

车载探地雷达技术在地铁隧道检测中的应用

曹志^{1,2}, 高洪清¹, 王威³, 刘华云⁴

(1. 中车南京浦镇车辆有限公司, 南京 210000; 2. 南京航空航天大学经济管理学院, 南京 210016;
3. 南京轨道交通产业发展有限公司, 南京 210000; 4. 成都唐源电气股份有限公司, 成都 610000)

摘要: 车载探地雷达技术通过发射和接收电磁波来探测和分析地下物体的特征, 对保障地铁隧道的安全性起到重要作用; 为对地铁隧道缺陷进行精确检测, 并提升检测的效率, 构建基于 Yolov5 模型的车载探地雷达检测系统; 首先采用零时校正、去直流、背景去除和图像增益方法对信号和图像进行去噪; 然后基于 Yolov5 目标检测模型, 引入特征网络金字塔和 SPP-Bottleneck 模块进行改进, 并采用锚框对目标图像进行检测, 最后构建基于 Yolov5 模型的车载探地雷达检测系统; 结果显示, 改进后的 Yolov5 模型在置信度相同的条件下, 相较于原始模型具有更高的 F_1 值; 在实例应用中, 基于 Yolov5 模型的车载探地雷达检测系统 F_1 、精确度、召回率平均值分别为 88.4%、87.3% 和 89.5%; 该系统对缺陷进行检测的时间为 0.3 s, 相较于其他 3 种检测模型, 效率分别提升了 93.75%、84.2% 和 50.0%, 更具有实际应用价值; 此次研究解决了传统车载探地雷达技术存在的问题, 对地铁的运营和维护具有重要的意义。

关键词: 车载探地雷达技术; 隧道检测; 信号去噪; Yolov5; SPP-Bottleneck

Application of Vehicular Mounted Ground Penetrating Radar Technology in Subway Tunnel Detection

CAO Zhi^{1,2}, GAO Hongqing¹, WANG Wei³, LIU Huayun⁴

(1. Nanjing Puzhen Rolling Stock Co., Ltd., CRRC, Nanjing 210000, China;

2. School of Economics and Management, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China;

3. Nanjing Rail Transit Industry Development Co., Ltd., Nanjing 210000, China;

4. Chengdu Tangyuan Electric Co., Ltd., Chengdu 610000, China)

Abstract: Vehicle mounted ground penetrating radar technology is used to detect and analyze the characteristics of subway tunnels by the emission and reception of electromagnetic waves, and it plays an important role in ensuring the safety and reliability of subway tunnels. In order to accurately detect the subway tunnel defects and improve the detection efficiency, an on-mounted radar detection system based on Yolov5 model is proposed. Firstly, the signal and image were first denoised through the methods of modifying the zero time, removing direct current (DC), background removal and image gain adjustment. Then, based on Yolov5 object detection model, the SPP-Bottleneck module and feature network pyramid are introduced to improve the performance of the system, the anchor box is adopted to detect the image of the target. The results show that the improved Yolov5 model has a higher F_1 value compared to the original model under the same confidence level. In practical applications, the F_1 , accuracy, and recall average values of the vehicle mounted ground penetrating radar detection system based on the Yolov5 model are 88.4%, 87.3%, and 89.5%, respectively. The Yolov5 object detection model has a detection time of 0.3 s, and its efficiency improves by 93.75%, 84.2%, and 50.0% compared to the other three detection models, respectively, which has more practical application value. This study solves the problems existing in traditional vehicle mounted ground penetrating radar technology, and it is of great significance for the operation and maintenance of subways.

Keywords: vehicle mounted ground penetrating radar technology; tunnel detection; signal denoising; Yolov5; SPP-Bottleneck

0 引言

地铁隧道是城市交通中十分重要的组成部分, 因此对于地铁隧道的维护和检测至关重要。然而, 隧道结构和地

质情况的复杂性使得地铁隧道的检测和维护变得异常关键^[1-2]。车载探地雷达是一种以雷达技术为基础的设备, 可以通过发射和接收电磁波来探测和分析地下物体的特征。它具有非接触、快速、高分辨率等特点, 能够有效地识别

收稿日期: 2023-08-30; 修回日期: 2023-09-14。

作者简介: 曹志(1982-), 男, 大学本科, 高级工程师。

通讯作者: 刘华云(1984-), 男, 大学本科, 助理工程师。

引用格式: 曹志, 高洪清, 王威, 等. 车载探地雷达技术在地铁隧道检测中的应用[J]. 计算机测量与控制, 2024, 32(4): 61-66.

地下障碍物，并提供有关地下结构和土壤情况的详细信息。孟繁龙等人将探地雷达安装在不同的载具上对地形进行检测。通过比较监测点的点云数据发现，不同的地形应用不同的载具雷达技术，可以获得不同的检测效果^[3]。利用车载探地雷达，可以对地下的排水系统、管线等进行全面的检测和评估。He 等人采用图像熵理论对地面进行描述，探索混合介质中探地雷达的检测性能。通过仿真实验显示，探地雷达能够在不同的介质中取得良好的检测性能^[4]。为了提升地铁隧道缺陷检测的精准度和检测效率，此次研究采用空气耦合天线作为雷达天线，并对车载探地雷达技术进行详细研究。针对雷达信号和雷达图像存在的噪声，采用零时校正、去直流、背景去除和图像增益方法进行图像和信号的去噪处理。在车载探地雷达技术中采用 Yolov5 目标检测模型，并引入 SPP-Bottleneck 模块对 Yolov5 目标检测模型进行改进，构建基于 Yolov5 模型的车载探地雷达检测系统，提升了原始车载雷达技术的探测精度。

1 车载探地雷达技术和地铁隧道检测研究

1.1 车载探地雷达技术研究

车载探地雷达技术是一种利用雷达波束对地下进行快速探测和成像的技术，该技术采用车载装置搭载在车辆上，通过发射探测波束并接收反射信号，获取地下目标的信息。车载探地雷达技术具有非接触式、快速、高效、广泛适用性等特点，被广泛应用于地下管线探测、隧道扫描、地质勘探、城市规划等领域。在地铁的隧道监测中，车载探地雷达技术采用扫描式探测，可以在行驶过程中实时获取地下信息，快速全面地掌握隧道周围地下情况，提高施工效率。载探地雷达技术能够获得高精度的地下目标信息，包括地质层位、管线位置、隧道结构变化等，可以提供详尽且准确的隧道地质信息^[5]。车载探地雷达技术具有广泛的应用范围，可以对较大范围的地下进行快速扫描，有效掌握隧道周边的地下情况。车载探地雷达技术可以实时监测隧道周围地下的变化情况，包括地质变形、管线移位、水位变化等，及时发现问题并采取相应的措施，保证隧道的安全运行^[6]。探地雷达检测的原理如图 1 所示。




图 1 探地雷达检测的原理图

车载探地雷达系统通过发射器产生探测波束，探测波束通常为微波频段的电磁波，具有一定的能量和频率^[7]。

探测波束在发射后遇到地下目标，如地下管线、地质层位、隧道结构等，会发生反射或散射，车载雷达系统通过接收器接收并记录这些信号，如式 (1) 所示：

$$t = \sqrt{\frac{4h^2 + a^2}{v}} \quad (1)$$

式中， t 为电磁波发射以及雷达系统接收的时间， h 为地下检测目标到雷达系统的距离， a 为天线的长度， v 为探测波束在不同介质中的传播速度。车载雷达系统通过分析接收到的反射信号的时间延迟和波形特征，可以计算出不同地下目标与车辆之间的距离，这样就可以获得地下目标的位置和深度信息，探测的深度如式 (2) 所示：

$$d_{\max}^4 = \frac{\lambda_m^2 \sigma_e e^{-4\alpha d}}{64\pi^3} C_{\text{system}} \quad (2)$$

式中， d 为车载探测雷达的最大探测深度， λ 为探测波束在介质中的主频波长， α 为衰减系数， σ_e 为地下检测目标的散射面积， C_{system} 为雷达系统的灵敏度和最大发射功率的比值。车载探地雷达的深度取决于多个因素，包括发射频率、接收灵敏度和地下目标的性质等。通常情况下，较低频率的雷达系统可以达到较大的探测深度，但分辨率可能较低。高频率的雷达系统则可以提供较高的分辨率，但探测深度相对较浅。实际应用中，可以根据需求选择适当的雷达频率，以平衡深度和分辨率的要求。探地雷达的水平分辨率和垂直分辨率是衡量雷达系统探测能力的两个重要指标，分为水平和垂直两种分辨率。水平分辨率是指雷达系统在水平方向上对地下目标的分辨能力，通常用于描述雷达系统在侧向探测时的能力^[8]。水平分辨率取决于雷达系统发射波束的宽度和接收信号的处理方式，较小的波束宽度可以提供更好的水平分辨率，即能够更好地识别并区分水平方向上的近邻地下目标。垂直分辨率是指雷达系统在垂直方向上对地下目标的分辨能力，通常用于描述雷达系统在深度方向探测时的能力。垂直分辨率取决于雷达系统发射波束的垂直角度范围和接收信号的处理方式，较小的垂直角度范围可以提供更好的垂直分辨率，即能够更准确地识别并区分不同深度的地下目标。分辨率计算的相关公式如式 (3) 所示：

$$\begin{cases} \Delta l = \sqrt{\frac{\lambda h}{2}} = \sqrt{\frac{hf_c}{2v}} \\ \Delta t = \frac{2\Delta h}{v} \end{cases} \quad (3)$$

式中， Δl 为两个检测目标在水平方向上的最短距离， λ 为探测波束的波长， h 为地下检测目标距离地表的深度， f_c 为雷达天线的频率， Δt 为探测波束在两个检测目标之间传播的时间差。采用合适的天线设计，有利于分辨率的提升。空气耦合天线是一种常用于车载探地雷达系统的天线类型，是一种非接触性的天线，通过空气感应的方式与地下目标进行信号交互^[9-10]。空气耦合天线的水平分辨率取决于其发射和接收波束的宽度，接收波束的宽度与天线的接收特性有关。通常情况下，较窄的发射和接收波束可以提供较高的

水平分辨率,使雷达系统能够更好地区分并识别水平方向上的近邻地下目标。空气耦合天线的垂直分辨率取决于其发射和接收波束的垂直角度范围,接收波束的垂直角度范围与天线的接收特性有关。通常情况下,较小的垂直角度范围可以提供较高的垂直分辨率,使雷达系统能够更准确地识别不同深度的地下目标。

1.2 车载探地雷达信号处理

雷达图像处理是对车载探地雷达系统获取的原始雷达信号进行处理和分析,以生成可视化的地下目标图像或定量化的地下目标信息。雷达图像和信号去噪是在雷达信号处理中非常重要的步骤之一。去噪的目的是降低或消除信号中的噪声成分,以提高雷达图像的质量和可靠性。去噪可以帮助识别和提取目标信号,减少误识别和误检测的可能性,并提高雷达系统的性能。对原始雷达信号进行预处理,包括去除噪声、补偿传输损失、校正时间延迟等,可以采用滤波、增益调整和零时校正等方法实现^[11]。零时校正是车载探地雷达系统中的一个重要步骤,用于校正天线和接收通道之间的时间差。在雷达系统中,发射的电磁波需要一定的时间才能到达地下目标并返回接收系统。这种时间差会在成像结果中引入误差。零时校正通过确定由雷达接收到的第一个有效信号的时间,来补偿发射和接收之间的时间差,确保成像结果的准确性。常见的零时校正方法分为硬件零时校正和软件零时校正,硬件零时校正通过电缆长度和信号传输速度等参数来计算和修正发射和接收之间的时间差,软件零时校正通过分析接收到的信号波形,并确定最早接收到的有效信号的时间点来进行校正^[12]。在实际应用中,雷达图像处理有很多技术和方法可供选择,如波束形成、多通道处理、数据融合等^[13-14]。具体的图像处理流程和算法选择通常根据应用需求、地下环境条件、雷达系统特性等因素进行优化和调整。在雷达图像处理中,去直流和背景去除是常见的预处理步骤,用于除去图像中的直流成分和背景噪声,以便更准确地分析和识别地下目标^[15-16]。去直流和背景去除公式如式(4)所示:

$$\begin{cases} X(m,t) = X(m,t) - \frac{1}{M} \sum_{b=1}^M X(m,b) \\ X(m,t) = X(m,t) - \frac{1}{k} \sum_{m=1}^k B(m,t) \end{cases} \quad (4)$$

式中, m 为采集的A-Scan数据的数量, $\frac{1}{M} \sum_{b=1}^M X(m,b)$ 为直流均值, t 为采样时间, M 为每道A-Scan数据的采样点数, k 为某一条A-Scan数据上采集的一段只有混凝土的雷达数据, $\frac{1}{k} \sum_{m=1}^k B(m,t)$ 为B-Scan每一行数据的平均值。雷达接收到的信号通常会包含直流成分,是由于不完美的校准或系统偏置引起的。去除直流可以使得图像的亮度范围均匀,避免偏离真实的目标反射强度。最简单的去直流方法是通过减去图像中的平均值,将整幅图像的亮度居中于零^[17]。背景噪声是指来自环境或雷达系统本身的不相关信号,包

括地面反射、系统噪声、电磁干扰等。背景去除的目的是抑制背景噪声,使得地下目标更容易被检测和分析。为了降低雷达信号受到其他信号干扰的强度,采用小波变换进行去噪处理^[18]。小波变换是一种用于信号和图像分析的一种数学变换方法。与传统的傅里叶变换相比,小波变换能够提供更好的时频局部性,并且能够适应信号和图像的非平稳特性^[19-20]。为了使接收到的图像亮度更高,图像更清晰,采用图像增益来解决。图像增益是一种调整图像亮度和对比度的方法,通过对图像的像素值进行线性或非线性的缩放,改变图像的亮度和对比度特性。图像增益可以使得图像的亮度范围更广或更窄,使图像更清晰、更鲜明。常见的图像增益方法包括线性拉伸、对数变换、幂律变换等^[21-22]。直方图均衡化是一种直方图调整的方法,用于增强图像的对比度和显示细节。直方图均衡化的核心思想是通过将原始图像的像素值进行变换,使得图像的灰度级分布尽可能均匀。通过直方图均衡化,可以使得图像中的暗部和亮部细节更加丰富,并使得整个图像的对比度得到改善。指数变换是一种非线性的时间域图像增强方法,通过对图像像素值进行指数函数的变换,达到增强图像细节和对比度的效果。指数变换的基本思想是通过调整图像中不同灰度区域的斜率和曲率,改善图像的可视质量和辨识能力。指数变换公式如式(5)所示:

$$y = b^{(x-a)} - 1 \quad (5)$$

式中, b 和 c 为参数,用于控制曲线的形状。 a 为参数,用于控制曲线的左右偏移量。指数变换的参数可以根据具体应用需求来选择,可以降低幅度信号放大并压制高幅度信号。指数变换常用于处理信号的压缩和扩展,以及调整信号的动态范围。通过上述的信号预处理和图像增益的方法,可以提高空气耦合天线的水平和垂直分辨率,去除图像中的噪声,从而提升车载探地雷达系统的探测能力和成像效果。

1.3 目标检测模型在地铁隧道检测中的研究

为了实现地铁隧道中的缺陷检测研究,在车载探地雷达中引入Yolov5(Yolov5, you only look once version 5)模型,提高检测的准确率。Yolov5采用了基于主干网络为CSPDarknet53(CSPDarknet53, cross stage partial Darknet53)的网络架构,相比于YOLOv4的Darknet53,CSPDarknet53具有更高的效率和准确性。CSPDarknet53是一种深度残差网络模型,由多个残差块(Residual Block)和CSP连接组成,每个残差块由一个 1×1 卷积层、一个 3×3 卷积层和一个残差连接(Residual Connection)组成。残差连接将输入特征与输出特征进行相加,有助于更好地传递梯度和优化信息的流动。CSP连接将特征图划分为两个部分,分别通过 1×1 卷积层进行处理。一部分继续向后传递,另一部分通过一系列的残差块和卷积层进行处理,之后再与前一部分进行合并,这种结构可以提高特征的复用和传递,同时减少参数量。因此,Yolov5的CSPDarknet53主干网络

采用了残差块和 CSP 连接的结构，通过逐渐减小特征图的尺寸和增加通道数，高效地提取多尺度的特征，这种主干网络设计使得 YOLOv5 在目标检测任务中具有更高的准确性和效率。YOLOv5 网络模型结构如图 2 所示。

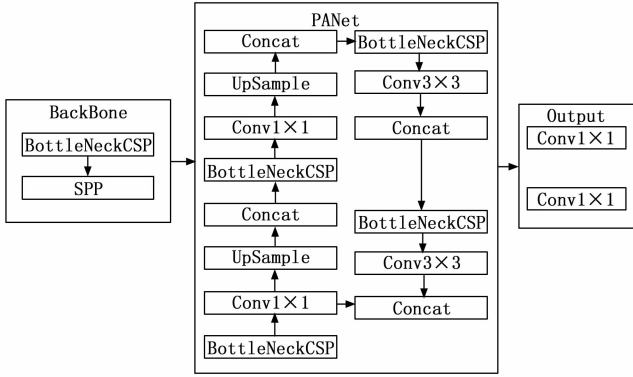


图 2 YOLOv5 网络模型结构图

在 YOLOv5 网络模型中，与其他深度学习网络模型的区别在于引入了一个特征网络金字塔。特征金字塔网络 (FPN, feature pyramid network) 主要用于解决目标检测中不同尺度目标的检测问题，其特征是包含一个自顶向下的路径 (Top-down Pathway) 和一个自下向上的路径 (Bottom-up Pathway) 来提取多尺度的特征信息。为了解决图像失真的问题，引入 SPP-Bottleneck (SPP-Bottleneck, spatial pyramid pooling-Bottleneck) 模块，该模块是一种常用的神经网络模块，用于处理具有不同尺度特征的图像。SPP-Bottleneck 结合了 SPP (Spatial Pyramid Pooling) 和 Bottleneck 结构，旨在提取多尺度的特征并减少网络的参数和计算量。Bottleneck 结构一般由一个 1x1 的卷积层、一个 3x3 的卷积层和一个 1x1 的卷积层组成，作用是通过降维和升维来减少网络的参数和计算量。在目标检测任务中，锚框 (Anchor Box) 是一种用于定义候选目标框的策略，通过在图像上按照一定的尺度和宽高比生成一系列固定大小的框，用于在不同位置和尺度上框选出可能包含目标的区域。首先根据具体任务和数据集的特点，选择一组适当的尺度和宽高比，通常，锚框会在多个尺度和多个宽高比上进行生成，以覆盖不同大小和形状的目标。锚框生成公式见式 (6)：

$$\begin{cases} h = \sqrt{R \cdot \frac{s}{ratio}} \\ w = ratio \cdot h = \sqrt{R \cdot s \cdot ratio} \end{cases} \quad (6)$$

式中， h 和 w 分别为锚框的高度和宽度， R 为设置的锚框变换比例， $ratio$ 为锚框的宽和高度之比， s 为锚框的面积。将生成的锚框应用于图像的所有可能位置，以获得一系列候选框。通常，锚框会在图像的每个像素位置进行生成，以检测不同位置的目标。将生成的锚框与真实的目标框进行匹配，以确定哪些锚框是正样本 (Positive Anchor)，即与目标框有较高的重叠率，并进行相应的分类和回归任务。

通常使用一定的阈值来判断锚框与真实目标框之间的重叠程度。通过锚框的生成，目标检测算法可以在不同的位置和尺度上搜索潜在的目标框，从而提高检测的准确性和鲁棒性。同时，由于锚框的固定尺度和宽高比，可以减少计算量，提高算法的效率。CIoU (Complete Intersection over Union) 损失函数是一种目标检测任务中常用的损失函数，用于度量预测框和真实框之间的差异。CIoU 计算公式如式 (7) 所示：

$$L_{CIoU} = 1 - IoU + \frac{\rho^2(b, b^{gt})}{c^2} + \beta\gamma \quad (7)$$

式中， β 为一个修正参数， ρ 为欧几里得距离， γ 为衡量参数， b 为预测框的中心点， b^{gt} 为目标框的中心点， c 为预测框和目标框交集部分的对角线距离。在目标检测任务中，采用 CIoU 损失函数来指导模型的训练，使模型能够更准确地预测目标框并提高检测性能。检测模型识别缺陷流程如图 3 所示。

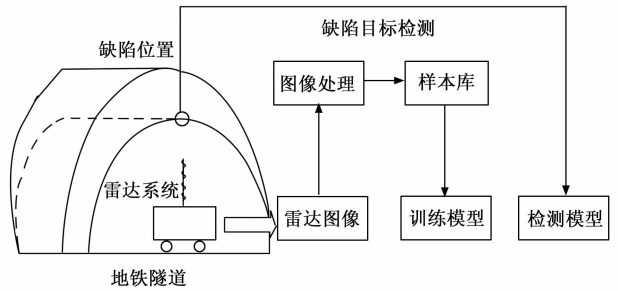


图 3 隧道检测模型检测缺陷流程图

2 地铁隧道目标检测模型性能测试与实例分析

2.1 地铁隧道目标检测模型性能测试

为了测试 YOLOv5 模型在车载探地雷达中的性能，操作系统选择 Windows10 系统，CPU 为 Intel (R) Core™ i9-10900CPU@2.80 GHz，GPU 为 NVIDIA GeForce RTX 2060，系统的内存为 32 GB。初始学习率设置为 0.001，批数量设置为 4，迭代次数设置为 80 次，动量因子数值设置为 0.937，衰减因子设置为 0.000 5。采用车载探地雷达技术对某地地铁隧道中拱顶存在的空洞和钢筋结构脱空数据进行采集，其中空洞面积大小在 0.50~2.0 m² 之间，深度在 0.05~0.18 m 之间。钢筋结构脱空面积大小在 0.08~0.50 m² 之间，深度在 0.05~0.32 m 之间，共计 100 个数据。将改进前的 YOLOv5 模型与引入 SPP-Bottleneck 模块的 YOLOv5 模型在隧道空洞和钢筋结构脱空数据集中进行对比测试，采用 Precision 和 Recall 数值作为测试指标，绘制 P-R 曲线如图 4 所示。

图 4 (a) 为改进前的 YOLOv5 模型的召回率和精度的曲线，图 4 (b) 为改进后的 YOLOv5 模型的召回率和精度的曲线。召回率越高，精度越低；召回率越低，精度越高，两者呈现反比线性关系。召回率和精度之间的比值反映了 YOLOv5 模型对地铁隧道目标检测的检测能力，因此，曲线




图 4 Yolov5 模型改进前后的召回率和精度曲线

与坐标轴之间围成的面积越大, 检测的能力越强, 面积越小, 检测的能力越弱。从图 4 中可以看出, 引入 SPP-Bottleneck 模块后的 Yolov5 模型, 在不同数据测试下的召回率和精度曲线与坐标轴之间围成的面积, 均大于改进前的 Yolov5 模型。因此, 引入 SPP-Bottleneck 模块的 Yolov5 模型能够处理不同类型的图像数据, 均能实现较高的检测精度, 相较于原始的 Yolov5 模型具有更好的检测能力。为了更好地描述 Yolov5 模型改进前后的性能, 采用 F_1 值曲线来进行对比分析。 F_1 值是一种常用于衡量二分类模型性能的指标, 综合考虑了精确率和召回率, 能够评估模型的综合性能。测试结果如图 5 所示。

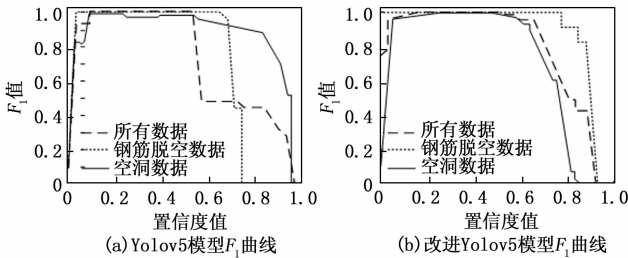


图 5 Yolov5 模型改进前后的 F_1 曲线

图 5 (a) 为改进前的 Yolov5 目标检测模型的 F_1 值曲线, 图 5 (b) 为改进后的 Yolov5 目标检测模型的 F_1 值曲线。从图中可以看出, 两种模型的 F_1 值曲线先增加, 到峰值后基本保持不变。随着置信度值的增加, F_1 值曲线逐渐减小。例如当置信度为 0.4 时, 改进前的 Yolov5 目标检测模型的所有数据的 F_1 值为 1.0, 钢筋脱空数据的 F_1 值为 1.0, 但是空洞数据的 F_1 值为 0.95。改进后的 Yolov5 目标检测模型的所有数据的 F_1 值为 1.0, 钢筋脱空数据的 F_1 值为 1.0, 空洞数据的 F_1 值为 1.0。在相同的置信度值下, 改进后的 Yolov5 模型具有更高的 F_1 值, 因此具有更好的检测性能。

2.2 地铁隧道目标检测模型实例分析

为了验证车载探地雷达技术在实际案例中的检测性能, 将 SIR-30 车载探地雷达系统沿着某市 1 号线地铁隧道进行检测, 车载探地雷达系统天线频率设置为 300 MHz, 为空气耦合天线。检测通道设置为 6 个, 每个通道都是独立的, 采样频率设置为 500 kHz, 扫描频率设置为 976 scan/s, 采

样点数为 512 个, 每个的采样时间为 60 ns, 间距 16 mm 采样一次。雷达系统前进速度为 60 km/h, 电源为 220 V 的交流电源。收集 7 种样本数据, 样本数据的类别分别为雨水井、电缆、金属导管、非金属管、稀疏钢筋网、密集钢筋网以及空洞, 合计 3 000 条数据。采用零时校正、去直流、背景去除和图像增益方法对信号和图像进行去噪处理。将车载探地雷达系统在上述 7 种类别的样本中进行测试, 采用召回率、精确度值和 F_1 值作为测试指标, 结果如表 1 所示。

表 1 不同种类样本的检测结果

种类	电缆	金属导管	非金属管	空洞	井	稀疏钢筋网	致密钢筋网	平均值
F_1 值	0.892	0.889	0.842	0.821	0.929	0.908	0.905	0.884
Precision	0.859	0.915	0.835	0.819	0.962	0.872	0.846	0.873
Recall	0.925	0.854	0.834	0.819	0.915	0.947	0.968	0.895

从表 1 中可以看出, 车载探地雷达系统检测稀疏钢筋网时的 F_1 值最高, 为 0.908, 检测空洞时的 F_1 值最低, 为 0.821。车载探地雷达系统检测金属导管时的精确度值最高, 为 0.915, 检测空洞时的精确度值最低, 为 0.819。车载探地雷达系统检测致密钢筋网时的召回率最高, 为 0.968, 空洞时的精确度值最低, 为 0.819。虽然检测不同缺陷时有不同的指标结果, 但是检测 7 种类别的样本 F_1 值平均值为 0.884, 精确度值的平均值为 0.873, 召回率的平均值为 0.895, 3 种指标的数值均在 0.850 以上。因此, 此次研究引入 SPP-Bottleneck 神经网络模块改进后的车载探地雷达系统, 对于地铁隧道中的不同缺陷的检测均具有有效性。为了验证 Yolov5 目标检测模型在车载探地雷达系统中的实际应用效果, 选择 3 种常见的目标检测模型进行对比测试, 分别为模板匹配模型、基于梯度直方图的支持向量机模型 (HOG-SVM, histogram of gradient-support vector mac)、基于区域卷积神经网络的目标检测模型 (Faster RCNN, faster regions with CNN features), 将 P-R 曲线和测试时间作为指标, 对比测试的结果如图 6 所示。

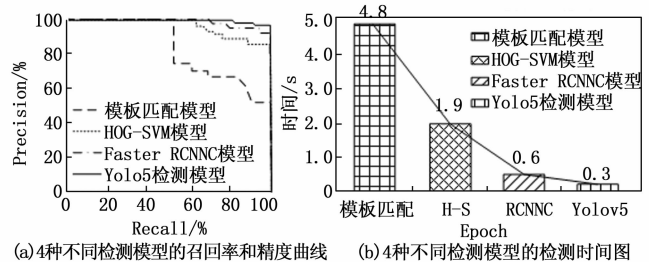


图 6 4 种不同检测模型的 P-R 曲线和时间柱状图

从图 6 (a) 中可以看出, 模板匹配模型的 P-R 曲线与坐标轴围成的面积最小, 检测的性能最差。Yolov5 目标检测模型的 P-R 曲线与坐标轴围成的面积最大, 检测的性能最优。从图 6 (b) 中可以看出, 模板匹配目标检测模型测

试时间为 4.8 s, HOG-SVM 目标检测模型的检测时间为 1.9 s, Faster RCNNC 目标检测模型的检测时间为 0.6 s, Yolov5 目标检测模型的检测时间为 0.3 s。由此可见, Yolov5 目标检测模型的检测时间相较于模板匹配目标检测模型、HOG-SVM 目标检测模型和 Faster RCNNC 目标检测模型, 检测效率分别提升了 93.75%、84.2% 和 50.0%。因此, 在改进后的 Yolov5 目标检测模型中, 引入的 SPP-Bottleneck 神经网络模块和特征金字塔能够增强模型对不同种类图像的检测效率, 锚框的生成能提高检测的准确性和鲁棒性。与其他 3 种模型相比, Yolov5 目标检测模型在实际的应用中具有更好的检测效果和检测效率, 使用价值高于其他 3 种检测模型。

3 结束语

地铁隧道对于地铁的运营和安全至关重要, 因此对于地铁隧道的检测和维护是一项关键的任务。为了更好地对地铁隧道的缺陷进行检测, 此次研究基于车载探地雷达检测系统, 对雷达系统中的信号和成像图像中, 存在的噪声采用不同的去噪方式进行处理。采用 Yolov5 目标检测模型, 并引入 SPP-Bottleneck 模块对 Yolov5 目标检测模型进行改进, 构建基于 Yolov5 模型的车载探地雷达检测系统。测试结果显示, 改进后的 Yolov5 模型与原始的 Yolov5 模型相比, 改进后的 Yolov5 模型具有更好的 P-R 值, 并且在相同的置信度值下, 改进后的 Yolov5 模型具有更高的 F_1 值。因此, 改进后的 Yolov5 目标检测模型具有更好的检测性能。在实际的工程应用中, 基于 Yolov5 检测模型的车载探地雷达检测系统的 F_1 值平均值为 0.884, 精确度值的平均值为 0.873, 召回率的平均值为 0.895, 均在 0.850 以上, 因此该模型对于隧道中的缺陷检测具有有效性。与其他 3 种目标检测模型相比, Yolov5 目标检测模型的 P-R 曲线与坐标轴围成的面积最大, 检测的性能最优。Yolov5 目标检测模型的检测时间为 0.3 s, 相较于模板匹配模型、HOG-SVM 模型和 Faster RCNNC 模型, 效率分别提升了 93.75%、84.2% 和 50.0%, 更具有实际应用价值。此次研究也存在不足之处, 模型检测的数据集不够全面, 在接下来的研究中应考虑到隧道内部结构数据, 构建更全面的数据集用来辅助检测。

参考文献:

- [1] 杨必胜, 宗泽亮, 陈 驰, 等. 车载探地雷达地下目标实时探测法 [J]. 测绘学报, 2020, 49 (7): 874-882.
- [2] 吕 可, 赵严冰. 基于仿真的舰载预警探测雷达使用性能分析研究 [J]. 计算机测量与控制, 2021, 29 (11): 111-115.
- [3] 孟繁龙, 王 婷, 张伟娜, 等. 不同载具下激光雷达在地形测量中的应用探讨 [J]. 工程技术研究, 2021, 2 (10): 60-61.
- [4] HE W, HUANG F, ZHANG S, et al. Fine grid model for the dielectric characteristics of ground-penetrating radar in mixed media [J]. Geophysical Prospecting, 2022, 70 (6): 1052-1065.
- [5] 徐从杰, 陈 阳, 司小东, 等. 运营地铁隧道车载探地雷达衬砌检测适用性研究 [J]. 现代隧道技术, 2022, 59 (S01): 627-634.
- [6] 王 斌, 杨瑞景, 龙福刚, 等. 基于激光雷达技术的轻便型电力巡检系统研究 [J]. 自动化技术与应用, 2023, 42 (1): 55-59.
- [7] 杨春峰, 于荣华, 黄维鹿, 等. 基于激光雷达和可见光立体测量的无人机电力巡线技术研究 [J]. 自动化技术与应用, 2021, 40 (10): 177-180.
- [8] WU Y, SHEN F, XU D. Ground-penetrating radar-based underground environmental perception radar for robotic system; [J]. International Journal of Advanced Robotic Systems, 2020, 17 (2): 1078-1082.
- [9] 王 旭. 机载雷达数据记录仪设计及关键技术研究 [J]. 微型电脑应用, 2020, 36 (7): 118-122.
- [10] 占洪涛, 郭 亮, 詹武平, 等. 基于 RCS 置信度分析的雷达目标识别 [J]. 微型电脑应用, 2022, 38 (7): 35-37.
- [11] 冯建伟, 王联智, 谢 敏, 等. 人工智能与雷达图相结合的配电网运维分析研究 [J]. 自动化仪表, 2021, 42 (7): 42-46.
- [12] 韩嘉良, 贾 丹, 韩国栋, 等. 一种具有宽带双极化低散射特征的微带阵列天线 [J]. 计算机测量与控制, 2023, 31 (4): 281-288.
- [13] 崔积丰. 基于卷积神经网络的多功能雷达波形识别方法研究 [J]. 计算机测量与控制, 2023, 31 (8): 267-272, 299.
- [14] 郑浩荣, 蔡红维, 张 瀚, 等. 基于变步长算法的航天测控雷达多站跟踪技术研究 [J]. 计算机测量与控制, 2022, 30 (10): 33-38.
- [15] 杨其锋, 陈晓宇, 吴庆玲. 探地雷达应力与折射率传感器的制备与性能 [J]. 实验室研究与探索, 2021, 40 (7): 60-63.
- [16] 张东昊, 覃 晖. 基于探地雷达和深度学习的隧道初期支护检测方法 [J]. 现代隧道技术, 2020, 57 (1): 174-178.
- [17] 舒志乐, 朱思宇, 张华杰. 无砟轨道 CA 砂浆层病害探地雷达检测及三维正演模拟 [J]. 铁道科学与工程学报, 2021, 18 (7): 1679-1685.
- [18] 刘 倩, 郭秀军, 邵 帅, 等. 中尺度模拟土壤油污染区探地雷达探测效果分析 [J]. 地球物理学进展, 2020, 35 (1): 322-330.
- [19] 冯德山, 谭 阳, 杨 军, 等. 基于复频移完全匹配层的辛龙格库塔算法探地雷达正演 [J]. 科学技术与工程, 2022, 22 (9): 3473-3484.
- [20] 吴学礼, 王壮壮, 刁炳权, 等. 基于小波自适应阈值方法的探地雷达去噪 [J]. 科学技术与工程, 2023, 23 (11): 4686-4692.
- [21] 王百泉, 董可欣, 刘昌斌, 等. 用于衬砌探测的空气耦合探地雷达天线设计 [J]. 测试技术学报, 2023, 37 (1): 79-86.
- [22] 蔡文龙, 周 凯, 王 罡. 基于探地雷达的沥青路面结构内部隐性病害量化识别方法研究 [J]. 物探化探计算技术, 2022, 44 (5): 597-604.