

面向探地雷达 B-scan图像的目标检测算法综述

侯斐斐 施荣华 雷文太* 董健 许孟迪 席景春

(中南大学计算机学院 长沙 410000)

摘要: 利用无损探测技术来获取地下目标的信息是当前研究的热点, 探地雷达(GPR)作为一种重要的无损工具, 已被广泛用于检测, 定位和特征化地下目标。然而, 从GPR成像中探测掩埋物体并评估其位置既费时又费力。因此, 实现地下目标的自动化探测对实际应用是必要的。为此, 该文在综合分析地下目标回波特征的基础上, 讨论了使用GPR评估目标位置的可行性, 并回顾了国内外学者在GPR成像中对双曲线特征自动化检测的研究进展。该文还在国内外典型实例剖析的基础上, 总结并比较了目标检测的处理方法。最后指出, 未来的研究应集中于开发新的深度学习检测框架, 用以自动检测和估计真实场景中的地下特征。

关键词: 探地雷达; 地下目标检测; 机器学习; 深度学习; 双曲线反射

中图分类号: TN957.51

文献标识码: A

文章编号: 1009-5896(2020)01-0191-10

DOI: 10.11999/JEIT190680

A Review of Target Detection Algorithm for GPR B-scan Processing

HOU Feifei SHI Ronghua LEI Wentai DONG Jian

XU Mengdi XI Jingchun

(Department of Computer Science and Engineering, Central South University, Changsha 410000, China)

Abstract: Ground Penetrating Radar (GPR), as a non-destructive technology, has been widely used to detect, locate, and characterize subsurface objects. Example applications include underground utility mapping and bridge deck deterioration assessment. However, manually interpreting the GPR scans to detect buried objects and estimate their positions is time-consuming and labor-intensive. Hence, the automatic detection of targets is necessary for practical application. To this end, this paper discusses the feasibility of using GPR to estimate target positions, and reviews the progress made by domestic and international scholars on automatic hyperbolic signature detection in GPR scans. Thereafter, this paper summarizes and compares the processing methods for target detection. It is concluded that future research should focus on developing deep-learning based method to automatically detect and estimate subsurface features for on-site applications.

Key words: Ground Penetrating Radar (GPR); Underground target detection; Machine Learning (ML); Deep Learning (DL); Hyperbolic reflection

1 引言

探地雷达(Ground Penetrating radar, GPR)技术作为一种新兴的无损检测技术, 具有定位准确、速度快、使用灵活、探测精度高等特点, 已被广泛应用于各个领域去探测浅层地下的未知物体^[1]。在军事领域, 涉及的问题包括探测地雷和埋藏爆炸危

险(Buried Explosion Hazard, BEHs)^[2-6]。在土木工程领域, 先进的GPR系统越来越多地用于道路路面监测^[7-9]。最近提出GPR可用于估算土壤中水分含量, 因为道路路面损坏的原因之一通常是结构层中的水或粘土侵入^[10]。在桥梁勘测中, GPR用于测量混凝土厚度, 估算含水量变化并标记或绘制钢筋位置^[11,12]。工程应用主要涉及结构和公用设施的无损检测, 设计可靠的方法收集公用设施的位置信息, 并建模和可视化位置的不确定性, 以防止公用设施罢工^[13-15]。

探地雷达利用地下材料的不同电磁特性, 通过向地面发射高频电磁波并接收返回信号来探测地下区域。此外, GPR B-scan图中的地下目标呈现出一对双曲线形状特征。这样, 地下目标的检测可以

收稿日期: 2019-09-04; 改回日期: 2019-11-12; 网络出版: 2019-11-18

*通信作者: 雷文太 leiwentai@csu.edu.cn

基金项目: 国家自然科学基金(61102139, 61872390), 中南大学基础研究基金(2018zzts181)

Foundation Items: The National Natural Science Foundation of China (61102139, 61872390), The Fundamental Research Funds for the Central Universities of Central South University (2018zzts181)

转化为图像中双曲线的提取。在实际应用中,由于硬件模块噪声,地下介质的不均匀性以及回声波的相互作用,GPR图像通常是有噪声的,因此,自动处理GPR图像并从中提取双曲线是具有挑战性的。在这一领域研究者们已经进行了大量的研究,并采用了许多不同的策略来解决这个问题。

在过去的十年中,Hough变换^[16]技术成功地用于变形形状的拟合。通过在Hough变换中引入加权因子,Borgioli等人^[17]解决了管道靠近时双曲线重叠的问题。Windsor等人^[18]在广义Hough变换方法中记录了一组关联的位置/时间数据对,其与传统的最小二乘(Least Squares, LS)算法协调以解释目标的某些位置参数。通常,这些方法需要预备模型和大的计算成本,这限制了实际情况的进一步应用。与Hough变换不同,可以通过LS方法搜索并区分2次曲线以用于GPR图像。文献^[19-21]中的LS方法专门为双曲线拟合而设计,但是大多数方法只能识别图像中的一条曲线,且由于缺少分割步骤而不适用于多条曲线检测。由于实际情况中无法完全去除噪声,并且图像可能包含多个双曲线,导致LS方法的检测难度大大增加。

近年来,机器学习算法不断涌现,并在GPR图像解译方面取得了一些研究成果,它避免了模板匹配并缩小了包括双曲线在内的搜索区域。文献^[22]在检测过程中通过神经网络对噪声信号进行分类。Maas等人^[23]使用Viola-Jones(VJ)算法^[24]提取GPR数据中的目标区域。对于这些工作,大多数应用特征需要由专家识别,分类结果取决于特征的质量,故随着数据量的增加,这项工作越来越难。

一些文献提出了基于卷积神经网络(Convolutional Neural Network, CNN)^[25]的检测算法,用于分析GPR数据。与机器学习不同,CNN跳过传统的“特征工程”步骤,直接从GPR B-scan中学习埋藏物体的特征表示,如文献^[2-6,26]所述。2015年,Besaw等人^[2]应用CNN从GPR B-scan中提取有意义的特征并对BEH进行分类,并采用几种启发式方法用于防止过度训练,包括交叉验证,网络权重正则化和“dropout”。基于之前的研究,文献^[3]在2016年又实施了数据增强(Data Augmentation, DA)技术,用于增加可用训练集的数量和可变性。文献^[4,5]研究了预训练CNN的初始化步骤,以解决少量标记的GPR数据样本问题。虽然基于CNN的双曲线检测方法在过去两年中得到了迅速发展,但输入网络的真实图像的大小和数量通常是有限的,大多数方法仅实现分类步骤,缺乏目标提取和曲线拟合步骤。文献^[27,28]中都采用了Faster RCNN来识

别灰度GPR B-scan图像的双曲线特征,不仅能判断B-scan是否包含埋藏目标,而且还能框定出候选目标所在区域。

最近,涌现了一些集成系统的研究,能够自动检测和拟合GPR图像的双曲线。在文献^[29]中,提出了列连接聚类(Column-Connection Clustering, C3)算法来将交叉双曲线分开,此外,C3的输出再次通过神经网络进行分类。在该模型中,C3算法水平扫描图像中的每个像素以进行聚类。然而,在GPR B-scan中,双曲线是垂直向下打开的,这个C3算法没有考虑这个重要特征。Zhou等人^[30]提出了开口扫描聚类算法(Open-Scan Clustering Algorithm, OSCA)来解决这个问题。OSCA纵向扫描预处理的二进制图像,该算法不仅可以通过像素的连接还能利用向下开口信息对后选目标进行聚类。因此,OSCA可以识别具有向下开口特征的聚类。然而,在整个图像上进行OSCA算法是不合适的,因为难以处理包含太多非平稳噪声的大型真实数据集,导致后续处理复杂化。另外,上述两种方法都没有解释如何在执行双曲线拟合算法之前自动获得拟合点。本文作者^[28]提出了一种新的双重聚类搜索评估(Double Clustering Seeking Estimation, DCSE)算法,将目标聚类相互分离,实现双曲线特征的识别,在此基础上,能进一步筛选除去具有向下开口的非目标。随后,提出基于列的横向滤波点(Column-based Transverse Filter Points, CTFP)方法从验证的聚类中自动提取双曲线拟合点,为曲线拟合做准备。

本文简要分析GPR目标回波双曲线特征,综述了GPR探测地下目标的研究进展,在对国内外学者大量的研究分析的基础上,对GPR探测地下目标的不同测定方法原理进行介绍并总结,以增进探地雷达对地下目标探测技术的认识与研究。最后在现有问题基础上提出展望。另外,为了便于读者较快掌握当前的GPR研究现状,本文将这些工作的总结展示在表1中,针对不同的方法阐述了其来源、时间,地下目标类型以及优缺点。

2 回波双曲线特征的形成

GPR的发送和接收天线放置在同一设备中。假设有一个埋在地下的物体,探地雷达以水平方向沿地面移动,不断向地下发射脉冲,同时接收物体反射信号。回波构成2维GPR图像,即B-Scan图像。在均匀介质的情况下,点对象(目标具有相对小的横截面)的B-scan图像显示出明显的双曲线特征。形成原因有两个^[31]:首先,GPR反射是一个椭圆锥体,其顶点位于天线的中心^[32],使探测器

表1 GPR目标检测的经典算法总结

序号	参考文献	时间	GPR目标	客观评价
1	Borgioli et al. [17]	2008	地理管道	在Hough变换中引入加权因子, 解决了管道靠近时双曲线重叠的问题; 但是需要预备模型, 计算成本相对较高。
2	Maas et al. [23]	2013	双曲线反射	使用Viola-Jones算法标记目标候选区域, 它避免了模板匹配并缩小了后续搜索区域; 然而, 应用特征需手动识别, 分类结果取决于特征的质量, 难度随着数据量的增加。
3	Besaw et al. [2]	2016	地理爆炸物	应用CNN从GPR B-scan中提取有意义的特征并对目标进行分类。交叉验证, 网络权重正则化和“dropout”用于防止过度训练。
4	Besaw[3]	2016	地理爆炸物	在CNN基础上增加了额外的Data Augmentation技术, 用于增加可用训练数据的数量和可变性。
5	文献[4,5]	2017	地理爆炸物	研究了预训练CNN的初始化步骤, 以解决GPR数据标记样本不足的问题; 但是输入网络中真实图像的大小和数量通常是有限的, 仅实现分类步骤。
6	Pham et al. [27]	2018	双曲线反射	首次采用Faster RCNN来检测GPR B-scan中的反射双曲线。该技术在真实测试集上的性能要超过使用HOG或Haar-like特征的检测器, 但缺少定量的评估。
7	Lei et al. [28]	2019	地理钢筋	在文献[27]基础上, 采用了DA手段增加真实GPR数据集和仿真数据集; 提出DCSE算法以识别双曲线特征, 完善了文献[30]中提出的OSCA算法; 提出CTFP算法自动提取拟合点。所提出方案的有效性在仿真和真实数据集上得到了验证。
8	Dou et al. [29]	2016	双曲线反射	提出了C3算法分割交叉双曲线, 并将其送入神经网络进行分类。C3算法水平扫描B-scan图像中的每个像素以进行聚类。然而, 双曲线是垂直向下打开的, C3算法没有考虑这个重要特征。
9	Zhou et al. [30]	2018	金属管道 水泥管道	提出OSCA算法解决了文献[29]中的难题, 可以识别具有向下开口特征的聚类。然而, 在整个图像上进行OSCA算法是不合适的, 因为难以处理包含太多非平稳噪声的大型现场数据集, 导致后续处理复杂化。

能够检测物体的倾斜方向。其次, 双向时间(即, 电磁(EM)波从发射天线传播到物体并返回到接收天线的时段)由GPR记录并绘制在天线测量信号正下方的雷达扫描中。因此, 当GPR天线向前移动然后远离埋藏的目标时, 反射在雷达扫描中形成双曲线。

为使读者更易理解, 图1展示了真实桥面形成的B-scan图(来源于美国田纳西大学Neyland Greenway桥面)。这是一幅灰度图像, 从图中可以看到整齐排列的双曲线特征, 反映了桥面下钢筋的数量, 位置和大小。GPR图像中的双曲线表示目标对象, 并且双曲线顶点可以计算出来用于表示目标的实际位置。因此, 对地下目标的定位任务可以转换为对B-scan图像中的双曲线进行检测。

3 以前基于传统方法的GPR目标检测

3.1 采用Hough变换法

在过去的十年中, Hough变换[16]技术成功地用




图1 真实场景中GPR B-scan中的双曲线特征

于变形形状的拟合。Capineri等人[33]利用传统的Hough变换方法检测GPR图像中的目标双曲线, 并与一种方法相结合提取双曲线, 目的是简化对GPR图像中复杂模式的解译; 同时计算了双曲线的位置(深度, 水平坐标)和孔径信息。类似于文献[16,33], 在文献[23]中, 在初步定位双曲线所在区域后(即缩小了后续处理面积), 广义Hough变换被用于精确定位双曲线。然而, 使用广义Hough变换算法确定双曲线的参数是耗时的, 因为算法需要在具有至少4维的空间中执行。另外, 广义Hough的准确性变换算法取决于离散化参数, 离散化参数的适度增加可能导致计算时间急剧增加。

当管道接近时, 会导致双曲线重叠, Hough变换提供了一种可能的解决方案。通过在Hough变换中引入加权因子, Borgioli等人[17]解决了管道靠近时双曲线重叠的问题, 其中这个加权因子取决于实验误差参数的差异程度。Windsor等人[18]也提出了一种用于分割目标重叠的方法, 通过在广义Hough变换方法中记录一组关联的位置/时间数据对, 再用传统的LS算法辅助以解译目标的某些参数(位置, 深度, 半径或速度)。

通常, 这些方法需要提前制定模型规格和大的计算成本, 在实际情况中难以推广应用。

3.2 采用最小二乘法

与Hough变换不同, 可以通过LS方法搜索和区分GPR图像中的2次曲线。在文献[19-21]中专门制定了适合双曲线拟合的LS方法, 但是大多数方法

只能识别图像中的一条曲线。由于实际情况中,完全去除噪声是不可能的,且一幅图像可能包含多个曲线,所以在缺少图像分割步骤的前提下,LS方法不适用于多曲线检测。

4 最近基于传统机器学习的GPR目标检测

随着计算机变得更小,更快,更高效,基于机器学习方法去自动检测GPR图像中埋藏目标的可能性更大,这避免了模板匹配并缩小了包括双曲线在内的搜索区域,减轻了现场操作人员的负担。

4.1 采用VJ算法

Maas等人^[23]使用VJ算法^[24]提取GPR数据中的目标区域。VJ算法包含以下几个重要的部分:利用Haar特征描述双曲线的共有属性;建立了一种称为积分图像的特征,并且基于积分图像,可以快速获取几种不同的矩形特征;利用Adaboost算法进行训练;为GPR B-scan目标检测模型建立层级分类器。得到分类结果后,采用Canny法进行边缘检测,接着利用Hough变换检测间断点边界形状(即目标双曲线)。

4.2 采用SVM算法

Pasolli等人^[34,35]设计了一种基于遗传算法(Genetic Algorithm, GA)的技术,用于在二进制图像中识别地下物体的线性和双曲线特征。通过使用这些提取的特征,使用支持向量机(Support Vector Machine, SVM)分类器将它们分类为线性或双曲线形状。文献^[11]避免了常规的边缘检测,阈值分割和模板匹配等手工操作,将机器学习分类法应用到GPR桥面数据上。具体操作是提取方向梯度直方图(Histogram of Oriented Gradient, HOG)特征,作为SVM分类器的输入初步得到候选框定目标。对比其他基于梯度/强度的特征向量,提取HOG特征更适合桥梁内嵌钢筋的分类。在GPR桥梁领域采用机器学习手段的优势是,当来自同一个桥面的数据拿来训练框架时,这个训练好的模型可以被重复利用。

4.3 浅层神经网络

在文献^[22]的检测过程中,采用神经网络对噪声信号进行分类,将其与目标剥离。这里的神经网络框架是一个多层的前馈神经网络,包含输入变量,一个隐藏层和输出变量。文献^[36]研究了3层全连接网络检测钢筋的存在,钢筋大小和深度的能力,并证明了使用神经网络方法来解译复杂的地下嵌入式钢筋是有希望的。Dou等人^[29]在对GPR目标双曲线聚类后,手动选择正/负样本,计算双曲线的两个归一化互关联值,送入自己搭建的3层感知神经网络进行训练分类进一步筛选目标,然后对最

终目标进行双曲线拟合。在文献^[37]中,Al-Nuaimy等人开发了一种自动系统,可识别GPR图像中的固体对象,如管道和杀伤地雷。在算法的第1步中,使用特征提取和神经网络(Neural Network, NN)分类来分割GPR图像。第2步骤利用边缘检测和模式识别进一步处理被分类为目标反射的区域,以识别被研究物体的精确位置。在文献^[38]中,实施了一些预处理步骤,旨在增强埋藏目标特征的可视化。接着,基于NN的检测器执行了自动的图像解译步骤。Al-Nuaimy和Shihab等人^[39-43]开发了許多GPR的自动检测和解译方法,如神经网络技术。Shaw等人^[44]使用神经网络方法自动化后处理步骤,并提出了一种估算钢筋直径的新技术。Shaw等人^[45]继之前的研究,使用边缘检测算法将雷达数据简化。使用多层感知器(Multi-Layer Perceptron, MLP)检测来自钢筋的信号反射,以识别简化双曲线形状。结果表明,使用MLP神经网络可以非常有效地实现嵌入式钢筋识别和定位的自动化。

5 最新基于深度学习的GPR目标检测

对于上述工作,大多数输入特征需要由专家识别,分类结果取决于特征的质量,随着数据量的增加,这项工作越来越难。机器学习的最新进展,特别是深度学习人工神经网络,已经导致模式识别任务中的性能显著提高。不像机器学习,深度学习跳过了“特征工程”步骤,能直接从2维数据中学习埋藏物体的特征表示。

5.1 基于CNN

一些研究提出了基于CNN^[25]的检测算法,用于分析GPR数据,CNN可以提取有意义的特征并准确分类GPR图像中包含的复杂特征。2015年,Besaw等人^[2]应用CNN从GPR B-scan中提取有意义的特征并对埋藏爆炸物进行分类。在论文中,几种启发式方法用于防止过度训练,包括交叉验证,网络权重正则化和“dropout”(在每个训练批次中,通过忽略一半的特征检测器,可以明显地减少过拟合现象)。在上述研究的基础上,文献^[3]在2016年增加了额外的技巧DA,这是一种广泛应用的技术,用于增加GPR训练数据的数量和可变性,可以为CNN和传统特征提取算法带来显著的性能优势,并拓展此方法对反坦克地雷和反人类地雷两种类型进行分类,提高分类精度。文献^[4,5]研究了预训练CNN的初始化步骤,以解决用于目标检测的GPR样本标记匮乏的问题。Dinh等人^[12]提出的方案整合了常规的图像处理方法和深度CNN,先使用图像处理方法(零时校正,迁移,滤波和阈值分割)找到候选目标双曲线的顶点;然后根据定点取出固定大

小的区域，相当于初次筛选目标，随之分为正例和负例样本；将步骤2得到目标区域提取出来，送入训练好的CNN中，将训练好的深度模型用来测试数据集。在文献[26]中使用CNN将地雷与其他埋藏目标(例如，杂波)区分开。文献[46]侧重判断GPR图像中是否包含潜在爆炸物。在文献[47]中，提出了一种利用CNN的地雷探测算法，能够直接从GPR图像中学习埋藏目标的特征，而不是强加任何模型或手工制作的特征。而且，所提出的方法在不同的CNN架构上进行了测试，均能以高精度处理较小的图像块，为精确的目标定位做了铺垫。文献[48]基于对CNN的深入了解，为了确定危险物的存在，在框架中引入了预训练的初始化步骤和数据增强技巧，讨论了3种不同的CNN框架，有助于实现更高的目标检测性能。

虽然基于CNN的目标检测方法在过去两年中得到了迅速改进，但输入GPR现场图像的大小和数量通常是有限的，大多数方法仅实现分类步骤，缺乏目标提取和曲线拟合方法。

5.2 基于Faster RCNN

文献[27]首次采用Faster RCNN框架来检测GPR B-scan中的反射双曲线。使用gprMax工具箱^[49]模拟生成更多不同配置的GPR仿真图以解决真实数据集匮乏的问题。首先，将CNN在灰度Cifar-10数据库^[50]上进行了预训练；然后，将预训练好CNN作为Faster RCNN的分类框架，在真实和模拟的GPR数据上进行训练和微调。该技术在真实测试集上的性能要超过使用HOG或Haar-like特征的检测器，但缺少定量的评估。

本文作者^[28]更深入地研究了这个问题。提出了一种自动化方案来定位GPR B-scan中的双曲线目标，可分为4个部分：(1) 将Faster RCNN应用于GPR B-scan中双曲线检测。Faster RCNN可以准确框定目标所在的区域，那么随后的处理将只在几个矩形区域内而不是整个图像上操作，这缩小了处理区域更易于获得双曲线聚类。此外，由于缺乏训练数据，还采用了DA技巧增加真实数据集和仿真数据集。(2) 然后，取出矩形区域并将其变换为二值图像，并通过形态学操作去除离散的噪声点。(3) 随后，提出DCSE算法分别两次扫描二进制图像以识别双曲线特征。(4) 最后，CTFP算法被提出，目的是从验证的聚类中自动提取拟合点，然后应用于双曲线拟合，进一步估计目标位置。所提出的方案能够自动且有效地从GPR B-scan中提取信息，分别在仿真和真实数据集的分析中得到了验证。

6 后处理方案综述

只利用上述对目标分类或目标区域初步检测的研究，还远不能得到最终想要的结果。另外，还需要两大后续处理步骤，分别是：聚类算法(用以分割双曲线)，双曲线拟合算法(用以定位顶点)。

6.1 聚类算法的演变

当处理GPR图像时，利用聚类算法将点分类为不同的点聚类。先前的聚类算法要么基于点之间的距离^[51,52]，要么基于某个区域内的点密度^[53,54]。但它们不能分割连接区域或者交叉的双曲线。

在文献[29]中，提出的系统由4个阶段组成：(1) 预处理过程；(2) 基于边缘检测的结果自动选择阈值；(3) 提出了C3算法来将感兴趣区域(RoI)分成不同的聚类；(4) 此外，C3的输出再次通过基于神经网络的方法进行分类。在该模型中，C3算法是基于同一行的相邻列的元素的匹配序列，原理是水平扫描GPR B-scan中的每个像素以进行聚类。该算法不仅能聚类独立的双曲线特征还能将交叉连接的双曲线分开。

直观地，GPR图像中的双曲线具有顶部，两个对称尾部和向下开口的特征，并且这些特征可以用于识别聚类是否为双曲线。由于存在噪声，两个尾部可能是不完整的并且不完全对称，但是向下开口总是存在，这是识别双曲线的关键特征。

然而，C3算法没有考虑这个重要特征。Zhou等人^[30]的工作包括4个部分：(1) 预处理算法；(2) OSCA聚类算法；(3) 基于抛物线拟合判断法(Parabolic Fitting-based Judgment, PFJ)；(4) 有限代数距离拟合法(Restricted Algebraic-Distance-based Fitting, RADF)。其中，提出的OSCA算法利用了该向下开口特征，弥补了C3算法的不足。OSCA纵向扫描预处理的二进制图像，不仅利用了像素的连接，还通过开口信息进行聚类。因此，OSCA可以识别具有向下开口特征的聚类。然而，好多复杂的聚类情况(见图2)没有被考虑进OSCA算法中，比如：非目标聚类也可能存在向下开口；在向下开口聚类的左/右腿上可能存在多个分支；来自同一个向下开口的两个腿在终点处重叠。

DCSE在文献[28]中被提出来，解决了上述3种情况，用于补充完善OSCA算法。这个算法开展了两次向下开口的搜索，第1轮搜索出所有的开口并设置阈值，以消除不规则区域；第2轮在此基础上，重新搜索开口并标记，依次遍历这些开口并按照设定的规则进行处理，得到的结果既消除了非目标聚类且分割了交叉的目标。图3给出了两个聚类算法(DCSE和OSCA)得到的对比结果，从而展现DCSE算法的优势。

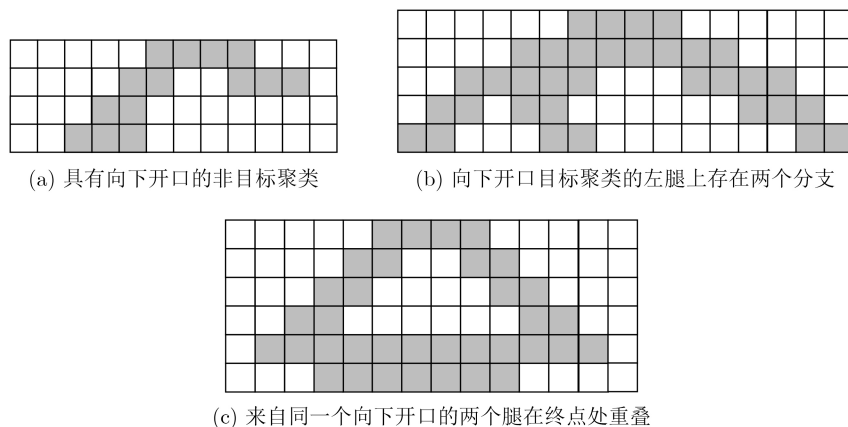


图2 在文献[28]中解决的一些复杂情况示例




图3 DCSE和OSCA算法的对比结果展示

6.2 双曲线拟合算法的演变

为获得目标的准确评估, 双曲线拟合算法也是GPR实现目标定位的一个重要组成成分。现有大量的拟合算法^[19,55-58], 被分为两大类: 基于代数距离的拟合算法(Algebraic Distance-based Fitting, ADF)和基于正交距离的拟合算法(Orthogonal Distance-based Fitting, ODF)。

文献[59]基于分类期望最大化算法, 将一个快速ADF算法合并到概率混合模型, 并将该模型应用于GPR空间数据解译。在文献[30]中, 通过对双曲线开口范围和顶点所在位置的限定, 并基于广义ADF算法, 提出了RADF算法, 有效地拟合了双曲线的下半部分。基于双曲线是特殊的2次曲线, 这里将拟合问题公式转化为一个隐式2阶多项式的受限的最小二乘法问题, 加入的限定条件/参数由OSCA和PFJ算法得到, 可以得到高准确率的拟合结果并能减少拟合时间。对比于代数距离, 正交距离具有欧几里得空间转换的不变性, 因此正交距离拟合算法更具有鲁棒性和准确性。文献[60]通过纳入基于ODF算法的双曲线拟合算法进入概率混合模型, 提出的算法可以实时识别GPR数据中的双曲线并计算埋设公用设施的深度和大小。在文献[29]中, 给向下开口的双曲线中引入了一个最小二乘ODF

算法。拟合算法的有效性使得这个系统更适合实时的现场应用。另外, 提出了一个新的方法直接利用给出的点计算原始的双曲线参数。即使只有3个点被用来计算参数, 那与给出的点也是接近的。对比于ADF结果, 提出来的方法计算原始双曲线通常更接近于最后的拟合结果。这两种类型的算法都有优势。当点分布是离散的, 这两种算法都能实现可接受的结果。对于密集分布的点, 常规的拟合算法没有限制的话, 得到的结果就差强人意了。

以上算法在得到聚类后, 利用给出的样本点直接进行曲线拟合, 都没有解释这些待拟合样本点是如何获取的, 并不能真正满足自动化需求。文献[28]中提出的CTFP算法解决了这个关键性的问题。在经过DCSE算法后验证得到目标聚类, 采用CTFP算法自动提取每一列的中值点。具体操作: 遍历聚类的每一列, 分别找到上边界点和下边界点, 求其均值, 初步得到候选样本点; 由于噪声和地下反射干扰, 这些点可能包含异常点, 为了使曲线拟合更平滑, 随后采用了低通滤波器对拟合点进行平滑处理, 最终得到样本点, 为接下来的双曲线拟合做准备。如图4所示, 在存在少数异常值的情况下, 通过使用CTFP算法选择拟合点, 双曲线拟合得到改善, 并且正确找到了峰值。

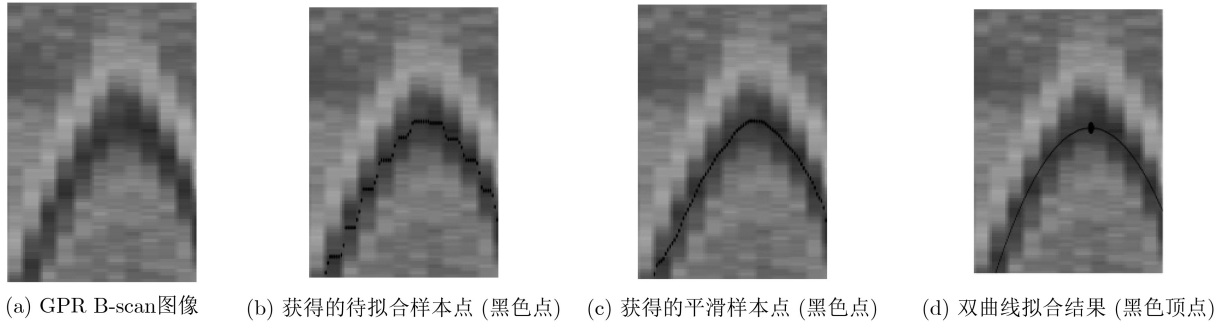


图4 基于CTFP算法的双曲线拟合结果展示

7 结束语

GPR一直是土木工程领域的重要工具，对GPR图像的处理本质都是在B-scan中获取有用信息以解决各种实际问题。随着数字图像处理技术的飞速发展，本文系统分析了GPR图像中埋藏目标检测的研究进展。对于传统的GPR目标检测方法，存在目标特征提取不完全，误报和漏报等现象。与传统手段相比，结合深度学习的新方案在实时检测和目标定位方面更加准确和稳健。GPR未来的发展方向将专注于针对目标检测的最新深度学习框架，形成一整套自动化方案，在准确性和速度方面实现更大的改进，并深入到工程领域的各个方面，从而改变传统的交互方式。该领域的快速发展有利于提高我国在高新工程领域的国际地位，人们应对此发展保持积极态度，并且期望在未来几十年中更广泛地使用该技术。

参考文献

- [1] JOL H M. 雷文太, 童孝忠, 周昉, 译. 探地雷达理论与应用[M]. 北京: 电子工业出版社, 2011.
JOL H M. LEI Wentai, TONG Xiaozhong, ZHOU Yang, translation. Ground Penetrating Radar: Theory and Applications[M]. Beijing: Publishing House of Electronics Industry, 2011.
- [2] BESAW L E and STIMAC P J. Deep convolutional neural networks for classifying GPR B-Scans[J]. *SPIE*, 2015, 9454: 945413.
- [3] BESAW L E. Detecting buried explosive hazards with handheld GPR and deep learning[J]. *SPIE*, 2016, 9823: 98230N. doi: [10.1117/12.2223797](https://doi.org/10.1117/12.2223797).
- [4] BRALICH J, REICHMAN D, COLLINS L M, *et al.* Improving convolutional neural networks for buried target detection in ground penetrating radar using transfer learning via pretraining[J]. *SPIE*, 2017: 10182.
- [5] REICHMAN D, COLLINS L M, and MALOF J M. Some good practices for applying convolutional neural networks to buried threat detection in Ground Penetrating Radar[C]. The 9th International Workshop on Advanced Ground Penetrating Radar, Edinburgh, UK, 2017: 1–5.
- [6] LAMERI S, LOMBARDI F, BESTAGINI P, *et al.* Landmine detection from GPR data using convolutional neural networks[C]. The 25th European Signal Processing Conference, Kos, Greece, 2017: 508–512.
- [7] BENEDETTO A, BENEDETTO F, DE BLASII S M R, *et al.* Reliability of radar inspection for detection of pavement damage[J]. *Road Materials and Pavement Design*, 2004, 5(1): 93–110. doi: [10.1080/14680629.2004.9689964](https://doi.org/10.1080/14680629.2004.9689964).
- [8] LEI Wentai, SHI Ronghua, DONG Jian, *et al.* A multi-scale weighted back projection imaging technique for ground penetrating radar applications[J]. *Remote Sensing*, 2014, 6(6): 5151–5163. doi: [10.3390/rs6065151](https://doi.org/10.3390/rs6065151).
- [9] LEI Wentai, ZENG Sheng, ZHAO Jian, *et al.* An improved back projection imaging algorithm for subsurface target detection[J]. *Turkish Journal of Electrical Engineering & Computer Sciences*, 2013, 21(6): 1820–1826.
- [10] BENEDETTO F and TOSTI F. GPR spectral analysis for clay content evaluation by the frequency shift method[J]. *Journal of Applied Geophysics*, 2013, 97: 89–96. doi: [10.1016/j.jappgeo.2013.03.012](https://doi.org/10.1016/j.jappgeo.2013.03.012).
- [11] KAUR P, DANA K J, ROMERO F A, *et al.* Automated GPR rebar analysis for robotic bridge deck evaluation[J]. *IEEE Transactions on Cybernetics*, 2016, 46(10): 2265–2276. doi: [10.1109/TCYB.2015.2474747](https://doi.org/10.1109/TCYB.2015.2474747).
- [12] DINH K, GUCUNSKI N, and DUONG T H. An algorithm for automatic localization and detection of rebars from GPR data of concrete bridge decks[J]. *Automation in Construction*, 2018, 89: 292–298. doi: [10.1016/j.autcon.2018.02.017](https://doi.org/10.1016/j.autcon.2018.02.017).
- [13] YUAN Chenxi, LI Shuai, CAI Hubo, *et al.* GPR signature detection and decomposition for mapping buried utilities with complex spatial configuration[J]. *Journal of Computing in Civil Engineering*, 2018, 32(4): 04018026. doi: [10.1061/\(ASCE\)JCCP.2018.04018026](https://doi.org/10.1061/(ASCE)JCCP.2018.04018026).

- 10.1061/(ASCE)CP.1943-5487.0000764.
- [14] LI Shuai, CAI Hubo, and KAMAT V R. Uncertainty-aware geospatial system for mapping and visualizing underground utilities[J]. *Automation in Construction*, 2015, 53: 105–119. doi: [10.1016/j.autcon.2015.03.011](https://doi.org/10.1016/j.autcon.2015.03.011).
- [15] LI Shuai, CAI Hubo, ABRAHAM D M, *et al.* Estimating features of underground utilities: Hybrid GPR/GPS approach[J]. *Journal of Computing in Civil Engineering*, 2016, 30(1): 04014108. doi: [10.1061/\(ASCE\)CP.1943-5487.0000443](https://doi.org/10.1061/(ASCE)CP.1943-5487.0000443).
- [16] ILLINGWORTH J and KITTLER J. A survey of the Hough transform[J]. *Computer Vision, Graphics, and Image Processing*, 1988, 43(2): 280.
- [17] BORGIOLO G, CAPINERI L, FALORNI P, *et al.* The detection of buried pipes from time-of-flight radar data[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2008, 46(8): 2254–2266. doi: [10.1109/tgrs.2008.917211](https://doi.org/10.1109/tgrs.2008.917211).
- [18] WINDSOR C G, CAPINERI L, and FALORNI P. A data pair-labeled generalized Hough transform for radar location of buried objects[J]. *IEEE Geoscience and Remote Sensing Letters*, 2014, 11(1): 124–127. doi: [10.1109/LGRS.2013.2248119](https://doi.org/10.1109/LGRS.2013.2248119).
- [19] BOOKSTEIN F L. Fitting conic sections to scattered data[J]. *Computer Graphics and Image Processing*, 1979, 9(1): 56–71. doi: [10.1016/0146-664x\(79\)90082-0](https://doi.org/10.1016/0146-664x(79)90082-0).
- [20] AKIMA H. A method of bivariate interpolation and smooth surface fitting for irregularly distributed data points[J]. *ACM Transactions on Mathematical Software*, 1978, 4(2): 148–159. doi: [10.1145/355780.355786](https://doi.org/10.1145/355780.355786).
- [21] PORRILL J. Fitting ellipses and predicting confidence envelopes using a bias corrected Kalman filter[J]. *Image and Vision Computing*, 1990, 8(1): 37–41. doi: [10.1016/0262-8856\(90\)90054-9](https://doi.org/10.1016/0262-8856(90)90054-9).
- [22] YOUN H S and CHEN C C. Automatic GPR target detection and clutter reduction using neural network[J]. *SPIE*, 2002, 4758: 579–582. doi: [10.1117/12.462229](https://doi.org/10.1117/12.462229).
- [23] MAAS C and SCHMALZL J. Using pattern recognition to automatically localize reflection hyperbolas in data from ground penetrating radar[J]. *Computers & Geosciences*, 2013, 58: 116–125. doi: [10.1016/j.cageo.2013.04.012](https://doi.org/10.1016/j.cageo.2013.04.012).
- [24] VIOLA P and JONES M J. Robust real-time face detection[J]. *International Journal of Computer Vision*, 2004, 57(2): 137–154. doi: [10.1023/b:visi.0000013087.49260.fb](https://doi.org/10.1023/b:visi.0000013087.49260.fb).
- [25] KRIZHEVSKY A, SUTSKEVER I, and HINTON G E. ImageNet classification with deep convolutional neural networks[J]. *Communications of the ACM*, 2017, 60(6): 84–90. doi: [10.1145/3065386](https://doi.org/10.1145/3065386).
- [26] WITTEN T R. Present state of the art in ground-penetrating radars for mine detection[J]. *SPIE*, 1998, 3392.
- [27] PHAM M T and LEFÈVRE S. Buried object detection from B-scan ground penetrating radar data using Faster-RCNN[C]. 2018 IEEE International Geoscience and Remote Sensing Symposium, Valencia, Spain, 2018: 6804–6807.
- [28] LEI Wentai, HOU Feifei, XI Jingchun, *et al.* Automatic hyperbola detection and fitting in GPR B-scan image[J]. *Automation in Construction*, 2019, 106: 102839. doi: [10.1016/j.autcon.2019.102839](https://doi.org/10.1016/j.autcon.2019.102839).
- [29] DOU Qingxu, WEI Lijun, MAGEE D R, *et al.* Real-time hyperbola recognition and fitting in GPR data[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, 55(1): 51–62. doi: [10.1109/tgrs.2016.2592679](https://doi.org/10.1109/tgrs.2016.2592679).
- [30] ZHOU Xiren, CHEN Huanhuan, and LI Jinlong. An automatic GPR B-Scan image interpreting model[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 56(6): 3398–3412. doi: [10.1109/TGRS.2018.2799586](https://doi.org/10.1109/TGRS.2018.2799586).
- [31] TANOLI W A, SHARAFAT A, and PARK J, *et al.* Damage Prevention for underground utilities using machine guidance[J]. *Automation in Construction*, 2017, 107: 102893.
- [32] YALÇINER C C, BANO M, KADIOGLU M, *et al.* New temple discovery at the archaeological site of Nysa (western Turkey) using GPR method[J]. *Journal of Archaeological Science*, 2009, 36(8): 1680–1689. doi: [10.1016/j.jas.2008.12.016](https://doi.org/10.1016/j.jas.2008.12.016).
- [33] CAPINERI L, GRANDE P, and TEMPLE J A G. Advanced image-processing technique for real-time interpretation of ground-penetrating radar images[J]. *International Journal of Imaging Systems and Technology*, 1998, 9(1): 51–59. doi: [10.1002/\(SICI\)1098-1098\(1998\)9:1<51::AID-IMA7>3.0.CO;2-Q](https://doi.org/10.1002/(SICI)1098-1098(1998)9:1<51::AID-IMA7>3.0.CO;2-Q).
- [34] PASOLLI E, MELGANI F, DONELLI M, *et al.* Automatic detection and classification of buried objects in GPR images using genetic algorithms and support vector machines[C]. 2008 IEEE International Geoscience and Remote Sensing Symposium, Boston, USA, 2008: II-525–II-528.
- [35] PASOLLI E, MELGANI F, and DONELLI M. Automatic analysis of GPR images: A pattern-recognition approach[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2009, 47(7): 2206–2217. doi: [10.1109/TGRS.2009.2012701](https://doi.org/10.1109/TGRS.2009.2012701).
- [36] MOLYNEAUX T C K, MILLARD S G, BUNGEY J H, *et al.* Radar assessment of structural concrete using neural networks[J]. *NDT & E International*, 1995, 28(5): 281–288.

- [37] AL-NUAIMY W, HUANG Y, NAKHKASH M, *et al.* Automatic detection of buried utilities and solid objects with GPR using neural networks and pattern recognition[J]. *Journal of Applied Geophysics*, 2000, 43(2/4): 157–165.
- [38] GAMBA P and LOSSANI S. Neural detection of pipe signatures in ground penetrating radar images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2000, 38(2): 790–797. doi: [10.1109/36.842008](https://doi.org/10.1109/36.842008).
- [39] AL-NUAIMY W, HUANG Y, NAKHKASH M, *et al.* Neural network for the automatic detection of buried utilities and landmines[C]. 1998 Progress of Electromagnetic Research Symposium, Nantes, France, 1998: 141.
- [40] SHIHAB S, AL-NUAIMY W, HUANG Y, *et al.* Automatic region-based shape discrimination of ground penetrating radar signatures[C]. 2003 Symposium on the Application of Geophysics to Environmental and Engineering Problems SAGEEP 2003, San Antonio, USA, 2003.
- [41] AL-NUAIMY W, LU Huihai, SHIHAB S, *et al.* Automatic mapping of linear structures in 3-dimensional space from ground-penetrating radar data[C]. 2001 IEEE/ISPRS Joint Workshop on Remote Sensing and Data Fusion over Urban Areas, Rome, Italy, 2001: 198–201.
- [42] SHIHAB S, AL-NUAIMY W, and ERIKSEN A. Image processing and neural network techniques for automatic detection and interpretation of ground penetrating radar data[C]. The 6th WSEAS, Crete, 2002.
- [43] AL-NUAIMY W, HUANG Yi, ERIKSEN A, *et al.* Automatic detection of hyperbolic signatures in ground-penetrating radar data[J]. *SPIE*, 2001, 4491: 327.
- [44] SHAW M R, MOLYNEAUX T C K, MILLARD S G, *et al.* Assessing bar size of steel reinforcement in concrete using ground penetrating radar and neural networks[J]. *Insight - Non-Destructive Testing and Condition Monitoring*, 2003, 45(12): 813–816. doi: [10.1784/insi.45.12.813.52980](https://doi.org/10.1784/insi.45.12.813.52980).
- [45] SHAW M R, MILLARD S G, MOLYNEAUX T C K, *et al.* Location of steel reinforcement in concrete using ground penetrating radar and neural networks[J]. *NDT & E International*, 2005, 38(3): 203–212.
- [46] LAMERI S, LOMBARDI F, BESTAGINI P, *et al.* Landmine detection from GPR data using convolutional neural networks[C]. The 25th European Signal Processing Conference, Kos, Greece, 2017.
- [47] BENGIO Y. Learning deep architectures for AI[J]. *Foundations and Trends® in Machine Learning*, 2009, 2(1): 1–127. doi: [10.1561/2200000006](https://doi.org/10.1561/2200000006).
- [48] REICHMAN D, COLLINS L M, and MALOF J M. Some good practices for applying convolutional neural networks to buried threat detection in Ground Penetrating Radar[C]. The 9th International Workshop on Advanced Ground Penetrating Radar, Edinburgh, UK, 2017.
- [49] WARREN C, GIANNOPOULOS A, and GIANNAKIS I. GprMax: Open source software to simulate electromagnetic wave propagation for Ground Penetrating Radar[J]. *Computer Physics Communications*, 2016, 209: 163–170. doi: [10.1016/j.cpc.2016.08.020](https://doi.org/10.1016/j.cpc.2016.08.020).
- [50] KRIZHEVSKY A. Learning multiple layers of features from tiny images[R]. Technical Report TR-2009, 2009: 1–60.
- [51] KANUNGO T, MOUNT D M, NETANYAHU N S, *et al.* An efficient k-means clustering algorithm: Analysis and implementation[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2002, 24(7): 881–892. doi: [10.1109/TPAMI.2002.1017616](https://doi.org/10.1109/TPAMI.2002.1017616).
- [52] NG R T and HAN Jiawei. Efficient and effective clustering methods for spatial data mining[C]. The 20th International Conference on Very Large Data Bases, Birmingham, USA, 1994: 144–155.
- [53] ESTER M, KRIEGEL H P, SANDER J, *et al.* A density-based algorithm for discovering clusters a density-based algorithm for discovering clusters in large spatial databases with noise[C]. The 2nd International Conference on Knowledge Discovery and Data Mining, Portland, Oregon, 1996: 226–231.
- [54] ERTÖZ L, STEINBACH M, and KUMAR V. Finding clusters of different sizes, shapes, and densities in noisy, high dimensional data[C]. The 2nd SIAM International Conference on Data Mining, 2003.
- [55] AHN S J, RAUH W, and WARNECKE H J. Least-squares orthogonal distances fitting of circle, sphere, ellipse, hyperbola, and parabola[J]. *Pattern Recognition*, 2001, 34(12): 2283–2303. doi: [10.1016/S0031-3203\(00\)00152-7](https://doi.org/10.1016/S0031-3203(00)00152-7).
- [56] FITZGIBBON A, PILU M, and FISHER R B. Direct least square fitting of ellipses[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1999, 21(5): 476–480. doi: [10.1109/34.765658](https://doi.org/10.1109/34.765658).
- [57] GANDER W, GOLUB G H, and STREBEL R. Least-squares fitting of circles and ellipses[J]. *BIT Numerical Mathematics*, 1994, 34(4): 558–578. doi: [10.1007/BF01934268](https://doi.org/10.1007/BF01934268).
- [58] PILU M, FITZGIBBON A W, and FISHER R B. Ellipse-specific direct least-square fitting[C]. The 3rd IEEE International Conference on Image Processing, Lausanne, Switzerland, 1996: 599–602.

- [59] CHEN Huanhuan and COHN A G. Probabilistic conic mixture model and its applications to mining spatial ground penetrating radar data[C]. The Workshops in SIAM Conference on Data Mining, 2010: 1-9.
- [60] CHEN Huanhuan and COHN A G. Probabilistic robust hyperbola mixture model for interpreting ground penetrating radar data[C]. 2010 International Joint Conference on Neural Networks, Barcelona, Spain, 2010:

1-8.

侯斐斐: 女, 1993年生, 博士生, 研究方向为探地雷达, 深度学习, 图像处理.

施荣华: 男, 1963年生, 教授, 博士生导师, 研究方向为射频系统集成和量子技术.

雷文太: 男, 1979年生, 副教授, 博士生导师, 研究方向为探地雷达系统集成和信号处理.