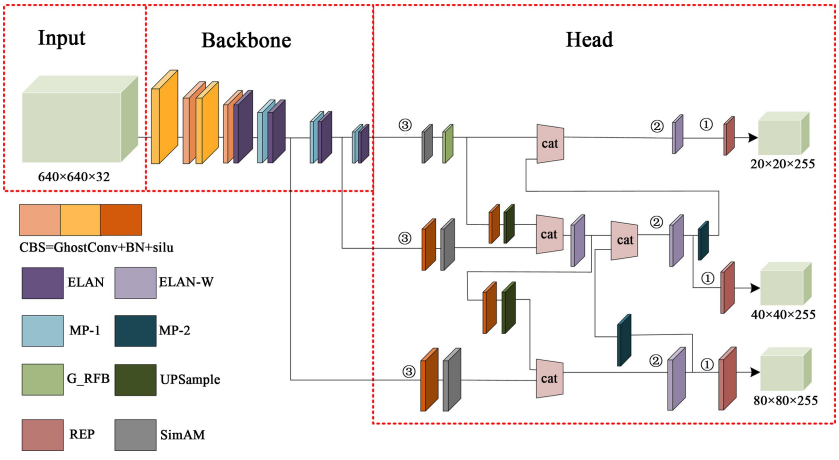

图 1 GSR-YOLOv7 网络结构图

1.2.1　Ghost 卷积

为了使模型更轻量化，本研究采用了 Ghost 卷积核来替代常规卷积核，以减小参数量。Han 等[17]利用特征图的冗余性，通过应用一系列成本低廉的线性变换，提出了一种更轻量级的 Ghost 卷积模块。图 2 为 Ghost 模块，对于输入特征层，首先使用标准卷积生成一部分真实特征层；然后使用深度可分离卷积和常数变换对每个特征层进行线性处理，得到另一部分特征层，并将这两部分特征层缝合在一起，形成 Ghost 模块的输出特征层。通过这种方式，Ghost 模块能够以更低的计算成本生成额外的特征层，从而在减小参数量的同时保持了模型的表达能力。

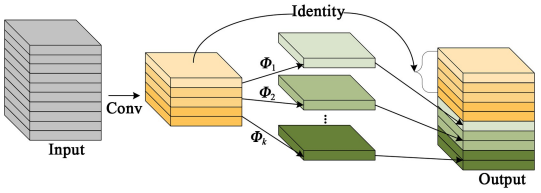

图 2　Ghost 模块结构图

假设 Ghost 模块的输入特征图大小为 $H\times W$，通道数为 C_{in}，输出的特征图大小为 $H'\times W'$，通道数为 $m\times s$，卷积核大小为 $k\times k$，常规卷积核的计算量为：

$$(m\times s)\times H'\times W'\times C_{in}\times k\times k \tag{1}$$

假设 Ghost 卷积的第一部分生成 m 个特征图，每个特征图生成$(s-1)$个新的特征图，卷积的第二部分共得到$m\times(s-1)$个特征图，卷积核大小相同，则 Ghost 卷积的第一部分的计算量为：

$$m\times H'\times W'\times C_{in}\times k\times k \tag{2}$$

第二部分的计算量为：

$$m\times(s-1)\times H'\times W'\times k\times k \tag{3}$$

则 Ghost 模块总的计算量为：

$$m\times H'\times W'\times C_{in}\times k\times k+m\times(s-1)\times H'\times W'\times k\times k \tag{4}$$

当输出特征图的大小和通道的数量相同时，常规卷积和 Ghost 卷积的计算量之比为：

$$\frac{(m\times s)\times H'\times W'\times C_{in}\times k\times k}{m\times H'\times W'\times C_{in}\times k\times k+m\times(s-1)\times H'\times W'\times k\times k}=\frac{C_{in}\times s}{C_{in}+s-1} \tag{5}$$

综上所述，当 $C_{in}\gg s$ 时，$\frac{C_{in}\times s}{C_{in}+s-1}\approx s$。经过以上计算可以看出，使用 Ghost 卷积可以减少卷积过程的计算量，因此对卷积过程的硬件资源要求和 GPU 使用率较低。

1.2.2　引入 SimAM 机制

当前阶段的注意力模块主要继承到某个块中，以提高前一层的输出。由于这种方法沿通道或空间维度操作，因此只能生成一维或二维权重，并在通道或空间维度上被同等对待。

a)通道注意力：1D 注意力，区别对待不同通道，平等对待所有位置；

b)空间注意力：2D 注意力，区别对待不同位置，平等对待所有通道。

这种特征会使它们缺乏辨别网络线索的能力。因此三维权重优于传统的一维和二维加权注意力，可以进一步细化特征。与现有的通道和空间注意力模块相比，SimAM 模块最大的区别在于，它不需要向原始网络添加参数，而是推断一层中特征图的三维注意力权重。SimAM 基于一些神经学理论，提出优化能量函数并推导出快速的解析解，即将函数应用在计算注意力机制的权值上。SimAM 代码量小、速度快、可移植性强，并且当前阶段的注意力模块主要继承到某个块中，以提高前一层的输出。由于这种方法沿通道或空间维度操作，因此只能生成一维或二维权重，并在通道或空间维度上被同等对待。

c)通道注意力：1D 注意力，区别对待不同通道，平等对待所有位置；

d)空间注意力：2D 注意力，区别对待不同位置，平等对待所有通道。

这种特征会使它们缺乏辨别网络线索的能力。因此三维权重优于传统的一维和二维加权注意力，可以进一步细化特征。与现有的通道和空间注意力模块相比，SimAM 模块最大的区别在于，它不需要向原始网络添加参数，而是推断一层中特征图的三维注意力权重。SimAM 基于一些神经学理论，提出优化能量函数并推导出快速的解析解，即将函数应用在计算注意力机制的权值上，使网络能够更好地区分重要的特征并抑制不重要的特征。SimAM 代码量小、速度快、可移植性强，并且移植后的卷积网络特征表达能力显著提高。不同注意力机制的区别如下图 3 所示。

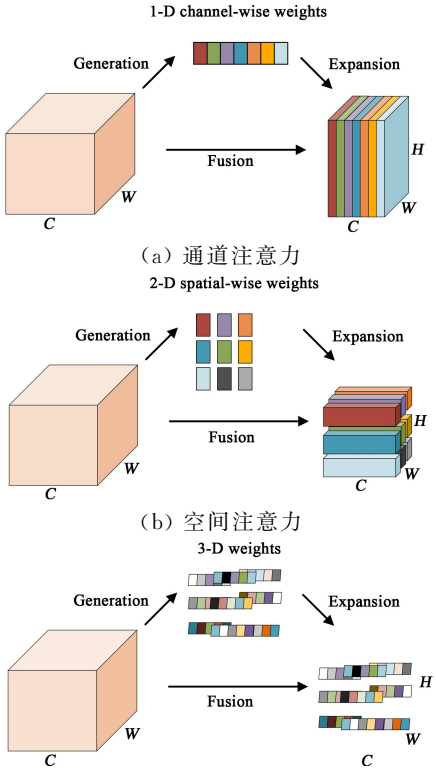

(a) 通道注意力

(b) 空间注意力

(c) 全三维注意力权重

图 3 不同注意力机制

1.2.3 改进 RFB 模块

本文对 RFB 进行了改进，以便于减少模型的参数量和运算量。将 RFB 分支 3 的 5×5 卷积核替换为两个 3×3 的卷积核，并让 3×3 和 1×1 的卷积核进行多路复用，因为 G_RFB 的输入输出通道数相同，shortcut可以选择直接相连，相对于RFB可训练参数减少了 47%。另外为了增强模型的非线性表达能力，G_RFB 的多分支结构已经通过不同的视觉大小获取信息，故 shortcut 选择直接相连，使信息传输更流畅，丰富了 G_RFB 模块中信息的多样性，进一步提高了模型在浅层中提取高级语义特征的能力，明显提升了模型的检测性能。改进后的 G_RFB 模块如图 4 所示。

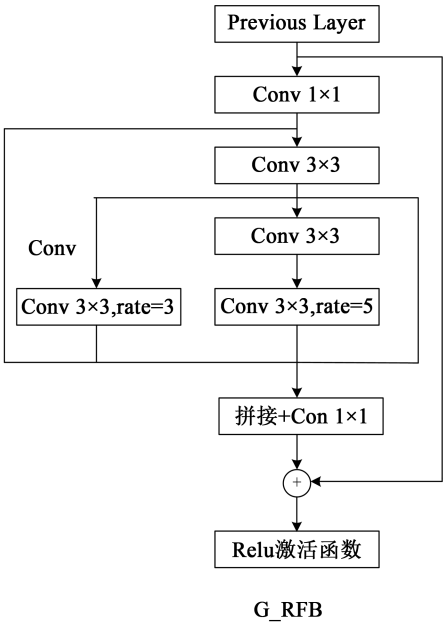

图 4 G_RFB 模块

1.2.4 改进损失函数

YOLOv7 模型中损失函数如下式所示：

$$L = L_{\mathrm{CIoU}} + L_{\mathrm{conf}} + L_{\mathrm{cls}} \tag{6}$$

式中，L_{CIoU} 为位置损失，L_{conf} 为置信度损失，L_{cls} 为分类损失。L_{conf} 和 L_{cls} 都是采用 BCEWithLogitsLoss 函数进行计算，而位置损失采用的是 CIoU[22] 损失进行计算。但 CIoU 损失函数对目标与预测框不匹配的情况欠缺考虑，从而导致收敛慢、不稳定的现象发生。

因此，本文使用改进后的 EIoU 损失函数替代 CIoU 损失函数作为回波图像的位置损失函数。EIoU 损失函数计算公式为：

$$L_{\mathrm{EIoU}}(B,B^{gt}) = L_{IoU} + L_{\mathrm{dis}} + L_{\mathrm{asp}} = 1 - IoU + \frac{\rho^2(b,b^{gt})}{c^2} + \frac{\rho^2(w,w^{gt})}{c_{\mathrm{w}}^2} + \frac{\rho^2(h,h^{gt})}{c_{\mathrm{h}}^2} \tag{7}$$

式中包含重叠损失、中心距离损失及宽高损失三个部分，算法在 CIoU 基础上将纵横比拆开，考虑宽高损失，使目标框与预测框之间的宽度和高度差最小，因此即使预测边界框和真实边界框大小相差较大时，EIoU 的值也可以保持稳定并加速收敛。其中，IoU 为预测框和目标框相交面积与合并面积的比值。如图 5 所示，B，B^{gt} 表示预测框和真实框，b，b^{gt} 为预测框和真实框中心点坐标，$\rho(b,b^{gt})$ 表示两者之间的欧氏距离，w，w^{gt} 和 h，h^{gt} 为预测框和真实框的宽和高，c 为能够同时包括预测框和真实框的最小外接矩形的对角线长度，c_{w}，c_{h} 是能覆盖两个框的最小外接框的宽度和高度。

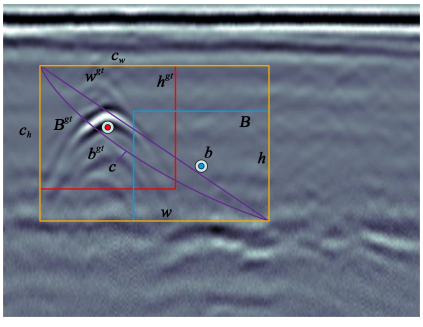

图 5 EIoU 示意图

为了提高对目标的检测能力，在位置回归损失部分增加一个惩罚项$(2-w\times h)$，当真实框较小时，其惩罚项就比较大，可以加强对小目标的检测，提高准确率。

$$L_{\text{coord}}=\sum_{i=0}^{s^2}\sum_{j=0}^{k}(2-w_i\times h_i)\times L_{\text{EIoU}} \tag{8}$$

2　实验结果分析

2.1　实验环境

本文提出的网络模型均用公开的人工神经网络库并在 Tensor Flow 框架上实现，实验环境配置为 GPU：NVIDIA GeForce RTX 3060Ti，Intel（R）Core（TM）i7-8700K CPU@3.70 GHz，16 G 运行内存。

2.2　实验数据集

本研究中使用的探地雷达回波图像数据来源于某道路地下目标数据，根据相关道路病害探测的工程经验可知，道路地下目标主要包括管线（pipe）和裂缝病害（crack）两种[15]。原始数据共有 600 张图像，分辨率为 1 654×826。为了针对本文的目标检测任务，将原始数据中包含目标的区域裁剪为 416×416 大小的图像。考虑到真实场景环境的多样性，对部分数据集进行了增强操作，包括随机旋转、加入高斯噪声、椒盐噪声以及亮度增强，最终获得数据集共 4 978 张，按照 8∶2 的比例划分训练集和测试集。基于管线和裂缝病害的回波特征，绘制包含回波特征占比较大的标签框，以降低模型训练过程的复杂性。标签制作如图 6 所示。

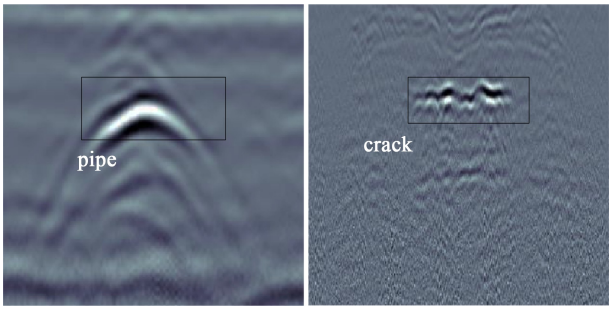

图 6　标签制作

2.3　模型训练参数设置及评价指标

训练参数中，将批大小（batch_size）设置为 16，即每次训练送入网络的图片数量为 16 张。初始学习率（LR）设置为 0.01，优化器选择了 Adam。训练的总轮数（epoch）设定为 140。训练过程中采用了学习率预热的方法，即学习率首先以线性增加的方式进行调整，在训练批次达到 5 时，学习率开始以余弦函数下降的方式变化。这种设置使得在训练初期，学习率较大，可以加快模型的收敛速度并趋于稳定；而在后期，学习率逐渐减小，有助于模型在接近最优点时更好地收敛。图 7 展示了学习率变化的曲线。改进后的模型损失函数下降曲线如图 8 所示，最终的损失函数稳定在 0.02 左右。

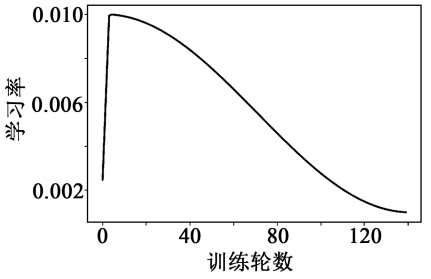

图 7　学习率曲线

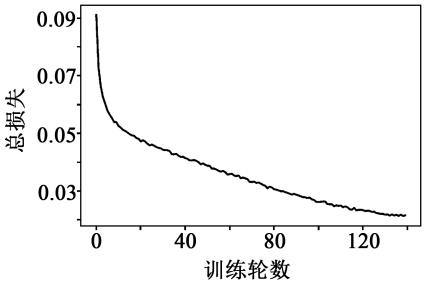

图 8　损失曲线

本文模型评价指标采用检测精度 MAP_{50} 和 $MAP_{50:95}$、模型大小、浮点运算量（GFLOPs），以及检测速度（FPS）。MAP_{50} 为当 $IoU=0.50$ 时两类的平均检测精度，$MAP_{50:95}$ 为 IoU 取值从 0.50 到 0.95，间隔 0.05 时两类的平均检测精度。

2.4　消融实验

实验结果如表 1 所示，实验编号 1 为 YOLOv7 原始模型，实验编号 2 在原始 YOLOv7 中使用 Ghost 卷积替换常规卷积，对比实验 1，模型大小减少了约 30%，GFLOPs 减少了约 40%，FPS 提高了约 14%，然而模型精度 MAP_{50} 和 $MAP_{50:95}$ 分别下降了 1.7%和 6.25%，这表明使用 GhostConv 有效减少了模型的参数量和计算量，但对模型精度产生了一定的影响。实验 3 在实验 2 模型的基础上添加了改进的 G_RFB 模块，模型精度 MAP_{50} 和 $MAP_{50:95}$ 提升超过了 3 个百分点，同时模型大小和 GFLOPs 进一步减少，但 FPS 有所下降。这说明添加 G_RFB 模块对模型精度、模型大小和 GFLOPs 的提升效果是明显的。实验 4 在实验 3 的基础上，

将边界框损失函数替换为改进的 EIoU，模型精度得到进一步提升，验证了引入改进的 EIoU 损失函数的有效性；实验 5 在实验 4 的基础上，引入了 SimAM 注意力机制，MAP_{50} 和 $MAP_{50:95}$ 均有所提升，GFLOPs 也有所下降。通过表 1 数据对比，验证了本文算法的改进能够有效提升对探地雷达回波目标的检测效果。改进网络的部分检测结果如图 9 所示。

表 1 消融实验结果

方法编号	模型	MAP_{50}/%	$MAP_{50:95}$/%	模型大小/MB	GFLOPs	FPS
1	YOLOv7	95.44	64.67	71.3	103.2	70
2	1+Ghost	93.82	60.63	50.4	62.4	80
3	2+G_RFB	96.86	66.93	46.5	58.1	73
4	3+EIoU	96.89	70.94	46.5	58.1	73
5	4+SimAM	97.57	73.13	46.5	57.7	73

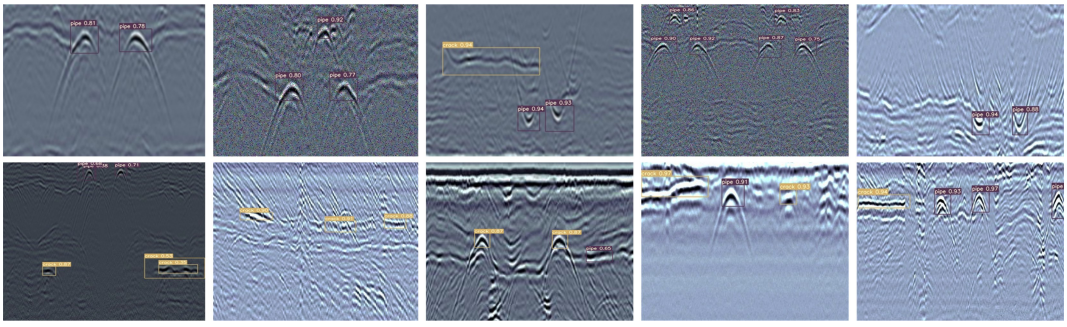

图 9 部分回波目标检测结果

2.5 SimAM 位置验证

为了验证 SimAM 注意力模块在模型网络中的位置对性能的影响，在上述实验 5 的基础上进行了研究。

表 2 SimAM 不同位置

实验编号	MAP_{50}/%	$MAP_{50:95}$/%	模型大小/MB	GFLOPs
1	97.11	69.79	46.5	57.7
2	97.21	71.23	46.5	57.7
3	96.90	70.97	46.5	57.7
4	97.57	73.13	46.5	57.7

实验编号 1 将 SimAM 插入到 Rep 模块后面（如图 1 中的位置①）。实验编号 2 将 SimAM 插入在 Rep 模块之前（如图 1 中的位置②）。实验编号 3 将 SimAM 插入在 Head 接口处（如图 1 中的位置③）。实验编号 4 则是本文所采用的网络框架。根据上述验证实验结果知，插入位置对模型大小和 GFLOPs 没有影响，则本文网络选择具有最高 MAP_{50} 和 $MAP_{50:95}$ 的位置插入 SimAM 模块。

2.6 模型对比分析

为验证本文提出的模型在探地雷达回波目标检测方面的性能，将 GSR-YOLOv7 与目前主流的目标检测算法进行了比较，包括 YOLOv3，YOLOv5l，YOLOv7，Faster R-CNN 和 SSD(VGG16)。在相同的实验配置下，比较结果如表 3 所示。

从表 3 可以看出，本文提出的模型在平均精度方面均优于 YOLOv3，YOLOv5l，YOLOv7，Faster R-CNN 和 SSD(VGG16)算法模型，并且模型较小。可见，本文提出的模型具有低浮点运算量和高准确率的特点，适用于部署在算力有限、体积较小的探地雷达移动端设备上。

表 3 不同模型对比实验结果

模型	MAP_{50}/%	$MAP_{50:95}$/%	模型大小/MB	GFLOPs
YOLOv3	94.31	55.24	234.0	65.7
YOLOv5l	95.49	63.63	89.3	109.0
YOLOv7	95.44	64.67	71.3	103.2
Faster R-CNN	94.98	58.19	108.0	63.0
SSD(VGG16)	92.13	54.73	90.7	57.0
本文模型	97.57	73.13	46.5	57.7

2.7 移动端部署

TensorFlow Lite 是可以在 Android，ios 等设备端运行的 TensorFlow 模型开源深度学习框架。开发者可在此框架上进一步开发出 APP，将算法移植到移动端进行部署。

首先将本网络模型训练的 GSR-YOLOv7. pt 文件转换为 tflite 格式。然后将搭建好的 Android 探地雷达回波目标识别模型部署到 Meizu17 pro 手机。探地雷达回波目标识别算法在 Meizu17 pro 手机测试的结果如图 10 所示。从图中可以知道，本文算法部署到移动端后可以正确识别到回波目标，并且一张回波图像在 Meizu17 pro 的 CPU，GPU 上检测时间约为 205 和 56 ms，检测速度约为 5 和 20 FPS，表明模型可以达到在移动端实时检测识别的效果，同时辅助现场工作人员，减少识别时间和错误率。

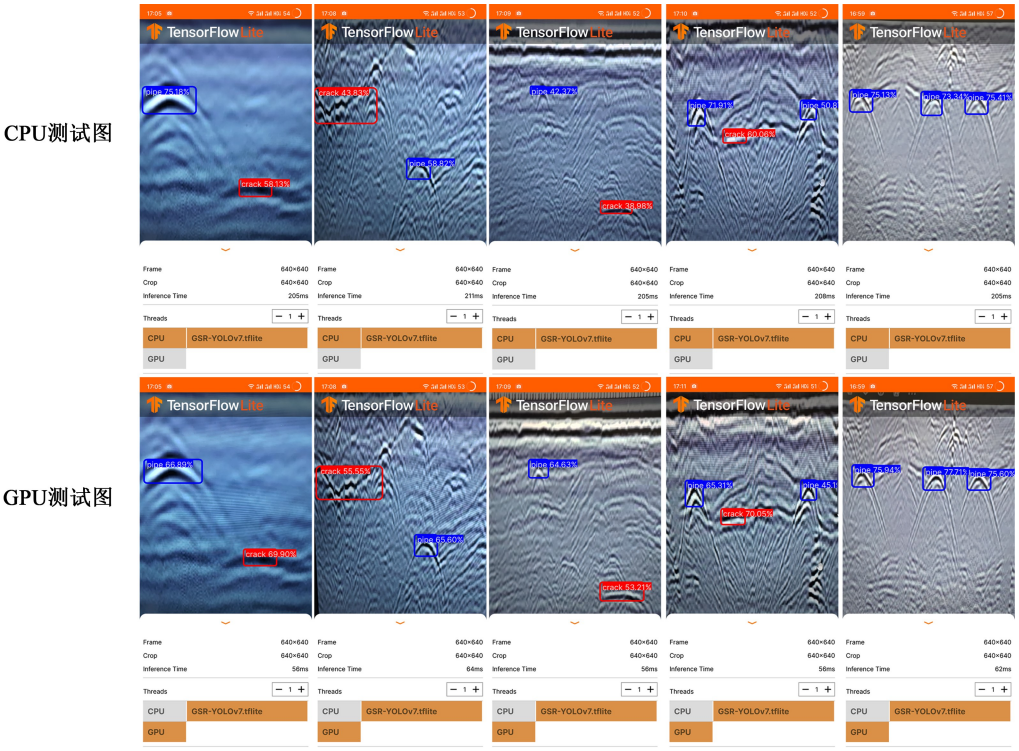

图 10　移动端回波目标测试结果

3　总结

本文针对探地雷达回波目标识别的问题，在 YOLOv7 的基础上使用 GhostConv 替换掉常规卷积，并引入 SimAM 注意力机制、改进后的 RFB 模块和改进后的 EIoU 边界框损失函数，提出一种适用于探地雷达回波的目标检测算法 GSR-YOLOv7。实验结果表明，GSR-YOLOv7 的 MAP_{50} 达到了 97.57%，$MAP_{50:95}$ 达到了 73.13%，模型大小及 GFLOPs 比 YOLOv7 更小。GSR-YOLOv7 的检测精度和检测速度均优于现有部分公开的目标检测算法，并且在 Meizu17 pro 移动端图像的检测速度约为 20 FPS，证明了本文提出算法的检测精度高，模型和 GFLOPs 都比较小，适合算力有限、体积较小的移动端设备上进行部署。

参考文献：

[1] Stryk J, Matula R, Pospisil K, et al. Comparative measurements of ground penetrating radars used for road and bridge diagnostics in the Czech Republic and France[J]. Construction and Building Materials, 2017, 154: 1199-1206.

[2] 杨　军，李　婷，袁忠明，等. 管线模型的探地雷达物理模拟实验[J]. 地球物理学进展，2023，38(2)：912-927.
Yang Jun, Li Ting, Yuan Zhongming, et al. Ground penetrating radar physical simulation experiment of pipeline model[J]. Progress in Geophysics, 2023, 38(2): 912-927.

[3] 朱兆荣，赵守全，秦　欣，等. 探地雷达隧道衬砌空洞探测效果模型和现场实体试验研究[J]. 岩土工程学报，2022，44(S1)：132-137.
Zhu Zhaorong, Zhao Shouquan, Qin Xin, et al. Model and field tests on detection effects of tunnel lining cavity by GPR[J]. Chinese J. of Geotechnical Engineering, 2022, 44(S1): 132-137.

[4] Liu H, Huang Z G, Yue Y P, et al. Characteristics analysis of ground penetrating radar signals for ground water pipe leakage environment[J]. J. of Electron. & Information Technol., 2022, 44(4): 1257-1264.

[5] Harseno R W, Lee S J, Kee S H, et al. Evaluation of air-cavities behind concrete tunnel linings using GPR measurements[J]. Remote Sensing, 2022, 14(21): 5348.

[6] Joshaghani A, Shokrabadi M. Ground penetrating radar (GPR) applications in concrete pavements[J]. Inter. J. of Pavement Engineering, 2022, 23(13): 4504-4531.

[7] Amran T S T, Ismail M P, Ismail M A, et al. GPR application on construction foundation study[C]// IOP Conf. Series: Materials Science and Engineering, 2017: 012089.

[8] Pan J J, Bastard C L, Wang Y D, et al. Time-delay estimation using ground-penetrating radar with a support vector regression-based linear prediction method[J]. IEEE Trans. on Geoscience and Remote Sensing, 2018, 56(5): 2833-2840.

[9] 曹　棋，宋效东，杨顺华，等. 基于探地雷达的典型红壤区网纹红土层识别[J]. 土壤学报，2019，56(4)：813-824.

Cao Qi, Song Xiaodong, Yang Shunhua, et al. Identification of plinthitic red earth layers in red soil regions typical of south china with ground penetrating radar[J]. Acta Pedologica Sinica, 2019, 56(4): 813-824.

[10] Thomas S B, Roy L P. Signal processing for coal layer thickness estimation using high-resolution time delay estimation methods[J]. IET Science Measurement & Technol., 2017, 11(8): 1022-1031.

[11] 马王鹏，王晓东，刘 冬. 探地雷达图像异常识别中 YOLO 目标检测算法的研究[J]. 测绘通报，2019(S1)：72-76.
Ma Wangpeng, Wang Xiaodong, Liu Dong. YOLO target detection algorithm research in GPR anomaly image recognition [J]. Bulletin of Surveying and Mapping, 2019(S1): 72-76.

[12] Hou F F, Lei W T, Li S, et al. Deep learning-based subsurface target detection from GPR scans[J]. IEEE Sensors J., 2021, 21(6): 8161-8171.

[13] Lin T Y, Dollár P, Girshick R, et al. Feature pyramid networks for object detection[C]// 2017 IEEE Conf. on Computer Vision and Pattern Recognition, 2017: 936-944.

[14] Kafedziski V, Pecov S, Tanevski D. Detection and classification of land mines from ground penetrating radar data using faster R-CNN [C]// 2018 26th Telecommunications Forum (TELFOR), 2018: 1-4.

[15] 赵 迪，叶盛波，周 斌. 基于 Grad-CAM 的探地雷达公路地下目标检测算法[J]. 电子测量技术，2020，43(10)：113-118.
Zhao Di, Ye Shengbo, Zhou Bin. Ground penetrating radar anomaly detection based on convolution Grad-CAM [J]. Electron. Measur. Technol., 2020, 43(10): 113-118.

[16] 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]// 2023 IEEE/CVF Conf. on Computer Vision and Pattern Recognition (CVPR), 2023: 17-24.

[17] Han K, Wang Y, Tian Q, et al. GhostNet: More features from cheap operations[C]// 2020 IEEE/CVF Conf. on Computer Vision and Pattern Recognition (CVPR), 2020: 1577-1586.

[18] Yang L, Zhang R Y, Li L, et al. SimAM: A simple, parameter-free attention module for convolutional neural networks[C]// Proc. of the 38th Inter. Conf. on Machine Learning, 2021: 11863-11874.

[19] Liu S, Huang D, Wang Y. Receptive field block net for accurate and fast object detection[C]// Computer Vision-ECCV 2018, 2018: 404-419.

[20] 刘 星，莫思特，张 江，等. 轻量化模型的 PeleeNet$_{yolov3}$ 地表裂缝识别[J]. 哈尔滨工业大学学报，2023，55(4)：81-89.
Liu Xing, Mo Site, Zhang Jiang, et al. PeleeNet$_{yolov3}$ surface crack identification with lightweight model[J]. J. of Harbin Institute of Technol., 2023, 55(4): 81-89.

[21] Zhang Y F, Ren W, Zhang Z, et al. Focal and efficient IOU loss for accurate bounding box regression[J/OL]. ArXiv, 2021, 2101: 08158[2023-06-14]. http://arxiv.org/abs/2101.08158.

[22] Zheng Z, Wang P, Liu W, et al. Distance-IoU Loss: Faster and better learning for bounding box regression[J/OL]. ArXiv, 2019, 1911: 08287[2023-06-14]. http://arxiv.org/abs/1911.0828701.

作者简介：

钟运杰(1996—)，男，控制科学与工程专业硕士研究生，研究方向为图像识别和目标检测；

莫斯特(1973—)，男，副教授/研究生导师，研究方向包括人工智能、仪器科学、数字图像处理，以及地质灾害监测等。