

基于深度学习的 GPR B-SCAN 图像 双曲线检测方法

王 辉^{1,2}, 欧阳缮¹, 廖可非¹, 晋良念¹

(1. 桂林电子科技大学信息与通信学院, 广西桂林 541004; 2. 贺州学院人工智能学院, 广西贺州 542899)

摘 要: 利用深度学习方法来处理探地雷达 (Ground Penetrating Radar, GPR) 数据以提高 GPR B-SCAN 双曲线检测准确率. 为了解决数据集样本不够的问题采用循环生成对抗网络 (Cycle Generative Adversarial Networks, CycleGAN) 算法对 GPR B-SCAN 图像数据进行增强. 采用 Faster R-CNN 算子来定位双曲线图像区域, 充分利用双曲线结构对称性及其方向差异性特征, 设计与之对应的卷积核模板, 通过卷积运算实现对 B-SCAN 图像中双曲线目标的有效分割. 对双曲线目标采用最小二乘法进行二次曲线拟合得到精确的双曲线图像. 与基于迁移学习的方法、HOG 算法以及基于 Hough 变换的 B-SCAN 检测算法等相比, 本文方法得到的结果在综合指标度量 F 上是最优的.

关键词: 深度学习; 探地雷达; 循环对抗生成网络; 卷积运算

中图分类号: TP391.41 **文献标识码:** A **文章编号:** 0372-2112 (2021)05-0953-11

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20200635

GPR B-SCAN Image Hyperbola Detection Method Based on Deep Learning

WANG Hui^{1,2}, OUYANG Shan¹, LIAO Ke-fei¹, JIN Liang-nian¹

(1. School of Information and Communication, Guilin University of Electronic Technology, Guilin, Guangxi 541004, China;

2. School of Artificial Intelligence Hezhou University, Hezhou, Guangxi 542899, China)

Abstract: In order to improve the accuracy of GPR (ground penetrating radar) B-SCAN hyperbola detection, the deep learning method is applied to the processing of GPR data. In order to solve the problem of insufficient samples in the data set, the GPR B-SCAN image data is augmented by using cycle generative adversarial networks algorithm (CycleGAN). The Faster R-CNN operator is used to locate the hyperbolic image area, making full use of the symmetry of the hyperbolic structure and its directional difference characteristics, designing the corresponding convolution kernel template, and realize effective segmentation of hyperbolic targets in B-SCAN images through convolution operation. The least square method is used to perform quadratic curve fitting on the hyperbolic target to obtain an accurate hyperbolic image. Compared with B-SCAN image detection algorithms such as transfer learning-based methods, HOG (histogram of oriented gradients) algorithm and Hough transform algorithm, the results obtained by the method in this paper are optimal on the comprehensive measurement index F .

Key words: deep learning; ground penetrating radar; cycle generative adversarial networks; convolution operation

1 引言

探地雷达 (GPR) 是一种无损的遥感探测技术, 其在地下物体探测上有着很好的性能表现, 被广泛应用于地下目标成像, 如探测地雷和埋藏爆炸危险物、地下管线检测及道路路面监测等^[1-3]. GPR 天线向地面发射电磁脉冲, 接收天线记录每个探测位置的时间序列即

A-SCAN, 将多道 A-SCAN 数据进行组合形成探测目标的截面图像即 B-SCAN. 同时, 基于反射测量模式得到的 GPR B-SCAN 图像具有双曲线几何特征^[4], 因此可以将 GPR 地下目标的探测转化为 B-SCAN 图像上双曲线的检测及识别的问题.

GPR B-SCAN 双曲线检测通常是先定位双曲线在 B-SCAN 图像中所处区域范围, 也称为感兴趣区域提取

(Region of Interest, ROI), 再从 ROI 中分割出双曲线. Chen^[5]等采用统计的方法先定位 ROI 区域再通过改进的 Hough 变换实现 GPR 目标检测. LIU^[6]等利用双曲线图像具有开口向下的对称特征先检测双曲线顶点再对双曲线进行拟合. 基于机器视觉的方法, 如 HOG (Histogram of Oriented Gradients) 算法^[7]、Haar-like 算法^[8]等将图像描述方法应用于双曲线特征表达, 但这些传统方法需要人工花费大量精力进行物体特征的设计, 其检测结果在完整性及准确率等方面并不理想. 近年来, 鉴于深度卷积神经网络在光学图像处理上取得了突破性的性能表现, 越来越多的学者开始将深度学习的方法应用到 GPR 数据处理上, 并在军事及公用基础设施的 GPR 无损检测等领域开展了广泛研究^[9-12]. 深度卷积神经网络通过构造正负样本集来训练网络模型, 并自动从训练样本中学习提取物体的高级特征. 针对 GPR 地下目标检测问题, 已有相关研究表明与人工设计特征相比卷积神经网络在提取物体特征的精确度上更具优势^[13]. 基于深度学习的图像 ROI 检测算法中, Faster R-CNN^[14]是近年来提出的最为有效的算法之一, 算法在生成候选区域时使用了 RPN (Region Proposal Network) 网络, 不仅速度快, 而且获得的结果更加精确, 已在诸多行业得到广泛应用^[15-17]. 但基于深度学习的 GPR 目标检测方法通常需要大量样本集数据来训练网络模型, 而在实际的 GPR 应用领域要获得大量的测量数据是非常困难的. 数据增强是扩展有限样本集的一种有效方法, Lei^[18]等将光学图像数据增强的常用方法, 例如, 在水平和垂直方向上翻转, 尺度变换, 旋转及灰度变换等用于 GPR 数据增强, 并采用迁移学习的方法来检测 GPR B-SCAN 图像中的双曲线, 但因为 GPR 与光学图像的成像机制不同且由于地质环境的复杂性 (如温湿度的变化及介质的非均匀性等) 这种方法得到的结果还不能令人满意.

目前, 生成对抗网络 (GAN)^[19] 是图像生成领域的一个研究热点, 在光学图像及医学图像数据增强等方面都取得了较大成功^[20-22], 同时为了解决对抗生成网络稳定性以及满足对生成数据多样性的需求, 相关学者提出了一系列改进的 GAN, 如 DCGAN、WGAN 及 CycleGAN^[23] 等, 这为我们利用生成对抗网络来增强 GPR B-SCAN 图像数据提供了很好的参考. 本文采用 CycleGAN 算法对 GPR B-SCAN 图像数据进行增强处理, 并在 GPR Hyperbola^[24] 数据库上进行了实验. 在获得大量 GPR 图像数据的基础上, 利用 Faster R-CNN 算子定位 GPR B-SCAN 图像中双曲线所处区域, 同时提出了一种基于卷积运算的双曲线特征快速分割方法并采用小二乘法进行拟合得到准确的双曲线图像.

2 GPR B-SCAN 图像数据增强的网络模型构建

2.1 GPR 目标成像的物理机制

GPR 向地下发射探测脉冲并接收对应回波的一道测试数据如下图 1(a) 所示, 随着 GPR 天线的不断前移得到的多道测试数据在 B-SCAN 图像中表现出双曲线结构特征如下图 1(b) 所示.


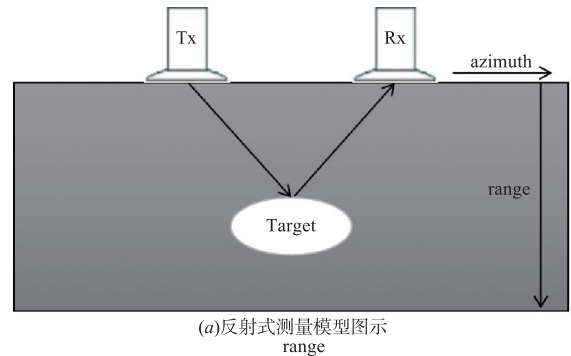


图1 GPR反射测量模式及目标成像

GPR 发射的电磁波在介质中传播时满足 Maxwell 方程组, 其微分形式如下:

$$\begin{aligned}\nabla \times \mathbf{E}(\mathbf{r}, t) &= -\frac{\partial}{\partial t} \mathbf{B}(\mathbf{r}, t) \\ \nabla \times \mathbf{H}(\mathbf{r}, t) &= \frac{\partial}{\partial t} \mathbf{D}(\mathbf{r}, t) + \mathbf{J}(\mathbf{r}, t) \\ \nabla \cdot \mathbf{D}(\mathbf{r}, t) &= \rho(\mathbf{r}, t) \\ \nabla \cdot \mathbf{B}(\mathbf{r}, t) &= 0\end{aligned}\quad (1)$$

其中 ∇ 称为哈密顿算子, \mathbf{r} 表示位移矢量, t 表示时间, \mathbf{E} 表示电场强度, \mathbf{H} 表示磁场强度, \mathbf{D} 表示电位移矢量, \mathbf{B} 表示磁感应强度, \mathbf{J} 表示电流密度矢量, ρ 表示电荷密度. 同时, 这些电磁参数之间满足如下本构关系:

$$\begin{aligned}\mathbf{D} &= \varepsilon \mathbf{E} \\ \mathbf{B} &= \mu \mathbf{H} \\ \mathbf{J} &= \sigma \mathbf{E}\end{aligned}\quad (2)$$

其中, ε 表示相对介电常量, μ 表示磁导率, σ 表示电导率. 对式(1) Maxwell 方程组中的第一个电场强度的旋度方程再进行一次旋度运算, 整理后得到其波动方程:

$$\nabla^2 \mathbf{E}(\mathbf{r}, t) - \varepsilon \mu \frac{\partial^2}{\partial t^2} \mathbf{E}(\mathbf{r}, t) - \sigma \mu \frac{\partial}{\partial t} \mathbf{E}(\mathbf{r}, t) - \frac{1}{\varepsilon} \nabla \rho = 0 \quad (3)$$

忽略诱导电荷密度 ρ 的影响, 可将式(3)简化为

$$\nabla^2 \mathbf{E}(\mathbf{r}, t) - \varepsilon \mu \frac{\partial^2}{\partial t^2} \mathbf{E}(\mathbf{r}, t) - \sigma \mu \frac{\partial}{\partial t} \mathbf{E}(\mathbf{r}, t) = 0 \quad (4)$$

对式(4)进行傅里叶变换可得:

$$\frac{\partial^2}{\partial \mathbf{r}^2} \dot{\mathbf{E}}(\mathbf{r}, \omega) + (\varepsilon \mu \omega^2 + i \sigma \mu \omega) \dot{\mathbf{E}}(\mathbf{r}, \omega) = 0 \quad (5)$$

其中 ω 表示频率. 求解式(5)可得:

$$\dot{\mathbf{E}}(\mathbf{r}, \omega) = E_0 e^{-\alpha \mathbf{r}} e^{-i \beta \mathbf{r}} \quad (6)$$

其中 E_0 表示电场强度的幅值, α 称为衰减因子, β 称为相移系数, 且

$$\alpha = \omega \sqrt{\frac{\varepsilon \mu}{2} \left(\sqrt{1 + \frac{\sigma^2}{\omega^2 \varepsilon^2}} - 1 \right)} \quad (7)$$

$$\beta = \omega \sqrt{\frac{\varepsilon \mu}{2} \left(\sqrt{1 + \frac{\sigma^2}{\omega^2 \varepsilon^2}} + 1 \right)}$$

由式(6)可知电场强度呈指数衰减, 由式(7)衰减因子 α 可知介质的电导率、相对介电常量和频率是影响电磁波在传输介质中衰减的主要因素. 而基于反射测量模式的 GPR 地下目标探测, 发射天线向地下发射高频电磁波束, 电磁波在相对介电常量变化的界面处发生反射, 反射波返回地面时被接收天线接收, 反射强弱与目标物体和其所在区域介质介电常量的差值有关, 可用反射系数 γ 来衡量:

$$\gamma = \frac{\sqrt{\varepsilon_1} - \sqrt{\varepsilon_2}}{\sqrt{\varepsilon_1} + \sqrt{\varepsilon_2}} \quad (8)$$

其中 $\varepsilon_1, \varepsilon_2$ 表示反射界面处不同介质的相对介电常量, 其差值大小是影响反射强弱的主要因素. 可见, GPR 在不同地质环境下非目标区域所形成的 B-SCAN 图像纹理是不同的, 同时在衰减一定的情况下, 接收天线能够收到目标足够强度的反射波信号时, 目标所成像的双曲线轮廓是相似的, 即双曲线形状是 GPR 目标成像的共性结构特征.

2.2 GPR B-SCAN 图像数据增强的网络模型原理

根据上述对 GPR 目标成像过程的分析可知, 目标表现出双曲线的外在结构特征, 而复杂的介质环境在 B-SCAN 图像上则表现出不同的内在纹理特征, 即一幅 GPR B-SCAN 图像同时具备外在的双曲线结构特征和内在的纹理特征. 在进行 GPR B-SCAN 图像数据增强时, 为了使生成的图像数据更加接近目标在不同介质环境下的成像结果, 生成的 GPR B-SCAN 图像中应保留完整的双曲线结构特征, 不同的纹理特征则是复杂介质场景的体现. 为此, 我们对 GPR B-SCAN 图像数据集按纹理的复杂度分为简单纹理和复杂纹理两类, 并在

此基础上进行两类纹理之间的相互转换以生成多样性纹理的 B-SCAN 图像数据.

设 m 幅 GPR B-SCAN 简单纹理图像构成的数据集表示为 $X = \{S^1, S^2, S^3, \dots, S^m\}$, 其中 S^i , ($i = 1, 2, 3, \dots, m$) 表示第 i 幅简单纹理的图像. n 幅 GPR B-SCAN 复杂纹理图像构成的数据集表示为 $Y = \{C^1, C^2, C^3, \dots, C^n\}$, 其中 C^j , ($j = 1, 2, 3, \dots, n$) 表示第 j 幅复杂纹理的图像. 将每幅 GPR B-SCAN 图像的特征抽象成由外在双曲线结构特征和内在纹理特征两部分组成, 则具有简单纹理的 B-SCAN 图像可表示为 $S_X = \{S|S_H; S_T\}$, 其中 S_H 表示图像 S 中的双曲线结构特征部分, S_T 表示 S 中的纹理特征部分. 具有复杂纹理的 B-SCAN 图像可表示为 $C_Y = \{C|C_H; C_T\}$, 其中 C_H 表示图像 C 中的双曲线结构特征部分, C_T 表示 C 中的纹理特征部分. 将 S_X 和 C_Y 中的纹理特征 S_T 和 C_T 进行相互映射以生成具有新纹理特征图像的过程可表示为

$$f(C_Y \rightarrow S_X) = \{\tilde{C}| \tilde{C}_H \approx S_H; C_T \rightarrow S_T\} \quad (9)$$

$$f(S_X \rightarrow C_Y) = \{\tilde{S}| \tilde{S}_H \approx C_H; S_T \rightarrow C_T\} \quad (10)$$

其中符号 \rightarrow 表示映射方向, f 表示简单纹理和复杂纹理 B-SCAN 图像之间的映射变换, \tilde{C}, \tilde{S} 是通过映射变换生成的图像, 符号 \approx 表示逼近关系. 式(9)表示从简单纹理生成复杂纹理图像 \tilde{C} 时应尽可能保留原有简单纹理图像 S 中双曲线结构特征的完整性. 对应的, 式(10)表示生成简单纹理的 B-SCAN 图像 \tilde{S} 中应尽可能保留原有复杂纹理图像 C 中双曲线结构特征的完整性. 进一步地, 本文利用 CycleGAN 网络在保留双曲线结构特征不变的基础上实现不同纹理复杂度图像之间的相互转换. 具体地, 对不同纹理复杂度的 GPR B-SCAN 图像而言双曲线是其外在在结构特征信息, 内在在纹理特征上存在较大差异, 通过风格转换, 生成具有新纹理的双曲线图像是对复杂地质环境下 GPR 目标成像结果的有效逼近, 这也更符合 GPR 目标探测应用场景.

3 深度学习网络模型及其在 GPR B-SCAN 双曲线图像检测中的应用

将 CycleGAN 和 Faster R-CNN 两个深度学习网络应用到 GPR B-SCAN 双曲线图像检测中, 本文建立的 GPR B-SCAN 双曲线检测模型架构如图 2 所示.

3.1 基于 CycleGAN 的 GPR B-SCAN 图像数据增强网络

循环生成对抗网络本质上是由两个镜像对称的 GAN 组成的一种环形网络. 源域样本空间 X 中 $\{x_i\}_{i=1}^M$ ($x_i \in X$), 目标域样本空间 Y 中 $\{y_j\}_{j=1}^N$ ($y_j \in Y$). CycleGAN 通过学习得到 X 到 Y 的映射关系 F 以及 Y 到 X 的映射关系 G , 同时并不要求 x_i 和 y_j 满足一一对应关系而实现图像风格转换的任务, 其网络结构如图 3 所示.

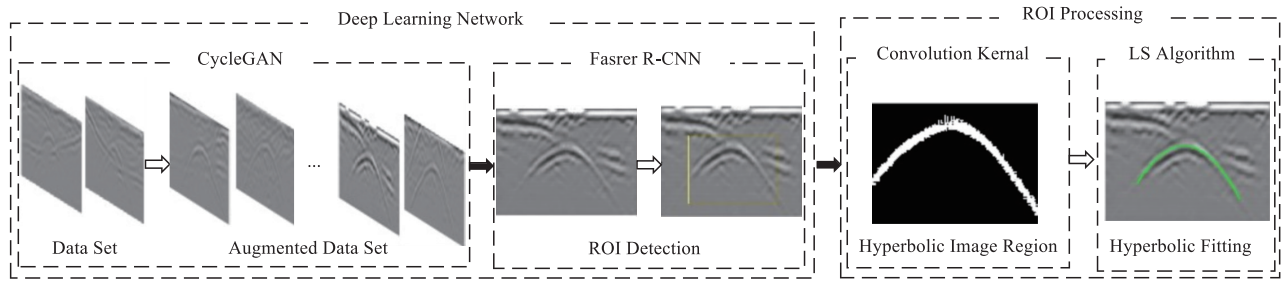


图2 基于深度学习的GPR B-SCAN图像双曲线检测模型框架

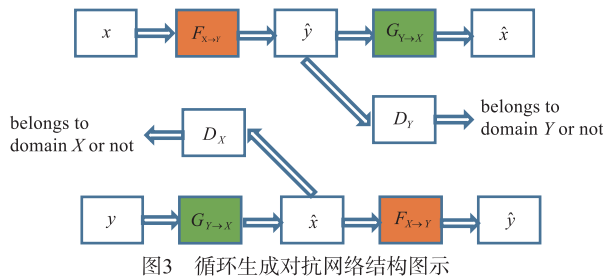


图3 循环生成对抗网络结构图示

图3所示的网络结构中两个生成器 $F_{X \rightarrow Y}$ 是相同的,两个 $G_{Y \rightarrow X}$ 也是相同的.根据生成器 $F_{X \rightarrow Y}$ 和判别器 D_Y 网络构造如下 GAN 损失函数:

$$L_{GAN}(F_{X \rightarrow Y}, D_Y, X, Y) = E_{y \sim p_{\text{data}}(y)} [\log D_Y(y)] + E_{x \sim p_{\text{data}}(x)} [\log(1 - D_Y(F_{X \rightarrow Y}(x)))] \quad (11)$$

对应地根据生成器 $G_{Y \rightarrow X}$ 、判别器 D_X 网络定义如下 GAN 损失函数:

$$L_{GAN}(G_{Y \rightarrow X}, D_X, Y, X) = E_{x \sim p_{\text{data}}(x)} [\log D_X(x)] + E_{y \sim p_{\text{data}}(y)} [\log(1 - D_X(G_{Y \rightarrow X}(y)))] \quad (12)$$

其中 E 表示期望函数.在此基础上通过引入循环一致损失函数来监督整个网络训练,循环一致损失将 $F_{X \rightarrow Y}$ 和 $G_{Y \rightarrow X}$ 两个生成器的损失相加,定义为

$$L_{\text{cyc}}(F_{X \rightarrow Y}, G_{Y \rightarrow X}) = E_{x \sim p_{\text{data}}(x)} [\|G_{Y \rightarrow X}(F_{X \rightarrow Y}(x)) - x\|_1] + E_{y \sim p_{\text{data}}(y)} [\|F_{X \rightarrow Y}(G_{Y \rightarrow X}(y)) - y\|_1] \quad (13)$$

其中 $\|\bullet\|_1$ 表示 1 范数,CycleGAN 的总损失函数可表示为

$$L(F_{X \rightarrow Y}, G_{Y \rightarrow X}, D_X, D_Y) = L_{GAN}(F_{X \rightarrow Y}, D_Y, X, Y) + L_{GAN}(G_{Y \rightarrow X}, D_X, Y, X) + \lambda L_{\text{cyc}}(F_{X \rightarrow Y}, G_{Y \rightarrow X}) \quad (14)$$

其中 λ 是惩罚因子,通常可根据实验数据集来取相应的经验值.本文对 GPR B-SCAN 图像数据进行增强,实现不同纹理 B-SCAN 图像之间的风格转换, λ 的取值在论文数据增强实验部分有进一步的说明.

对 CycleGAN 网络模型的构造可归结为求解如下优化问题:

$$(F_{X \rightarrow Y}^*, G_{Y \rightarrow X}^*) = \arg \min_{F_{X \rightarrow Y}, G_{Y \rightarrow X}, D_X, D_Y} \max L(F_{X \rightarrow Y}, G_{Y \rightarrow X}, D_X, D_Y) \quad (15)$$

式(15)优化问题的求解过程通常先对判别器 D_X, D_Y 进行优化求 L 的极大值,再对 $F_{X \rightarrow Y}, G_{Y \rightarrow X}$ 进行优化求 L 的极小值.本文使用 Adam 优化算法对式(15)进行优化求解.

3.2 基于 Faster R-CNN 的 GPR B-SCAN 双曲线图像检测网络

Faster R-CNN 模型结构如下图4所示,主要由候选区域网络(RPN)和 Fast R-CNN 检测器两部分组成.RPN 和 Fast R-CNN 通过共享 CNN 参数在很大程度上提高了算法速度,Faster R-CNN 通过一系列的卷积运算提取输入图像特征,同时这些特征在 RPN 中经过一个 3×3 和两个并行 1×1 的卷积核,一方面通过 softmax 判断目标边界框属于前景还是背景,另一方面对标定的边界框进行修正来获得精确的候选区域.进一步对候选区域进行非极大值抑制及感兴趣区域池化操作以得到确定的候选框尺寸,再经过分类、回归生成每个候选区域相对实际位置偏移量的预测值并进行修正以实现目标的准确定位.

3.2.1 基于卷积运算的 B-SCAN 双曲线图像分割算法

根据图像本身的结构特征设计与之对应的卷积核,通过卷积运算来提取这一特征信息是分析图像特征的一种有效方法.如图5所示,GPR B-SCAN 图像是开口向下的双曲线,且具有对称性.

图5所示(a)、(b)两个区域部分的曲线具有相反的方向特征,为描述方便,我们称 a 区域(即左半部分图像,用 I_l 表示)的双曲线部分为正向斜率曲线, b 区域(即右半部分图像,用 I_r 表示)双曲线部分为反向斜率曲线.针对 I_l 和 I_r 左右两部分图像我们分别设计如下卷积核 C_L 和 C_R 以提取正向斜率曲线和反向斜率曲线.

$$C_L = \kappa \begin{bmatrix} -1 & 0 \\ 0 & 1 \end{bmatrix} \quad (16)$$

$$C_R = \kappa \begin{bmatrix} 0 & -1 \\ 1 & 0 \end{bmatrix} \quad (17)$$

其中, κ 称为尺度因子,通常取经验值,设图像 I_l 或 I_r 的宽度为 w_{half} :

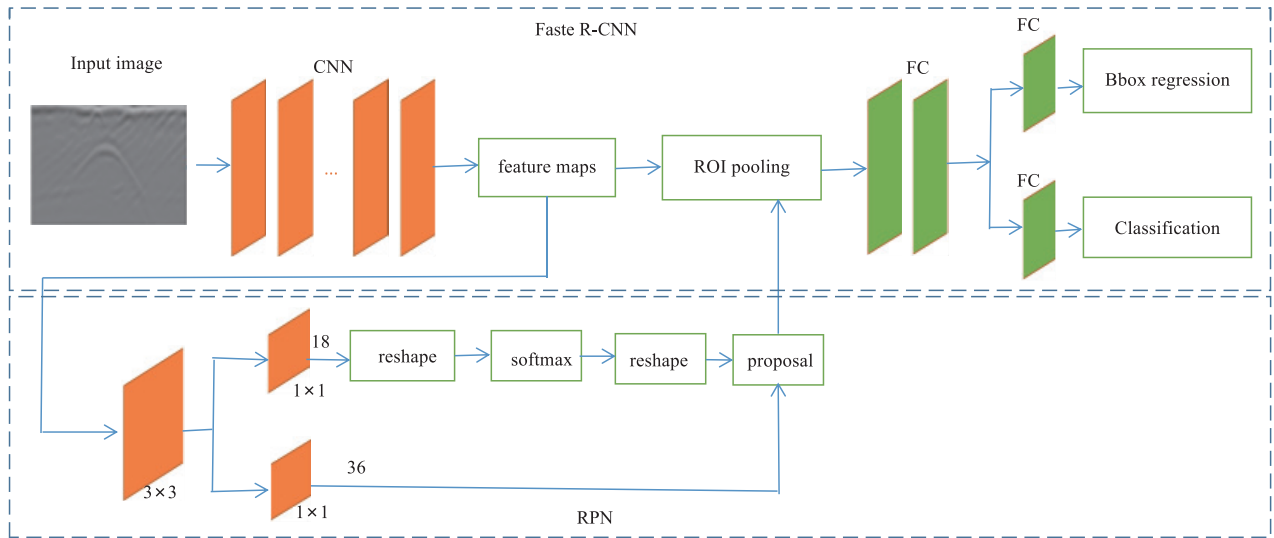


图4 Faster R-CNN网络结构图

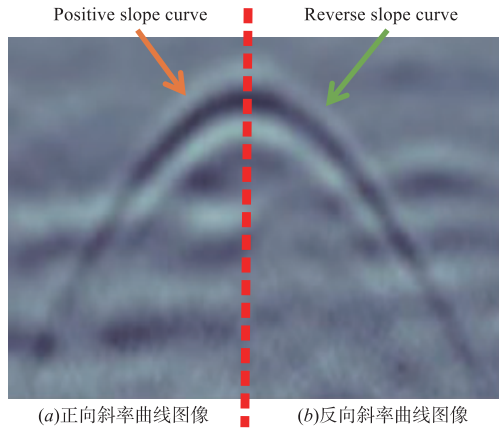


图5 GPR B-SCAN图像双曲线结构示意图

$$\kappa = \begin{cases} 0.25, & \text{if } w_{half} < 50 \\ 1, & \text{if } w_{half} > 150 \\ 0.5, & \text{others} \end{cases} \quad (18)$$

I_L, I_R 分别表示 I_l, I_r 的卷积运算结果:

$$I_L = I_l \otimes C_L \quad (19)$$

$$I_R = I_r \otimes C_R \quad (20)$$

如图 6(a) 所示 GPR B-SCAN 图像中包含两条双曲线,且曲线 1 与曲线 2 相互交叉. 通过 Faster R-CNN 算法检测得到双曲线 2 所处图像区域如下图 6(b) 所示,其左半部分区域 I_l 既有正向斜率曲线也有反向斜率曲线. 进一步对 I_l 和 I_r 分别采用式 (16) 和式 (17) 进行卷积运算得到 I_L 和 I_R 的二值图像分别如图 6(c)、(d) 所示,由 (c) 图结果可见,在检测得到正向斜率曲线的同时有效抑制了反向斜率曲线的干扰,(d) 图中也检测得到了完整的反向斜率曲线. 双曲线是通过 Faster R-CNN 算法检测得到的主要目标,将图 6(c)、(d) 所示左、右两部分图像进行融合取最大的连通域 Ω 即为双

曲线特征区域,结果如图 6(e) 所示. 后续可对该区域进行二次曲线拟合以精确提取得到 B-SCAN 双曲线图像.

由于 Faster R-CNN 检测到的候选框区域与目标真实的位置可能会存在一定偏差,同时 GPR B-SCAN 双曲线图像本身也并非严格中心对称,为提高算法的鲁棒性,我们在选取左、右图像区域 I_l 和 I_r 时可增加一定的冗余量 th ,设图像宽度为 w ,本文取经验值 $th = 0.1w$. 下图 7(a) 所示是划分图像左、右区域的过程示意图,对 I_l 和 I_r 分别进行卷积运算处理后得到对应的二值图像 I_L 和 I_R 如下图 7(b)、(c) 所示,对其重叠部分取并集以得到结构更加完整的拼接图像如下图 7(d) 所示.

3.2.2 基于 LS 的二次曲线拟合算法分析

由于本文处理的 GPR B-SCAN 数据具有明显的双曲线特征,可采用算法复杂度低的最小二乘法进行双曲线拟合. 将 B-SCAN 图像区域 Ω 用离散序列 (x_k, y_k) , $k = 1, 2, 3, \dots, N$ 来表示,其中 N 是区域 Ω 中离散序列点的个数,用二次函数 $\varphi(x) = p_0 + p_1x + p_2x^2$ 对序列进行曲线近似拟合,二次曲线拟合函数与离散序列的均方误差可表示为

$$\sigma(p_0, p_1, p_2) = \sum_{k=1}^N (\varphi(x_k) - y_k)^2 \quad (21)$$

根据多元函数求极值方法可得:

$$\begin{bmatrix} N & \sum_{k=1}^N x_k & \sum_{k=1}^N x_k^2 \\ \sum_{k=1}^N x_k & \sum_{k=1}^N x_k^2 & \sum_{k=1}^N x_k^3 \\ \sum_{k=1}^N x_k^2 & \sum_{k=1}^N x_k^3 & \sum_{k=1}^N x_k^4 \end{bmatrix} \begin{bmatrix} p_0 \\ p_1 \\ p_2 \end{bmatrix} = \begin{bmatrix} \sum_{k=1}^N y_k \\ \sum_{k=1}^N x_k y_k \\ \sum_{k=1}^N x_k^2 y_k \end{bmatrix} \quad (22)$$

求解系数 $\hat{p}_0, \hat{p}_1, \hat{p}_2$, 得到在最小均方误差准则下的二次拟合曲线为

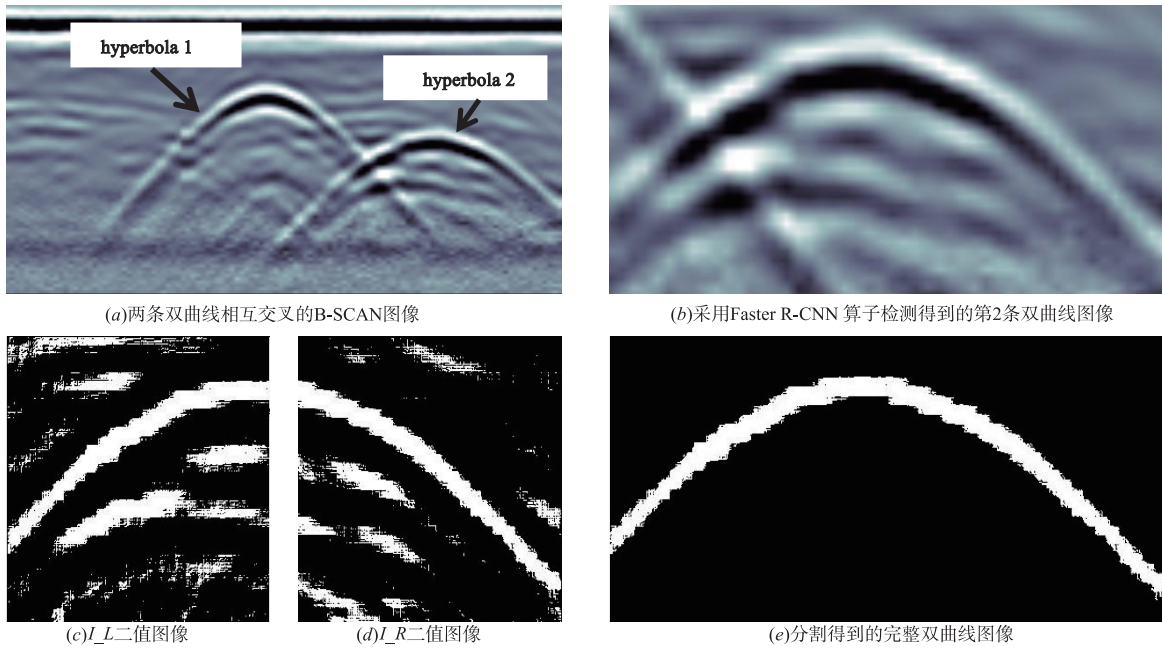


图6 基于卷积运算的双曲线检测结果




图7 鲁棒的双曲线图像分割结果

$$\varphi(x) = \hat{p}_0 + \hat{p}_1x + \hat{p}_2x^2 \quad (23)$$

图 6(e) 中 B-SCAN 图像双曲线区域对应的二次曲线拟合结果如图 8 中绿色曲线所示。

4 实验与结果分析

4.1 基于 CycleGAN 的 GPR B-SCAN 图像数据增强实验

GPR B-SCAN 数据集中的图像主要通过 GPRMAX^[25] 软件仿真得到,从中选取了 2400 幅大小为 500×350 的




图8 双曲线拟合


图像,使用 CycleGAN 进行数据增强.将如下图 9(a) 所示纹理较为简单的图像分为一类(记为 A,1200 幅),图 9(b) 所示纹理复杂的图像分为另一类(记为 B,1200 幅).从这两类图像中分别随机选取 300 幅图像作为测试集,其余 900 幅图像作为训练集. Adam 优化器 $\beta = 0.5$, 初始学习率取 0.0002.

使用 CycleGAN 得到从 A 映射到 B 及从 B 映射到 A 的结果分别如图 9(c)、图 9(d) 所示.从转换结果来看,转换前后的图像中都完整地保留了 B-SCAN 双曲线特征信息,具有很好的主观视觉效果.整体上,采用 CycleGAN 进行数据增强后的图像更接近真实地质环境下的 GPR 目标探测结果.

需要注意的是,通过调节式(14)中循环一致损失函数的惩罚因子 λ 可以生成不同风格的图像,取不同的 λ 即在循环损失与鉴别损失之间进行相应的调节,如果 λ 取值较大表明循环损失比鉴别损失占更大比重,生成的图像中能更好的保留原图像中的特征信息.考虑到 GPR 目标成像通常是在地质结构较为复杂的环境下进行,为

了生成更具多样性 GPR 风格的图像可以适当调小 λ 的取值,但当 λ 取值太小时会导致生成图像中原有图像特征的丢失,通过在 GPR B-SCAN 数据集上的实验发现 λ 的合理取值区间为 5 ~ 13. 当取 $\lambda = 8$ 时,图 9(a)、图 9

(b) 中所示不同风格图像相互转换后的结果如图 9(c)、图 9(d) 所示. 而当惩罚因子取值较小 $\lambda = 3$ 时会出现生成图像的双曲线特征信息模糊甚至丢失的情况,如图 9(e) 所示结果是图 9(b) 图像风格转换失败的情况.



(a)简单纹理的B-SCAN图像
(b)复杂纹理的B-SCAN图像
(c)从A映射到B的结果
(d)从B映射到A的结果
(e)惩罚因子取值太小导致风格转换失败的结果
图9 B-SCAN图像数据增强的结果

4.2 基于 Faster R-CNN 的 GPR B-SCAN 双曲线图像检测实验

采用上文基于 CycleGAN 的图像增强方法总共获得了 5520 幅图像,其中 5440 幅图像是通过软件仿真得到,60 幅是通过物理模拟方式得到(在实验场景下埋设

固定目标),20 幅是探测城市道路及地下管线等目标的实测数据,数据来源包括 TACOMA 实测的城市道路 GPR 数据^[26],ZHOU^[27] 及 SUN^[28] 等实测地下管线的 GPR B-SCAN 双曲线数据. 从中随机选取 520 幅图像用于测试(包含 20 幅实测 B-SCAN 图像数据),并对其它

5000 幅图像进行双曲线区域标定,将制作的数据集用于 Faster R-CNN 网络的训练,本文 CNN 选用 resnet50 网络模型架构.从测试集样本的检测结果中选取了如图 10 所示的 12 幅图像加以分析,其中图 10(a)所示 3

幅图像是 GPRMAX 软件仿真得到的数据,图 10(b)所示 3 幅图像是物理模拟数据,图 10(c)、图 10(d)所示 6 幅图像是实测数据.

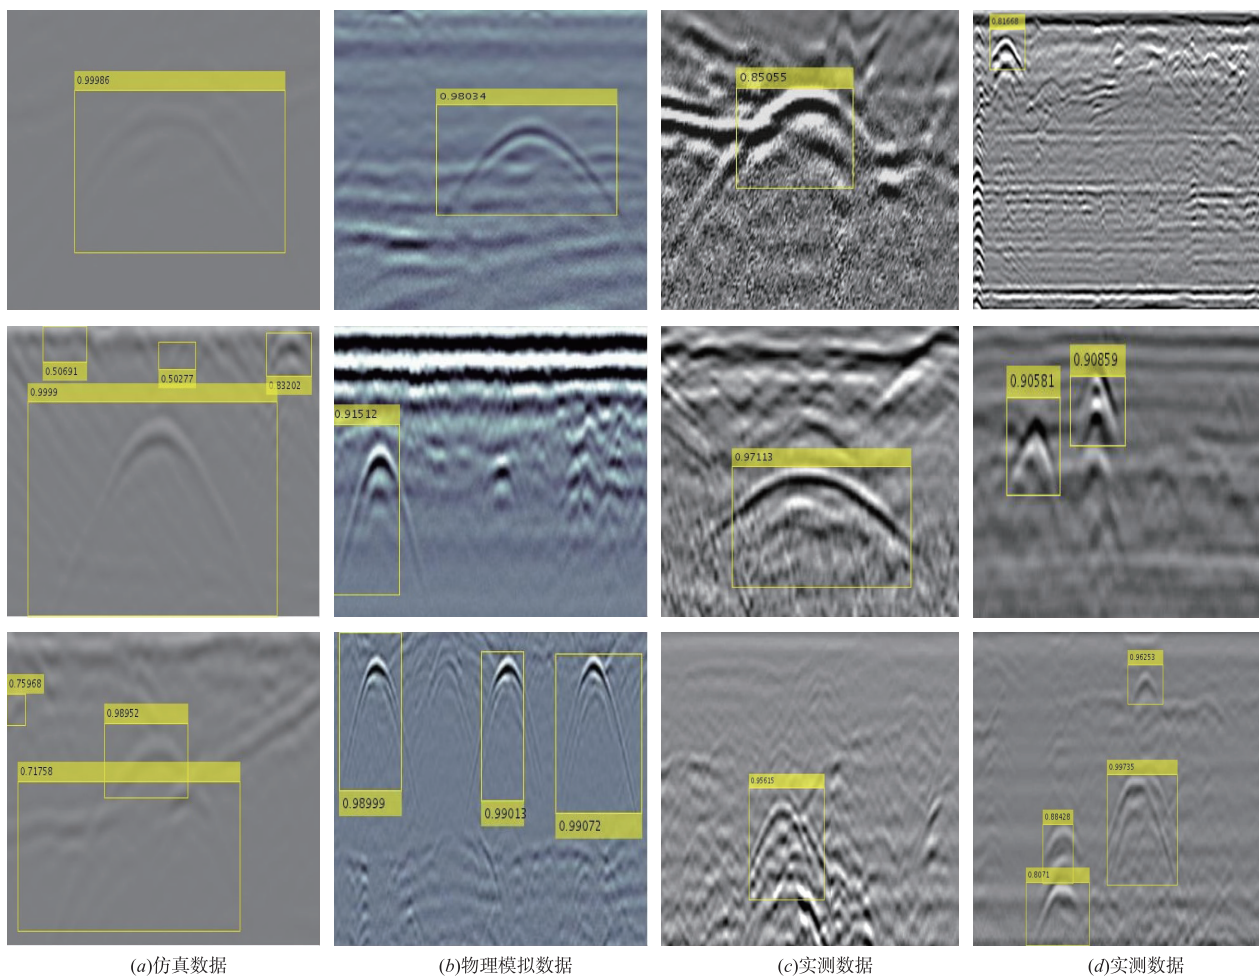


图 10 采用Faster R-CNN算法检测得到的双曲线图像区域

从图 10 所示结果可见,通过 GPRMAX 软件进行仿真、物理模拟以及实测得到的数据,当 B-SCAN 图像中表现出较为明显的双曲线结构特征时,采用 Faster R-CNN 算子都能够较为准确地检测到对应的双曲线区域.进一步地,根据本文提出的一种基于卷积运算的 B-SCAN 图像双曲线快速分割算法,使用式(16)(17)所示的卷积核 C_L 、 C_R 对上图 10 所示检测到得分大于 0.8 的 B-SCAN 图像区域进行卷积运算,分割得到对应的双曲线二值图像如图 11 所示.

对图 11 所示的双曲线区域采用最小二乘法进行二次曲线拟合得到完整的 B-SCAN 双曲线如图 12 中的绿色曲线所示.

为能客观地描述算法检测效果的有效性,采用综合指标 F 度量来衡量双曲线图像检测结果, F 的值越大表示检测效果越好,计算公式为

$$F = \frac{2 \times P \times R}{P + R} \quad (24)$$

其中, $p = \frac{\text{正确判断为目标像素点的个数}}{\text{检出的目标像素点个数}}$,称为准确率,表示正确检测到目标像素点个数占实际检测到目标像素点个数的比例; $R = \frac{\text{正确判断为目标像素点的个数}}{\text{实际目标像素点的个数}}$,称为召回率,表示正确检测到目标像素点的个数占真实目标像素点个数的比例.

对测试的 520 幅样本图像根据纹理结构的复杂度以及双曲线几何尺寸的大小按表 1 所示组合方式共分为 4 类,其中第 1 类 180 幅;第 2 类 50 幅;第 3 类 185 幅;第 4 类 105 幅.

将本文算法与文献[18]中基于迁移学习的方法、文献[7]基于 HOG 算法以及文献[5]基于 Hough 变换




图11 采用卷积运算分割得到的双曲线图像




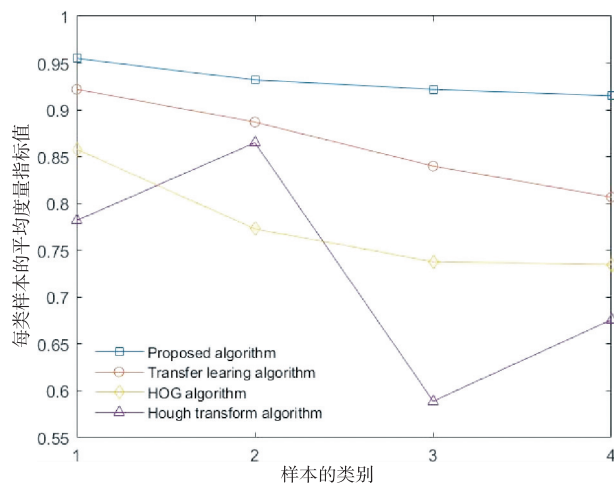
图12 双曲线拟合结果

的算法进行了比较. 对每一类测试样本的 F 均值统计结果如图 13(a)所示,在整个测试样本空间上对 520 幅图像统计各算法的 F 均值如图 13(b)所示.

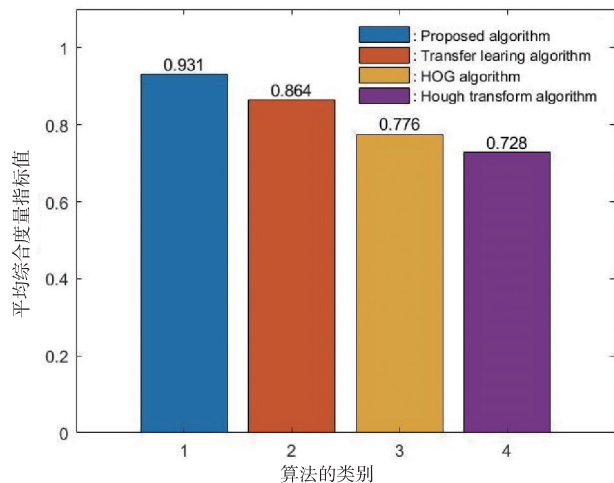
表 1 数据集样本的分类

分类	纹理简单	纹理复杂
双曲线几何尺寸大	1	3
双曲线几何尺寸小	2	4

根据图 12 所示结果可见本文算法对 GPR B-SCAN 双曲线的拟合效果在直观视觉上有较高的拟合度,同时从图 13 统计的客观衡量指标 F 来看本文算法在不同类别的图像上都取得了较好的检测结果,在 4 种方法中其检测结果也是最优的,平均 F 值达到 0.931,整体上对大尺寸双曲线目标的检测效果要好于小尺寸目标,主要原因在于小尺寸双曲线目标的定位精度总体上低于大尺寸目标.



(a) 不同算法分别在4类测试样本上取得的F均值统计结果



(b) 不同算法在整个测试样本集上得到的F均值统计结果

图13 综合度量指标F的统计结果

5 结论

本文在分析 GPR 目标成像特征的基础上,提出了采用 CycleGAN 网络来实现 B-SCAN 图像数据增强的方法,生成了逼真度高的 GPR B-SCAN 图像.同时,针对复杂地质环境下噪声干扰大,GPR B-SCAN 图像对比度低,采用传统光学图像处理方法难以对双曲线目标进行有效分割的问题,提出了一种基于卷积运算的双曲线快速分割方法.通过二次曲线拟合得到的双曲线主观视觉效果较好,与其它3种基于深度学习、基于传统机器学习以及基于 Hough 变换算法相比,本文方法在客观度量指标上是最优的,这也对后续深入分析目标所处的空间位置及其几何结构特征等信息具有重要意义.需要指出的是,针对强噪声干扰下 GPR 实测 B-SCAN 图像中双曲线结构特征不明显甚至完全淹没在噪声中的情况,直接使用本文方法将难以得到预期的检测结果.未来工作中处理强噪声干扰问题时,通过对实测数据进行滤波预处理,并在 GPR 目标成像物理机

制的约束下结合深度学习网络来增强 B-SCAN 图像中双曲线特征信息是重点研究的问题.

参考文献

- [1] Ebrahim S M, Medhat N I, Mansour K K, et al. Examination of soil effect upon GPR detectability of landmine with different orientations [J]. *NRIAG Journal of Astronomy and Geophysics*, 2018, 7(1): 90–98.
- [2] Pablo B, Bonomo N, Patricia M. Automatic detection of pipe-flange reflections in GPR data sections using supervised learning [J]. *Journal of Applied Geophysics*, 2019, 170: 103856.
- [3] 郝彤, 赵杰. 面向双曲线形态的探地雷达图像识别技术综述 [J]. *电子学报*, 2019, 47(6): 1366–1372.
Hao T, Zhao J. A brief review of the hyperbola signature recognition techniques for ground penetrating radar [J]. *Acta Electronica Sinica*, 2019, 47(6): 1366–1372. (in Chinese)
- [4] 侯斐斐, 施荣华, 雷文太, 等. 面向探地雷达 B-scan 图像的目标检测算法综述 [J]. *电子与信息学报*, 2020, 42(1): 191–200.
Hou F F, Shi R H, Lei W T, et al. A review of target detection algorithm for GPR B-scan processing [J]. *Journal of Electronics and Information Technology*, 2020, 42(1): 191–200. (in Chinese)
- [5] 陈德莉, 黄春琳, 粟毅. 用统计方法和 Hough 变换进行 GPR 目标检测与定位 [J]. *电子学报*, 2004, 32(9): 1468–1471.
Chen D L, Huang C L, Su Y. An integrated method of statistical method and Hough transform for GPR targets detection and location [J]. *Acta Electronica Sinica*, 2004, 32(9): 1468–1471. (in Chinese)
- [6] Liu Y Y, Wang M Q, Cai Q R. The target detection for GPR images based on curve fitting [A]. *International Congress on Image and Signal Processing [C]*. Yantai, China: IEEE, 2010. 2876–2879.
- [7] Torriero P A, Morton K D, Sakaguchi R, et al. Histograms of oriented gradients for landmine detection in ground-penetrating radar data [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, 52(3): 1539–1550.
- [8] Maas C, Schmalzl J. Using pattern recognition to automatically localize reflection hyperbolas in data from ground penetrating radar [J]. *Computers & Geosciences*, 2013, 58(8): 116–125.
- [9] Kang M S, Kim N, Im S B, et al. 3D GPR image-based U-Net for enhancing underground cavity detectability [J]. *Remote Sensing*, 2019, 11(21): 2545.
- [10] Zhou X, Chen H, Li J. An automatic GPR B-Scan image interpreting model [J]. *IEEE Transactions on Geoscience*


- & Remote Sensing, 2018, 56(99):3398 – 3412.
- [11] Alvarez J K, Kodagoda S. Application of deep learning image-to-image transformation networks to GPR radargrams for sub-surface imaging in infrastructure monitoring [A]. The 13th IEEE Conference on Industrial Electronics and Applications [C]. Wuhan, China: IEEE, 2018. 611 – 616.
- [12] Zhang J, Yang X, Li W G, et al. Automatic detection of moisture damages in asphalt pavements from GPR data with deep CNN and IRS method [J]. Automation in Construction, 2020, 113: 103119.
- [13] Besaw L E, Stimac P J. Deep convolutional neural networks for classifying GPR B-Scans [J]. Proceedings of SPIE the International Society for Optical Engineering, 2015, 9454: 945413.
- [14] Ren S Q, He K M, Girshick R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 39(6): 1137 – 1149.
- [15] Li J Y, Zhang J, Chang D D, et al. Computer-assisted detection of colonic polyps using improved Faster R-CNN [J]. Chinese Journal of Electronics, 2019, 28(4): 718 – 724.
- [16] Zhao Z B, Zhen Z, Zhang L, et al. Insulator detection method in inspection image based on improved Faster R-CNN [J]. Energies, 2019, 12(7): 1204 – 1213.
- [17] Pham M T, Lefèvre S. Buried object detection from B-scan ground penetrating radar data using Faster-RCNN [A]. IEEE International Geoscience and Remote Sensing Symposium [C]. Valencia, Spain: IEEE, 2018. 6804 – 6807.
- [18] Lei W T, Hou F F, Xi J C, et al. Automatic hyperbola detection and fitting in GPR B-scan image [J]. Automation in Construction, 2019, 106: 102839.
- [19] Goodfellow I J, Pouget-Abadie J, Mirza M, et al. Generative adversarial networks [J]. Advances in Neural Information Processing Systems, 2014, 3: 2672 – 2680.
- [20] Huang S W, Lin C T, Chen S P, et al. AugGAN: Cross domain adaptation with gan-based data augmentation [A]. ECCV 2018: European Conference on Computer Vision [C]. Munich Germany: Springer, 2018. 718 – 731.
- [21] Wu Y, Yang F, Huang J, et al. Super-resolution construction of intravascular ultrasound images using generative adversarial networks [J]. Journal of Southern Medical University, 2019, 39(1): 82 – 87.
- [22] Micha P, Isabel F, Maria R, et al. Generating large labeled data sets for laparoscopic image processing tasks using unpaired image-to-image translation [A]. Medical Image Computing and Computer Assisted Intervention [C]. Shenzhen, China: Springer, 2019. 119 – 127.
- [23] Zhu J Y, Park T, Isola P, et al. Unpaired image-to-image translation using cycle-consistent adversarial networks [A]. The IEEE International Conference on Computer Vision [C]. Venice, Italy: IEEE, 2017. 2223 – 2232.
- [24] Chen X Y. Proof of concept project for detecting and classifying hyperbolas in ground penetrating radar (GPR) data [DB/OL]. <https://github.com/irenexy-chen/gpr-data-classifier>, 2018-08-24.
- [25] Warren C, Giannopoulos A, Giannakis I. gprMax: Open source software to simulate electromagnetic wave propagation for ground penetrating radar [J]. Computer Physics Communications, 2016, 209: 163 – 170.
- [26] Tacoma, Everett. Ground penetrating radar detection in seattle [DB/OL]. <https://www.cnilocates.com/ground-penetrating-radar-gpr-detection>, 2020-04-22.
- [27] Zhou X R, Chen H H, Hao T. Efficient detection of buried plastic pipes by combining gpr and electric field methods [J]. IEEE Transactions on Geoscience and Remote Sensing. 2019, 57(6): 3967 – 3979.
- [28] Sun W, Xu Q, Zhang H, et al. Research on detection and visualization of underground pipelines [A]. International Conference on Remote Sensing [C]. Nanjing, China: IEEE, 2012. 1 – 4.

作者简介



王 辉 男, 1982 年 10 月生, 湖北仙桃人, 贺州学院副教授, 现为桂林电子科技大学博士研究生。主要研究方向: 探地雷达信号处理、深度学习。

E-mail: syswangxueleng@163.com



欧阳缙 (通信作者) 男, 1960 年 9 月生, 江西安福人, 桂林电子科技大学教授, 博士生导师。主要研究方向: 探地雷达信号处理、智能信息处理。

E-mail: hmoysh@guet.edu.cn