光电智能识别与感知

DOI：10.16818/j.issn1001－5868.20260105001

基于深度学习的探地雷达地下目标类别检测方法

于　敏[1],侯　敏[1],许择善[2],柴　泽[1],于继超[1],胡峻峰[1]*

（1. 东北林业大学 计算机与控制工程学院,哈尔滨 150040；2. 成都圭目机器人有限公司,成都 610101）

摘　要： 针对目前城市地下空间探测中探地雷达（Ground Penetrating Radar,GPR）图像类别检测时存在的精度低、结构异常特征双曲线识别困难、模型计算复杂度高等问题,文章提出一种基于改进YOLOv11的轻量化地下目标检测模型RBD-YOLOv11。利用GprMax软件进行金属管、PVC管及钢筋网三个类别的GPR图像仿真并通过CycleGAN对仿真图像进行域迁移,构建数量充足且高质量的数据集。首先,采用重参数化视觉Transformer轻量主干网络,减少模型参数量与计算量。其次,在Neck部分采用多尺度特征融合网络双向特征金字塔网络和空间-通道解耦下采样模块,以提升多尺度特征融合能力,降低计算成本。最后,采用动态上采样实现复杂背景下结构异常特征双曲线的有效识别。该方法能在更轻量化条件下实现较高的识别准确率,在GPR图像类别检测领域具有优势。

关键词： 探地雷达；地下目标；深度学习；结构异常双曲线

中图分类号： TP391.41;U418;P631.3　**文章编号：** 1001－5868(2026)05－0845－11

Deep-Learning Method for Underground Target Detection in Ground-Penetrating Radar

YU Min[1], HOU Min[1], XU Zeshan[2], CHAI Ze[1], YU Jichao[1], HU Junfeng[1]

(1. College of Computer and Control Engineering, Northeast Forestry University, Harbin 150040, CHN;
2. Chengdu Guimu Robot Co., Ltd., Chengdu 610101, CHN)

Abstract: To address low accuracy, complex hyperbolic feature recognition of structural anomalies, and high computational demands in urban underground image detection using ground-penetrating radar (GPR), this study proposes a lightweight detection model named RBD-YOLOv11, based on an improved YOLOv11n. A high-quality dataset comprising metal pipes, PVC pipes, and rebar meshes was constructed using GprMax for simulation and CycleGAN for domain transfer. Firstly, a re-parameterization vision transformer is adopted as a lightweight backbone network to significantly reduce model parameters and computational load. Secondly, a bidirectional feature pyramid network and spatial-channel decoupled downsampling modules are integrated into the Neck architecture to enhance multiscale feature fusion capabilities while reducing computational costs. Finally, a lightweight dynamic upsampler is employed to effectively recognize structural anomaly hyperbolas under complex backgrounds. Experimental results show that the proposed method achieves high recognition accuracy with a lightweight architecture, thereby benefiting GPR image category detection.

Key words: ground penetrating radar; underground targets; deep learning; structural anomaly hyperbolas

收稿日期：2026－01－05.

*通信作者：胡峻峰

0 引言

目前，城市化进程进入高速发展时期，城市地下空间的开发和利用变得尤为重要。随着地下工程数量不断增多，部分早期建设的地下设施不可避免地出现了老化现象，导致地下结构变形、管道破裂、道路坍塌等安全问题频发。为有效保障城市地下空间的安全，对地下目标进行精确、高效的类别检测具有重要意义。

探地雷达（Ground Penetrating Radar，GPR）作为一种非破坏性的地球物理探测方法，在地下测绘领域得到了广泛应用，能够获取地下不同埋藏目标的大量信息[1-4]。该技术主要借助电磁波在地下介质各分层界面所引发的部分反射信号，达成对地下目标的有效识别与精准判定，通过对反射信号进行处理，形成GPR的图像中蕴含丰富的地质雷达数据。然而，地下介质与环境极为复杂，GPR图像中往往存在着大量的噪声及干扰信号。因此，当下迫切需要探索出更高效、精确的探地雷达数据解读方法，以提升GPR图像解译工作的处理效能和精准程度。

为了挖掘探地雷达在地下目标探测方面的潜力，高效解译探地雷达数据，研究人员将图像处理技术应用在探地雷达B-Scan图像识别中。机器学习是人工智能范畴内的关键核心技术，在图像处理领域展现出卓越的分析与处理效能。基于此，在早期阶段，研究人员主要采用传统的机器学习算法开展GPR图像的识别研究工作。对于在雷达回波信号剖面图像中呈现双曲线特征的物体，杨莘等[5]构建了一套从粗到细的图像处理策略。具体而言，该策略先选取适宜的方向算子，对图像中的模糊区域进行精准边缘定位，随后运用改进后的Hough变换实施曲线拟合，进而提取出目标双曲线。Williams等[6]则将支持向量机（Support Vector Machines，SVM）、隐马尔可夫模型（Hidden Markov Model，HMM）与下采样技术相融合，达成对冰盖裂缝GPR图像的自动分类。刘敦文等[7]建立了一种用于解释隧道衬砌厚度探地雷达探测信号的BP神经网络模型。经实际应用与验证，该模型能够提升探地雷达信号解释的精确度以及工作效率。

深度学习的发展为诸多领域带来了变革性的影响，其具备从海量数据中自动提取有效特征的能力，可高效应对各类识别与检测任务，这一特性为复杂GPR图像的识别工作开辟了全新的解决路径[8]。当前探地雷达领域的相关研究面临着公开数据集匮乏的困境，多数研究只能依托仿真数据展开处理分析[9]。然而，仿真生成的图像与实际采集的GPR图像之间存在着显著的域差异。因此，如何得到用于深度学习的真实域GPR图像成为首先要解决的问题。Hu等[10]利用对损失函数加以改进的深度卷积生成对抗网络（Deep Convolutional Generative Adversarial Network，DCGAN），对城市地下缺陷中如空洞等类型的GPR图像进行数据扩充。在此基础上提出一种融合注意力模块的地下缺陷识别模型，有效提升了地下缺陷的识别精准度。但传统卷积生成的对抗神经网络在训练环节可能会出现训练崩溃以及模式坍塌等问题。方涛涛等[11]运用GprMax软件开展GPR图像的仿真工作，并对仿真图像采用循环一致性生成对抗网络（Cycle-Consistent Generative Adversarial Network，CycleGAN）进行域迁移，以此缩小仿真图像与真实图像之间的域差异。基于此数据集提出一种添加CBAM注意力机制的YOLOv8n模型，进行地下管线的识别定位，提高了管线的定位精度。赵迪等[12]创新性地提出一种基于卷积神经网络（Convolutional Neural Networks，CNN）以及梯度类激活可视化热力图（Gradient-weighted Class Activation Mapping，Grad-CAM）的探地雷达公路地下目标检测方法。但该方法需要通过分类训练、Grad-CAM图二值化、计算连通区域生成检测框三个阶段来实现对目标的识别，处理过程较为复杂。

目前，YOLO单阶段目标检测算法已广泛应用于各类目标检测任务[13]，将其引入GPR图像解译中，能够高效、准确地满足地下目标类别检测的需求[14-16]。Mehta等[17]通过数据增强和对YOLOv3的迁移学习，实现对管线、异常区域和桥洞的GPR图像检测，但精度比较低，平均精度为74.5%。Li等[18]提出一种将三维探地雷达与深度学习模型结合的方法，能够有效实现隐蔽裂缝的自动识别与定位，YOLOv5模型的最佳平均精度均值达到了94.39%，但其只对单一目标进行识别，在模型应用范围上有一定限制。王惠琴等[19]将ConvNeXt网络与YOLOv5相结合，提出一种地下多种管线的GPR图像识别网络，平均精度均值达到了96.19%。但该研究在数据集中混合使用了仿真数据与真实数据，没有考虑到仿真数据与真实图像的域差异和特征双曲线的结构异常问题，导致其在真实域图像识

别中存在局限性。

综上所述，当前借助GPR图像开展地下目标类别检测的方法仍存在不足：GPR图像数据量匮乏，仿真图像与真实图像之间存在域分布差异，难以有效提取特征；模型的参数量与计算量偏大，难以在资源受限的移动设备上部署应用；现有的检测方法无法满足GPR图像中多尺度及双曲线结构异常地下目标的类别检测需要。

针对上述问题，本文提出一种轻量化的GPR图像分类检测方法RBD-YOLOv11。该方法能够对多种类别的特征双曲线进行准确高效的识别检测。在数据集方面，采用部分工程实测数据，使用GprMax＋CycleGAN的方法对所得仿真图像进行风格迁移操作，以此减小仿真图像与真实图像之间的域差异，构建更加高质量的数据集。

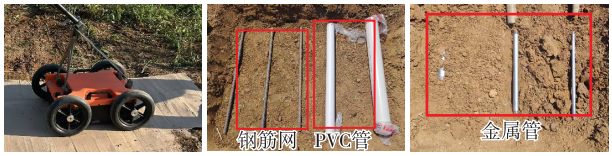
1）基于YOLOv11n的基准模型，替换更加轻量化的重参数化视觉Transformer（Re-parameterization Vision Transformer，RepViT）主干网络，以降低模型的参数量与计算量。

2）引入多尺度特征融合网络双向特征金字塔网络（Bidirectional Feature Pyramid Network，BiFPN），针对特征双曲线结构异常引发的多尺度识别问题进行优化，不仅增强了模型的多尺度特征融合效果，还进一步提升了GPR图像识别的准确率；同时采用空间-通道解耦下采样（Spatial-Channel Decoupled Downsampling，SCDown）模块，提高计算效率并降低成本。

3）使用轻量动态上采样器（Dynamic Upsampling，DySample），使采样过程聚焦于特征双曲线所在区域，减少对复杂背景信息的冗余采样。

1　数据集建立

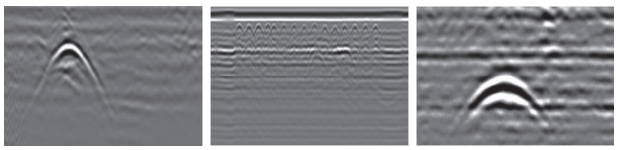
本文使用的GPR图像数据集来自工程实测和仿真迁移。实测数据集包括两部分，一部分来自大连中睿提供的道路下管线及隧道钢筋网实际工程探测，另一部分来自金属管、PVC管、钢筋网的预埋实验。预埋实验如图1所示，探测工具采用大连中睿RGPR-20探地雷达，介质为非均匀的黏性土壤。预埋实验的覆盖宽度为1.5 m，长度为1.8 m，目标埋藏深度为30～40 cm，钢筋和PVC管的间隔均为30 cm，金属管布置的间隔为50 cm。探测时采用400 MHz的屏蔽天线对不同直径的金属管、钢筋网及PVC管进行探测实验。



（a）探地雷达设备　（b）钢筋及PVC管　（c）金属管

图1　预埋实验

通常情况下，深度学习网络的训练过程需要大量的GPR图像，但通过实测获取的GPR图像数量比较有限，难以满足检测网络的数据量需求。在进行GPR图像研究时，可借助仿真模拟软件GprMax生成大规模图像样本[16]。作为一款用于模拟电磁波传播的开源工具，GprMax采用时域有限差分方法求解三维麦克斯韦方程组来模拟工程、地球物理学、考古学及医学等领域的电磁波传播，实测GPR图像如图2所示。但依靠仿真方法无法完全复现复杂的真实环境，生成样本与真实样本存在较大差异，且场景类型相对单一。



（a）金属管　（b）钢筋网　（c）PVC管

图2　实测GPR图像

CycleGAN在图像风格迁移任务中应用广泛，能够实现图像在不同图像域之间的迁移。因此，为减少仿真图像与真实图像的域差异，提升检测网络对真实数据的处理能力，对金属管、钢筋网、PVC管进行GPR图像仿真，并使用CycleGAN进行图像风格迁移，金属管示例如图3所示。图3(a)为埋藏管线的道路模型，介质层由上至下分别为路基碎石土、二灰稳定层、沥青混凝土和土壤。进行地下目标建模仿真时使用自动化脚本实现不同的地质模型大小、不同的目标埋藏位置、不同的目标半径。地质模型长为5～10 m，深为2.1 m，目标埋深为0.3～1.6 m，空心管线半径为0.1～0.4 m，壁厚为0.02 m，实心钢筋半径为0.01～0.02 m，钢筋个数为3～10不等。图3(b)为利用GprMax仿真生成的金属管GPR图像，该图像为无复杂地下介质干扰的理想环境状态。图3(c)是利用CycleGAN风格迁移后的GPR图像，与仿真图像相比，图像质量有所下降，但更能体现出GPR B-Scan图像的典型特征。



（a）地质模型 （b）仿真图像 （c）迁移后的图像

图3 基于CycleGAN的仿真图像风格迁移

预埋实验通过改变地下目标的埋深位置和间隔，以不同速度和位置采用探地雷达进行多次扫描，扫描时多次调整时窗、道间距等参数。最终选取20张符合要求的GPR图像，与实际工程探测的44张图像构成了64张实测数据集，其中金属管图像为21张，钢筋网图像为23张，PVC管图像为20张。利用时域有限差分方法模拟金属管图像330张、钢筋网图像328张、PVC管图像325张，一共983张，并利用CycleGAN对仿真图像进行风格迁移。实测与仿真GPR图像总计1 047张，金属管、钢筋网与PVC管的样本总数分别为351张、351张和345张。各类别样本数量分布高度一致（比例约为1∶1∶1），实现了数据集在类别层面的严格均衡。这种均衡分布保证了模型在特征提取过程中对不同类别地下目标的关注度一致，有效避免了模型对多数类别的过拟合现象。为增强模型的鲁棒性，对数据集进行数据增强，最终构建的GPR数据集包括6 282张图像，以8∶1∶1的比例划分训练集、验证集和测试集。

2 改进模型RBD-YOLOv11

针对目前GPR图像类别检测时存在的精度低、结构异常特征双曲线识别困难、误检和漏检较多、模型计算复杂度高等问题，本文以YOLOv11n作为基础模型进行优化改进。通过重构主干网络（Backbone）与颈部网络（Neck），实现对地下结构异常双曲线特征的高效、精准识别。为在保证特征提取能力的同时降低模型的参数量与计算负担，RBD-YOLOv11将原有的主干网络替换为RepViT轻量化网络，RepViT结合了轻量级视觉变换器（Vision Transformer，ViT）的架构设计原则与卷积神经网络的高效推理优势，如图4左侧所示，经过Stem层及Stage1～4的处理，主干网络提取出不同尺度的特征图（Stage2，Stage3，Stage4及后续处理层），分别对应浅层的纹理细节特征和深层的语义特征。Neck部分引入了BiFPN，DySample和SCDown三大模块，构建了一个高效且对异常特征敏感的融合网络。BiFPN引入了自顶向下和自底向上的双向路径，为不同分辨率的输入特征引入可学习的权重。这使得网络能够根据GPR结构异常特征的重要性，自动调整不同尺度特征的贡献度，从而更精准地捕捉结构异常导致的细微特征变化。在BiFPN的特征传递路径中，结合了C3k2模块增强了特征的非线性表达能力。在特征融合的自顶向下路径中，模型使用了DySample替代传统的最近邻或双线性插值上采样，不需要高昂的计算开

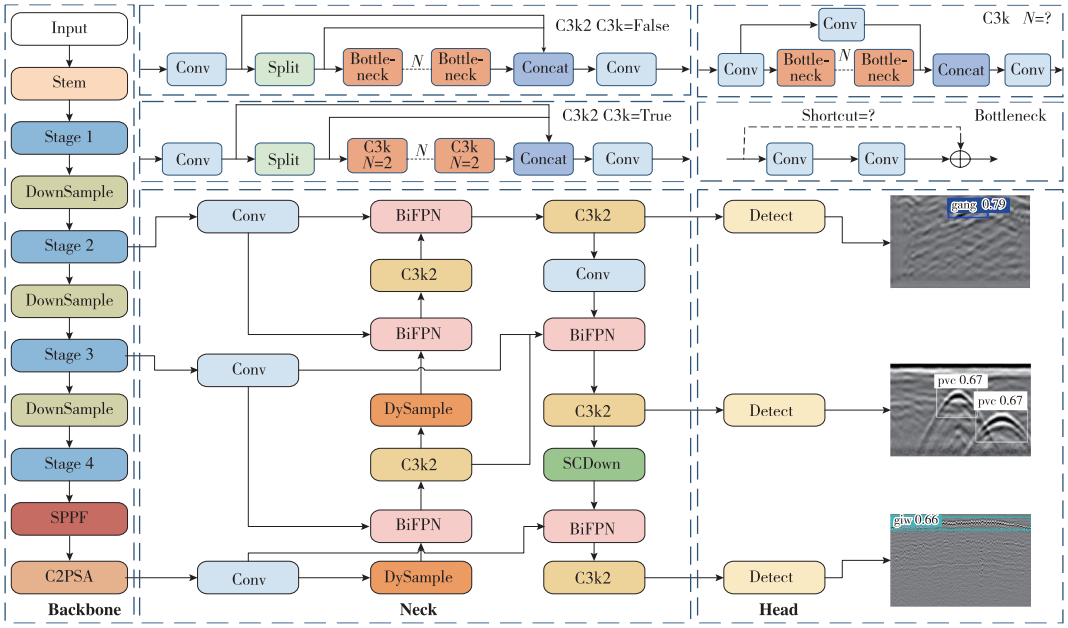


图4 RBD-YOLOv11模型结构图

销，能够引导上采样过程聚焦于目标特征（双曲线区域），有效抑制背景噪声的干扰。在特征融合的自底向上路径中，为了降低计算成本，模型引入了SCDown。经过 Neck 部分充分融合后的三个尺度的特征图（分别对应大、中、小目标），被送入检测头（Detect）。检测头通过一系列卷积层预测目标的类别概率和边界框位置，如图 4 右侧所示，改进后的RBD-YOLOv11 能够在复杂的 GPR 图像中清晰地识别出结构异常双曲线特征。

2.1　轻量化网络 RepViT

GPR 图像的局部特征表现为点状目标的双曲线衍射波，需要主干特征提取网络具有极强的边缘捕捉能力和高频信息提取能力。全局特征表现为地层的横向连续性、整体的介质衰减趋势以及深层与浅层信号的相关性，识别目标往往需要结合背景地层信息。

为实现模型轻量化目标，并能更好地提取 GPR 图像特征，本文选用 RepViT 网络替换模型的主干网络，以此降低计算的复杂度。RepViT 的设计思路是将轻量级 ViT 的高效架构理念融入标准轻量级 CNN（例如 MobileNetV3）中，以提升模型对移动设备的适配性，构建全新的轻量级纯 CNN 系列模型[20]。这种结构解决了传统轻量级 CNN 过于关注局部纹理而忽视长距离依赖的问题，从而更好地适配 GPR 图像“局部目标（双曲线）与全局地质背景（地层连续性）强耦合”的特性。RepViT 实现了更加高效的网络结构，在参数量和计算复杂度上显著降低的同时，大幅提高了训练速度，并在延迟方面也具有优势。在不影响模型性能的前提下，RepViT 有效降低了模型的存储要求与计算成本，这一特性使其更适配资源受限设备的部署场景，满足实时任务的应用需求。

RepViT 网络结构如图 5 所示，其特征提取网络主要包含 Stem，Stage 与下采样这三个关键功能模块。Stem 模块用于输入图像的初步特征提取，执行两次 3×3 卷积运算，既能很好地捕捉图像的局部信息，又能降低特征图维度，从而减少数据量，降低计算复杂度，提高模型的训练和推理速度。Stage 模块由多个 RepViTSEBlock 与 RepViTBlock 模块堆叠构成。该模块不仅能对输入特征进行多尺度融合，还能够捕捉特征图所包含的全局空间信息，使模型更高效准确地处理复杂特征。可以根据具体的任务需求和硬件资源情况，灵活地增加或减少 Stage 的数量，以实现模型良好的可扩展性。下采样模块包括 3×3 深度可分离卷积、1×1 逐点卷积与 FFN 模块。该模块在不同阶段进行分层下采样操作，通过缩减特征图尺寸，在降低计算复杂度和数据量的同时，增强了模型整体鲁棒性。

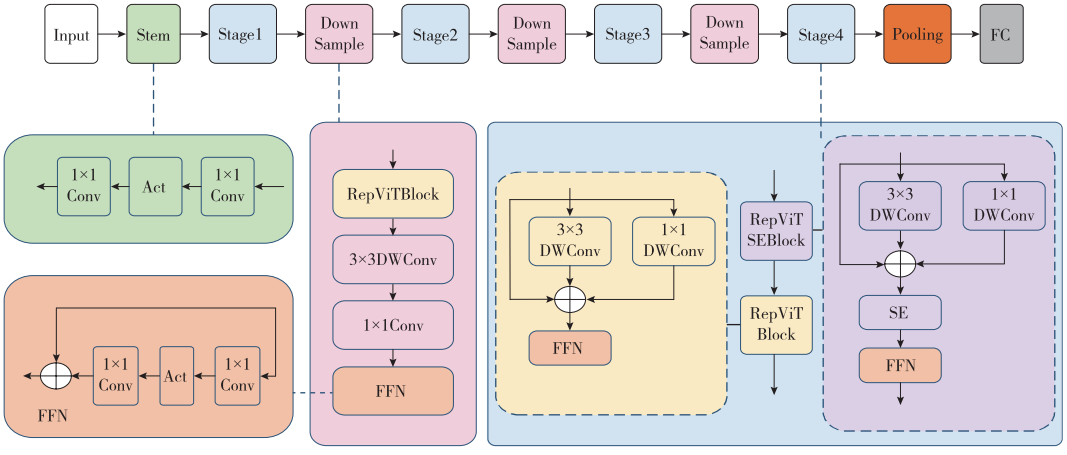


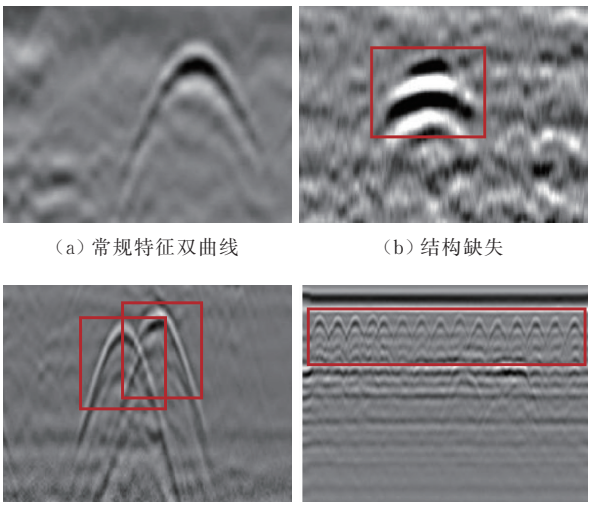
图 5　RepViT 网络结构图

2.2　基于改进 BiFPN 的多尺度特征融合网络

在 GPR 图像类别检测任务中，YOLOv11n 可以对 GPR 图像中常规且比较完整的特征双曲线进行有效识别，但部分 GPR 图像中的特征双曲线存在结构缺失、大范围多目标以及结构交叉等特点，由此增加了 GPR 图像的类别检测难度，导致 GPR 图像中出现特征双曲线的多尺度现象，如图 6 所示。

YOLOv11n 模型的颈部网络采用路径聚合网络（Path Aggregation Network，PANet），其结构如图 7（a）所示。该结构上采样与下采样操作之间的信息流仅能实现单向传递，随着网络深度的增加会导致信息丢失，模型精度受到影响，出现漏检、误检

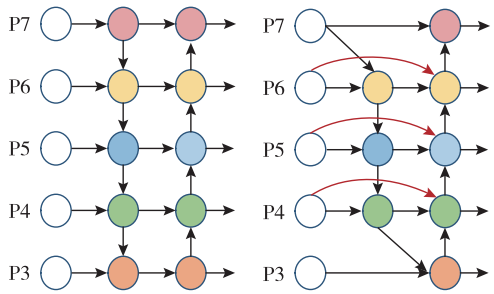
等现象。针对GPR图像中特征双曲线的尺度差异，在识别过程中，提取多尺度的特征信息进行融合十分关键。基于上述问题，本文引入多尺度特征融合网络BiFPN，替换YOLOv11n模型颈部网络原有的PANet结构，如图7(b)所示。该结构不仅能够提升模型的类别检测能力与运行稳定性，还能增强模型的多尺度特征融合效果。



(a) 常规特征双曲线　(b) 结构缺失

(c) 结构交叉　(d) 大范围多目标

图6　结构异常特征双曲线



(a) PANet结构　(b) BiFPN结构

图7　特征融合网络对比图

BiFPN结构会将仅具备单一输入边的节点移除，这类节点因未参与特征融合过程，对特征融合网络整体性能的贡献较低。在特征融合过程中引入了更多的跨层连接和反向路径，以实现更高效的特征传播和信息融合[21]。在特征融合操作前，先对原始卷积层的参数进行调整，将通道数减少至256，以此减少模型的参数量、降低计算复杂度，使模型更符合小型硬件设备的部署需求。

不同于YOLOv11n在PANet中使用步长为2的3×3卷积进行下采样，BiFPN引入可学习的权值来学习不同输入特征的重要性能，其输入与输出的关系式为：

$$O=\sum_i \frac{\omega_i}{\varepsilon+\sum_j \omega_j}\cdot I_i \tag{1}$$

式中，ω_i为输入特征I_i对应的学习权重，通过后级应用ReLU来确保$\omega_i \geqslant 0$。为避免数值不稳定，设置初始学习率$\varepsilon=0.0001$，归一化权重的值在0～1之间。

引入BiFPN增强了模型的复杂特征处理能力，但也引入了额外的计算开销。本文采用YOLOv10设计中更为高效的SCDown下采样模块，能够在底层操作上极致压缩计算量，从而实现整体模型的性能平衡，其结构如图8所示。先通过1×1的逐点卷积(Pointwise Convolution，PWConv)调节通道数，再通过3×3的深度卷积(Depthwise Convolution，DWConv)进行空间下采样，在降低计算成本的同时最大限度保留信息。

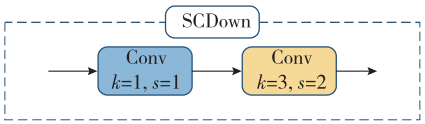


图8　SCDown结构图

2.3　DySample轻量动态上采样模块

Liu等[22]提出超轻量且高效能的DySample动态上采样器，该模块针对传统上采样方案中工作负载过高、应用场景受限等问题，避开动态卷积，从点采样角度出发去构建上采样流程，实现了更优的计算处理方法。

相较于传统基于内核设计的动态上采样器，DySample在模型参数量与浮点运算次数方面实现了有效缩减，占用更少的GPU内存，延迟也显著降低，在目标检测、实例分割等任务中表现优异，在工业检测中也展现出显著的优势和潜力。

DySample上采样器的具体结构如图9所示。对于给定的某一特征映射X，设其尺寸为$C\times H\times W$。首先通过采样点生成器将其转化为尺寸为$2g\times sH\times sW$的点采样集S，其中S的第一维度$2g$代表x和y坐标。其次，grid sample函数利用点采样集S中的位置信息对输入特征进行重新采样，最终得到尺寸为$C\times sH\times sW$的上采样特征图X_1，计算过程如式(2)所示，即：

$$X_1=\text{grid_sample}(X,S) \tag{2}$$

DySample实现高效上采样的核心组件为采样点生成器，对于给定的特征映射X需要结合线性层、

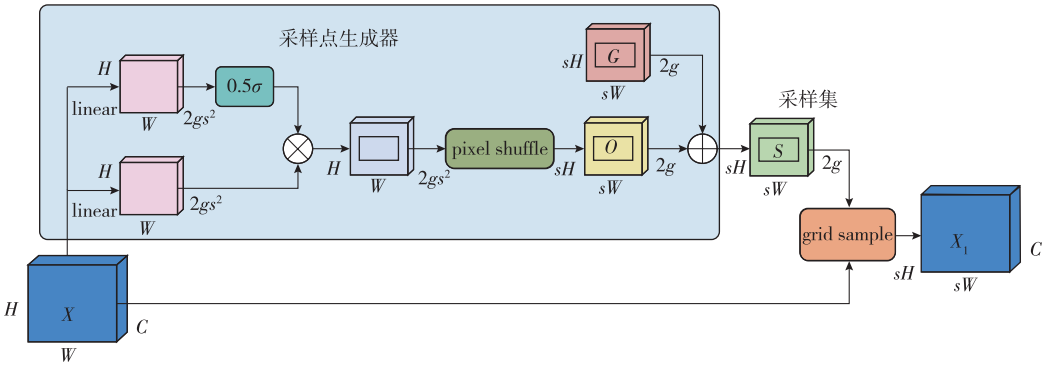


图 9　DySample 上采样器结构图

上采样比例因子 s、pixel shuffle 上采样操作共同生成偏移量 O，将其与原始采样网格 G 叠加，最终可得到采样集 S。sigmoid 函数用于生成动态范围因子，该因子的引入不仅能提升偏移量的灵活度，还可缓解偏移量的重叠问题。上述采样过程如公式(3)所示，即：

$$O = 0.5 \times \mathrm{sigmoid}\left[\mathrm{linear}_1(X)\right] \cdot \mathrm{linear}_2(X) \quad (3)$$

GPR 图像背景复杂，结构异常特征双曲线的类别检测较为困难，为了提高对目标区域的关注，本文在 Neck 网络部分使用了 DySample 动态上采样模块，减少计算量的同时使采样点聚焦于目标区域，针对性地减少对复杂背景部分的采样，从而突出 GPR 图像中的目标特征，提高类别检测的准确率。

3　实验及结果分析

3.1　服务器环境及配置

本实验在 Ubuntu 20.04.2 操作系统下开展，GPU 采用 NVIDIA A100，开发语言为 Python 3.9，借助 CUDA 11.4 实现计算加速，模型训练基于深度学习框架 Pytorch 1.12.0。实验所用的具体训练参数配置如表 1 所示。

表 1　训练参数设置

参数名称	参数设置
optimizer	Adam
epochs	150
batchsizes	16
workers	8
Imgs	640
lr0	0.001

3.2　实验评价指标

为了对比不同网络在自建 GPR 数据集上的类别检测能力，本研究采用精确率(P)、召回率(R)、平均精度(AP)及平均精度均值(mAP)作为核心评价指标。其中，精确率 P 的定义为正确预测为正样本(TP)的数量占所有预测为正样本(TP+FP)总数的比值，该指标的具体计算公式为：

$$P = \frac{TP}{TP + FP} \quad (4)$$

召回率 R 的定义为模型正确预测为正样本的数量，与数据集中实际为正样本(TP+FN)的比值，该指标的具体计算公式为：

$$R = \frac{TP}{TP + FN} \quad (5)$$

平均精度均值 mAP 的定义为数据集中每个类别的平均精度取算术平均值，该指标的具体计算公式为：

$$mAP = \frac{1}{n}\sum_{i=1}^{N} AP_i = \frac{1}{n}\sum_{i=1}^{N}\int P\mathrm{d}R \quad (6)$$

3.3　主干网络对比实验

探地雷达设备多应用于移动场景，在实际工程应用中需要模型具有更低的计算复杂度和较小的存储空间。本文以 YOLOv11n 为基础开展主干网络对比实验，以选出合适的主干网络，实验所得结果如表 2 所示。

表 2　主干网络对比实验结果

Backbone network	*mAP*@0.50/%	*P*/%	*R*/%	*Params*/(×10⁶)	*GFLOPs*/G	*Model Size*/M
YOLOv11n	77.2	81.8	75.4	2.58	6.3	5.24
YOLOv11n_FasterNet	75.2	80.5	74.6	2.37	5.5	4.85
YOLOv11n_EfficientNetV2	77.3	82.5	76.6	2.08	5.2	4.40
YOLOv11n_shuffleNetV2	73.1	80.9	75.2	1.70	4.1	3.61
YOLOv11n_RepViT	74.3	80.2	75.7	1.64	4.1	3.56

在进行主干网络的选取时，本研究以参数规模、计算复杂度及 mAP 等作为核心评估指标。当分别采用 FasterNet、EfficientNetV2、ShuffleNetV2 与 RepViT 作为主干网络时，除 EfficientNetV2 外，其

他主干网络的mAP都有小幅降低，但仍保持在较高水平。FasterNet的参数量、计算量和模型权重降低幅度较小，且精度低于原模型，综合效果较差。EfficientNetV2的各指标有不超过1.2%的微小增加，但参数量、计算量和模型权重仍然较大。ShuffleNetV2和RepViT在计算量上最低，但在其他指标上仅RepViT表现较好。

其中，当主干网络为RepViT时，参数量、计算量和模型权重达到最低，参数量较原模型下降了36.4%，计算量GFLOPs降至4.1 G，降低了34.9%，模型权重降低了32.1%，虽然在平均精度均值、精确率和召回率上都略低于原模型，但各指标仍保持在较高水平，在精度可控的情况下为后续在模型轻量化基础上进行精度提升打下了坚实的基础。RepViT在精度损失相对较小（mAP下降2.9%）的情况下，实现了最大幅度的模型轻量化，这种权衡对于实际工业部署具有重要价值，特别是在计算资源受限的应用场景中，综合考量后选择RepViT作为YOLOv11n的主干网络。

3.4 消融实验

为了评估各个模块改进后对YOLOv11n模型性能的影响，本文通过消融实验验证各模块引进后的改进效果。通过各项性能指标的变化分析每个模块的贡献，为后续模型的结构优化提供可靠依据。实验结果见表3。

表3 消融实验结果

YOLOv11n	RepViT	BiFPN	DySample	*mAP*@0.5/%	*P*/%	*R*/%	*Params*/($\times10^6$)	*GFLOPs*/G	*Model Size*/M
√				77.2	81.8	75.4	2.58	6.3	5.24
√	√			74.3	80.2	75.7	1.64	4.1	3.56
√		√		77.4	81.2	76.5	2.58	6.7	5.31
√			√	74.8	80.0	75.0	2.59	6.3	5.27
√	√	√		76.9	82.1	75.8	1.64	4.5	3.62
√	√		√	76.9	81.4	76.2	1.65	4.1	3.59
√		√	√	79.0	85.1	73.3	2.59	6.7	5.32
√	√	√	√	78.6	85.0	77.3	1.64	4.5	3.63

RepViT结构效果：将模型主干网络替换为RepViT网络后，召回率提高了0.3%，且参数量降低了36.4%，计算量降低了34.9%，模型权重降低了32.1%，证明该模型替换轻量化主干网络后虽精度有小幅降低，但在精度可控情况下实现了最佳的轻量化性能。

BiFPN结构效果：在原模型使用RepViT主干网络的基础上，Neck部分采用多尺度特征融合网络BiFPN，相较原模型精确率提高了0.3%，召回率提高了0.4%，说明BiFPN能够有效融合多尺度特征。参数量、计算量和模型权重略微上涨，相较原模型分别降低了36.4%，28.6%和30.9%，这主要是因为增加了卷积层进行通道数调整，避免不同层级因通道数不一致而带来的特征融合困难，牺牲部分参数量和计算量，实现精度的提升。

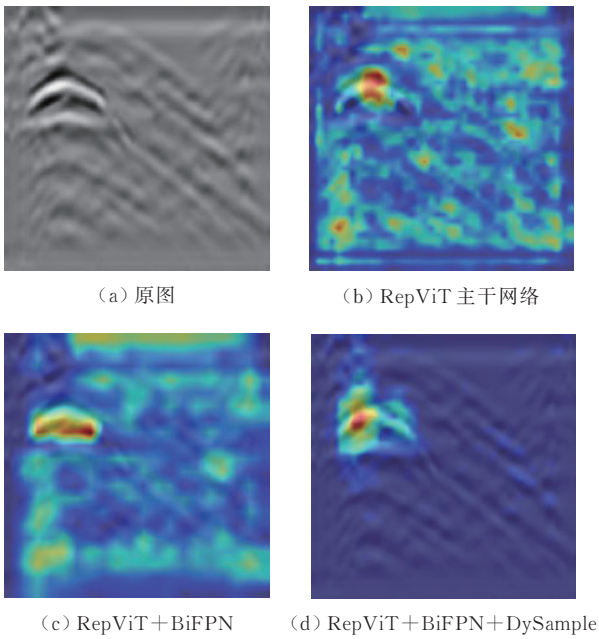
DySample结构效果：在原模型使用RepViT主干网络和BiFPN特征融合网络基础上，引入了DySample动态上采样器，mAP提高了1.4%，精确率提高了3.2%，召回率提高了1.9%，说明DySample可以有效模糊复杂背景信息，更聚集于特征双曲线区域，在保证参数量和计算量不变的情况下，进一步实现了精度的提升，最终得到了较为理想的改进效果。

3.5 模型特征可视化

为了更清晰直观地评估各改进模块对模型类别检测性能的提升效果，采用Grad-CAM[23]方法生成视觉热力图，如图10所示。该方法能够直观呈现不同模块如何影响网络学习的情况。Grad-CAM借助训练所得权重进行反向传播，对获取的梯度矩阵进行全局平均池化处理，进而对特征层中各通道进行加权激活，最终形成热力图。热力图中不同区域的亮度差异反映了对应位置在模型决策过程中的重要程度。

图10(b)所示为采用RepViT主干网络的模型热力图，虽然特征双曲线部分为主要关注的区域，但对不相关的背景部分仍有响应。在此基础上引入BiFPN特征融合网络如图10(c)所示，与图10(b)相比，特征双曲线部分颜色更亮，响应程度增强，错误提取的背景特征处亮度变低，抑制了对背景区域的错误关注。如图10(d)所示，再引入DySample，减少对复杂背景的采样，有效忽略了复杂背景特征，使亮度主要集中于特征双曲线部分，说明特征

双曲线为模型类别检测的关键特征区域，有着更高的响应程度，对正确目标的感知加强，使模型更加准确地关注GPR图像地下目标的双曲线特征。



（a）原图　（b）RepViT主干网络　（c）RepViT＋BiFPN　（d）RepViT＋BiFPN＋DySample

图10　改进模块对GPR检测模型性能贡献的热力图

3.6　对比实验

为了充分验证所改进模型的能力，本文选取了单发多框检测器（Single Shot MultiBox Detector，SSD）及包括多个版本的YOLO系列模型在内的主流One-Stage网络，在自建的GPR数据集上对类别检测性能进行对比。

由表4数据可知，经本文方法优化改进后的模型，在参数量、计算复杂度与权重大小等方面均低于对比模型的情况下，mAP和精确率分别达到78.6%，85%。本文改进的轻量化模型能够在计算资源有限的移动设备上进行部署，同时保证较高的精度。虽然SSD的精度值最高，但其参数量、计算量和模型权重都远大于本文模型，不适用于资源有限的移动设备。YOLOv7-tiny和YOLOv8n的mAP比本文模型高，但其他指标表现都不如本模型。YOLOv9-tiny和YOLOv10n的计算量和参数量相比本模型都过高，各评价指标都低于本模型。YOLOv11n作为基线模型综合来看有着较低的计算量、参数量和较高的精度，改进后的RBD-YOLOv11相比YOLOv11n的mAP提高了1.4%，精确率提高了3.2%，召回率提高了1.9%，模型参数量减少了36.4%，计算量减少了28.6%，模型权重降低了30.7%。

表4　不同模型GPR图像类别检测结果

模型	*mAP*@0.5/%	*P*/%	*R*/%	*Params*/(×10⁶)	*GFLOPs*/G	*Model Size*/M
SSD	82.7	88.7	80.2	24.10	61.2	91.62
YOLOv7-tiny	81.2	69.9	73.9	6.02	13.2	12.30
YOLOv8n	79.8	77.6	77.5	3.00	8.1	5.98
YOLOv9-tiny	73.9	77.3	76.9	2.80	11.7	6.50
YOLOv10n	76.0	80.4	73.1	2.69	8.2	5.51
YOLOv11n	77.2	81.8	75.4	2.58	6.3	5.24
YOLOv8-CES	73.1	80.3	74.9	2.50	7.1	5.43
YOLO11-L	76.4	83.1	77.5	1.97	4.6	4.04
RBD-YOLOv11	78.6	85.0	77.3	1.64	4.5	3.63

由于GPR公开数据集较少，大部分基于GPR图像的深度学习类别检测方法均基于自建数据集，为验证本研究改进模型的有效性，本文采用文献[24]中提到的YOLOv8-CES和文献[25]中提到的YOLO11-L这两种探地雷达图像检测方法。在本研究中的自建GPR数据集上进行对比试验，结果显示所提出的方法在类别检测精度和模型参数量等方面效果都更优。

为进一步直观对比本文改进的RBD-YOLOv11和原模型YOLOv11对GPR图像的类别检测性能，选择了大范围多目标、结构交叉、结构缺失等较难检测的GPR图像进行预测。实验结果如图11所示，本文提出的改进模型在特征双曲线结构异常的GPR图像类别检测中表现优异，检测性能更稳定，漏检与误检现象较少。

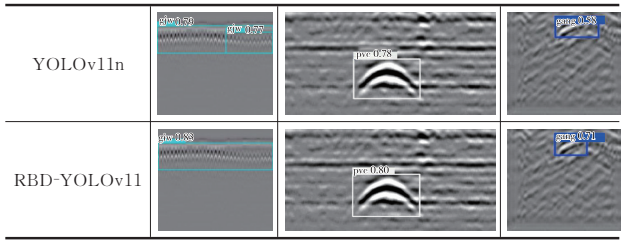


图11　模型类别检测结果对比

4　结论

本文针对GPR图像中双曲线结构异常目标识别难及模型计算复杂度高，提出一种轻量化检测方法RBD-YOLOv11。在数据集方面，利用GprMax仿真结合CycleGAN风格迁移，有效减少了仿真与实测数据的域差异，构建了高质量、多样性的数据集，有效增加了GPR图像样本的多样性，增强了模型的鲁棒性。在模型方面，通过引入RepViT轻量

化主干网络、BiFPN多尺度特征融合网络以及DySample动态上采样器，实现在降低模型参数量和计算量的同时增强了对GPR图像的类别检测能力。

实验结果表明，在自建数据集上改进后的RBD-YOLOv11模型表现优异，与原始YOLOv11n相比，mAP提升了1.4%，精确率和召回率分别提升了3.2%和1.9%；同时，模型参数量、计算量和权重分别减少了36.4%，28.6%和30.7%。本文模型能够满足用户在计算资源有限的设备上进行部署，同时60.3 FPS的帧率满足实时检测任务的要求。未来将收集更多不同类型的地下目标探地雷达数据进行实验，通过算法结构的进一步改进优化，拓展探地雷达智能探测技术的应用边界。

参考文献：

[1] Park Y J, Kim K H, Cho S B, et al. Buried small objects detected by UWB GPR[J]. IEEE Aerospace and Electronic Systems Magazine, 2004, 19(10): 3-6.

[2] 谢昭晖，李金铭. 我国探地雷达的应用现状及展望[J]. 工程勘察, 2007, 35(11): 71-75.
Xie Zhaohui, Li Jinming. The application status and its prospect of ground penetrating radar (GPR) in China [J]. Geotechnical Investigation & Surveying, 2007, 35 (11): 71-75.

[3] Walubita L F, Scullion T, Leidy J, et al. Non-destructive testing technologies application of the ground penetrating radar (GPR) to perpetual pavements [J]. Road Materials and Pavement Design, 2009, 10(2): 259-286.

[4] Lorenzo H, Pérez-Gracia V, Novo A, et al. Forestry applications of ground-penetrating radar[J]. Forest Systems, 2010, 19(1): 5-17.

[5] 杨 莘，陈淑珍，唐中柱. 探地雷达管道目标图像的识别[J]. 计算机应用, 2005, 25(5): 1209-1211, 1218.
Yang Shen, Chen Shuzhen, Tang Zhongzhu. Recognition for pipe image of ground penetrating radar [J]. Journal of Computer Applications, 2005, 25(5): 1209-1211, 1218.

[6] Williams R M, Ray L E, Lever J H, et al. Crevasse detection in ice sheets using ground penetrating radar and machine learning[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2014, 7(12): 4836-4848.

[7] 刘敦文，徐国元，黄仁东，等. 一种基于神经网络的探地雷达信号解释研究[J]. 地球物理学进展, 2004, 19(1): 179-182.
Liu Dunwen, Xu Guoyuan, Huang Rendong, et al. Study on a signal interpretation of GPR based on BP neural network[J]. Progress in Geophysics, 2004, 19(1): 179-182.

[8] Tong Z, Gao J, Yuan D. Advances of deep learning applications in ground-penetrating radar: a survey [J]. Construction and Building Materials, 2020, 258: 120371.

[9] Pham M T, Lefèvre S. Buried object detection from B-scan ground penetrating radar data using faster-RCNN [C]// IGARSS 2018-2018 IEEE International Geoscience and Remote Sensing Symposium, 2018: 6804-6807.

[10] Hu H, Fang H, Wang N, et al. Defects identification and location of underground space for ground penetrating radar based on deep learning [J]. Tunnelling and Underground Space Technology, 2023, 140: 105278.

[11] 方涛涛，王池社，王 洁，等. 基于YOLO v8n的探地雷达图像管线定位方法[J]. 国外电子测量技术, 2023, 42(11): 170-177.
Fang Taotao, Wang Chishe, Wang Jie, et al. Ground penetrating radar image pipeline location based on YOLO v8n[J]. Foreign Electronic Measurement Technology, 2023, 42(11): 170-177.

[12] 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]. Electronic Measurement Technology, 2020, 43 (10): 113-118.

[13] 王 敏，许永琪，曹小萌，等. 基于DSCI-YOLOv8的纺织品材质分类方法[J]. 电子测量技术, 2024, 47(18): 130-137.
Wang Min, Xu Yongqi, Cao Xiaomeng, et al. Textile material classification method based on DSCI-YOLOv8[J]. Electronic Measurement Technology, 2024, 47 (18): 130-137.

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

[15] Liu W, Luo R, Xiao M, et al. Intelligent detection of hidden distresses in asphalt pavement based on GPR and deep learning algorithm[J]. Construction and Building Materials, 2024, 416: 135089.

[16] Giannopoulos A. Modelling ground penetrating radar by GprMax [J]. Construction and Building Materials, 2005, 19(10): 755-762.

[17] Mehta R, Fazeel A, Rama P, et al. CNN-based sub-surface object detection using ground penetrating radar [C]//2021 11th International Workshop on Advanced Ground Penetrating Radar (IWAGPR), 2022: 1-5.

[18] Li S, Gu X, Xu X, et al. Detection of concealed cracks from ground penetrating radar images based on deep learning algorithm [J]. Construction and Building Materials, 2021, 273: 121949.

[19] 王惠琴，罗 佳，何永强，等. 改进YOLOv5的探地雷达常见地下管线识别[J]. 地球物理学报, 2024, 67(9): 3588-3604.
Wang Huiqin, Luo Jia, He Yongqiang, et al. Identification of

common underground pipelines by ground penetrating radar based on improved YOLOv5 [J]. Chinese Journal of Geophysics, 2024, 67(9): 3588-3604.

[20] Wang A, Chen H, Lin Z, et al. Rep ViT: revisiting mobile CNN from ViT perspective [C]//2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2024: 15909-15920.

[21] Tan M, Pang R, Le Q V. EfficientDet: scalable and efficient object detection [C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2020: 10778-10787.

[22] Liu W, Lu H, Fu H, et al. Learning to upsample by learning to sample[C]//2023 IEEE/CVF International Conference on Computer Vision (ICCV), 2024: 6004-6014.

[23] Selvaraju R R, Cogswell M, Das A, et al. Grad-CAM: visual explanations from deep networks *via* gradient-based localization [J]. International Journal of Computer Vision, 2020, 128(2): 336-359.

[24] 白　桃, 安奕铭, 金光来, 等. 道路隐性病害三维探地雷达图谱轻量化识别改进算法[J]. 交通运输工程学报, 2025, 25(4): 42-57.
Bai Tao, An Yiming, Jin Guanglai, et al. Improved algorithm for lightweight identification of 3D GPR images of hidden road defects[J]. Journal of Traffic and Transportation Engineering, 2025, 25(4): 42-57.

[25] 杨　豪,郭凯丽,张军辉,等. 基于YOLO11-L算法的道路内部空洞定量识别[J]. 中国公路学报, 2026,39(4):1-18.
Yang Hao, Guo Kaili, Zhang Junhui, et al. Quantitative identification of internal voids in Roads Based on YOLO11-L Algorithm [J]. China Journal of Highway and Transport, 2026, 39(4):1-18.

作者简介：

于　敏(2000—),女,山东省聊城市人,硕士研究生,主要研究方向为机器学习及其在探地雷达领域的应用;

胡峻峰(1980—),男,黑龙江省绥化市人,博士,副教授,主要研究方向为模式识别、智能控制。