

基于生成式对抗网络的隧道衬砌探地雷达 数据智能处理方法

宁长远¹, 孙洪鹏¹, 张东昊², 史伟鉴³, 张思远³, 章 晖²

(1. 龙建路桥股份有限公司, 哈尔滨 150036; 2. 大连理工大学建设工程学院, 辽宁 大连 116024;

3. 龙建路桥第一工程有限公司, 哈尔滨 150000)

摘要: 探地雷达(GPR)广泛应用于隧道衬砌质量检查,然而实际采集的原始探地雷达数据常常无法直接进行解译,需要进行去噪、增益、图像平滑等多种技术手段处理后,才能从中读取有效回波信息。考虑到目前探地雷达数据基本通过人工处理,处理流程复杂,参数选取主观性强,处理工作费时费力,基于生成式对抗网络(GAN),提出一种直接将探地雷达原始数据转化为具有清晰回波信号图像的端到端处理方法。使用的生成式对抗网络由一系列不同尺度生成器和鉴别器组成,可以智能识别探地雷达数据整体和局部特征,并对原始数据自动进行全面的处理操作。该方法成功应用于隧道初衬质量检测的实测探地雷达数据处理任务中,数据处理效果基本与人工处理结果相同,并实现了更高的数据处理效率。

关键词: 隧道衬砌; 探地雷达; 数据处理; 深度学习; 生成式对抗网络

中图分类号: U457+.2 **文献标志码:** A **文章编号:** 1671-1807(2025)09-0079-06

截至 2022 年底,中国已建成的隧道总里程达到 48 762 km^[1-2]。大量服役的隧道除了提供交通便利性以外,同时也伴随着大量隧道结构运营维护的需求^[3]。探地雷达作为一种快速、高分辨率的探测工具,可满足隧道结构快速质量检查要求,已广泛应用于诸多隧道衬砌检测的工作中^[4-7]。然而,由于探地雷达通过发射与接收电磁波来对隧道衬砌内部介电电性参数分布情况进行探测,导致探地雷达设备易受内部电路与环境电磁干扰的影响,进而在原始数据内形成电磁噪声^[8]。探地雷达发射出的电磁波在返回接收天线前,会在衬砌表面、衬砌混凝土骨料间发生多种路径的反射与折射,在数据内形成多路径传播噪声,并且探地雷达天线的旁瓣也会产生多路径传播噪声^[9]。这些噪声会与有效回波信号混杂在一起,干扰数据的解析工作^[10-11]。另外,由于电磁波信号在隧道衬砌内的能量衰减,减弱了深层回波信号返回接收天线时的强度,进而降低深

层回波信号的清晰度^[12-13]。

因此,对于探地雷达的原始数据,需要进行去噪、平滑、能量增益等一系列处理,才能实现雷达数据有效回波信号的清晰识别^[14-15]。探地雷达数据处理流程一般为低频噪声移除、背景噪声移除、零时校正、能量增益、带通滤波、滑动平均^[16]。在此基础上,也会根据数据特点进一步采用二维滤波或小波去噪等更高级处理算法^[17-19]。可以发现,探地雷达数据处理涉及流程多,且每一流程的参数需要根据探测数据进行针对性取值,否则便无法保证理想的处理效果^[20]。在实际的隧道探测工作中,原始数据基本依靠技术人员进行人工处理,不仅费时费力,而且数据处理参数一般由技术人员根据自身经验确定,主观性较强^[5,21]。

随着深度学习技术的发展,基于卷积神经网络自动挖掘数据内隐含的复杂特征信息,并建立不同域数据间的非线性映射,已经成为信号处理领域研

收稿日期: 2024-11-04

基金项目: 国家自然科学基金(41904095)

作者简介: 宁长远(1972—),男,黑龙江哈尔滨人,高级工程师,研究方向为桥梁、隧道施工相关技术;孙洪鹏(1987—),男,黑龙江哈尔滨人,硕士,工程师,研究方向为桥梁与隧道施工技术;张东昊(1997—),男,河北张家口人,博士研究生,研究方向为隧道及地下工程智能诊断与智慧运维;史伟鉴(1988—),男,黑龙江绥化人,硕士,高级工程师,研究方向为桥梁与隧道施工技术;张思远(1983—),男,黑龙江哈尔滨人,高级工程师,研究方向为桥梁与隧道施工技术;通信作者章晖(1985—),男,陕西安康人,博士,副教授,研究方向为隧道及地下工程智能诊断与智慧运维。

究热点^[22]。对于高度非线性、非平稳的探地雷达信号,使用深度学习方法进行由原始数据到不含噪声的纯净数据间的端到端映射,可以实现智能快速去噪,已在诸多研究中证明为有效的方法^[23-24]。此过程在网络得到充分训练后便可以自动进行,无须人工干预,大大减少了传统去噪方法的处理时间与人的主观影响^[24]。然而,目前针对深度学习雷达数据处理方法的研究,仅局限于对数据内噪声的滤除。尚未通过深度学习技术,建立起整体的由原始数据到施加了去噪、增益、图像平滑等多流程处理手段后清晰回波数据的端到端方法^[8, 25]。理论上,深度学习网络通过神经元权重来隐式映射特征向量,可以捕捉极其复杂的探地雷达信号特征,允许深度学习方法进行更多种类的数据处理工作^[26]。因此,本文基于深度学习方法^[27],利用生成式对抗网络^[28],提出一种针对探地雷达数据的端到端自动处理方法。该方法可以自动分离原始探地雷达 B-scan 数据中的有效回波信号与其他干扰信号,智能进行去噪、增益、图像平滑等流程,最后直接输出清晰的处理后 B-scan 图像。

1 生成式对抗网络

1.1 网络结构

本文构建的生成式对抗网络由多个不同尺度的生成器和鉴别器组成,以保证网络生成的虚拟图像与原始探地雷达数据在物理上的多尺度一致性^[29],如图 1 所示。该网络可以自动提取探地雷达原始数据内的复杂多尺度特征,并且重建出高度真实的清晰回波数据。其中,多尺度生成器由一个低

分辨率生成器和一个高分辨率生成器组成,分别负责全局图像生成和局部细节修饰。在训练过程中,首先训练低分辨率生成器,其训练数据由训练集内图像通过两次下采样得到,旨在通过小尺度的训练,使网络通观整个输入数据,来捕捉内部的全局特征,从而建立起原始数据与处理后图像整体间的非线性映射。随后训练高分辨率生成器,并在高分辨率生成器的残差层前接入低分辨率生成器的输出结果,使其在数据全局映射的基础上,进一步学习原始数据和处理后图像之间的局部细节映射关系。最后,对两个生成器进行权重微调,使其达到最优性能。

在进行生成器训练的过程中,同时接入多尺度鉴别器,以推动生成器产生更高质量的数据,多尺度鉴别器由高、中、低分辨率 3 个鉴别器组成,高分辨率鉴别器接收高分辨率生成器输出的结果并评估其真实程度,中、低分辨率鉴别器分别接收经过一次下采样和二次下采样的生成器图像并评估真实性。低分辨率鉴别器负责使生成结果在整体上保持和谐,随着鉴别器分辨率的增大,其评估结果逐渐可以引导生成器产生具有更精致局部细节的处理后图像。

1.2 损失函数

使用均方误差(mean square error, MSE)作为生成器的像素级损失函数:

$$\text{MSE}(P_{\text{pre}}, P_{\text{real}}) = \frac{1}{m} \sum_{i=1}^m (p_{\text{pre},i} - p_{\text{real},i})^2 \quad (1)$$

式中: P_{pre} 为生成器处理的雷达图像; P_{real} 为训练集内真实的处理后雷达图像; $p_{\text{pre},i}$ 为生成器处理图像

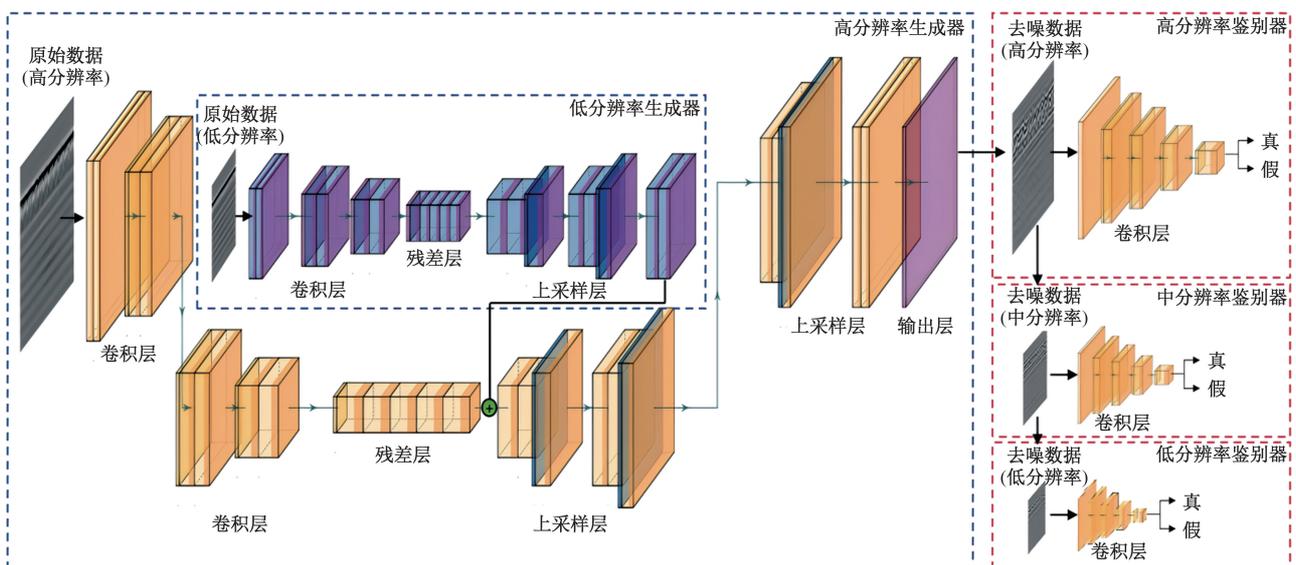


图 1 生成式对抗探地雷达数据处理网络

的第 i 个像素值; $p_{\text{real},i}$ 为真实处理后图像的第 i 个像素值; m 为生成器输出的处理图像内总的像素数量。使用均方误差作为生成器的损失函数,可以逐像素地计算生成器输出结果与准确结果间的差别,从而指导生成器权重的更新方向。

生成式对抗网络中的生成器与鉴别器训练是一个动态的对抗过程,整体的对抗性损失函数 L 可以由以下公式描述。

$$L = \lambda_{\text{GAN}} L_{\text{GAN}} + \lambda_{\text{FM}} L_{\text{FM}} \quad (2)$$

$$L_{\text{GAN}} = E_{x \sim p_{\text{data}}(x)} \{ \ln[D(x)] \} + E_{z \sim p_z(z)} \{ \ln\{1 - D[G(z)]\} \} \quad (3)$$

$$L_{\text{FM}} = E_{x \sim p_{\text{data}}(x)} \sum_{i=1}^T \frac{1}{N_i} \{ \|D_k^{(i)}(x) - D_k^{(i)}[G(z)]\|_1 \} \quad (4)$$

式中: L_{GAN} 为生成器与鉴别器之间的对抗性损失; x 为真实样本,服从真实数据集的分布 $p_{\text{data}}(x)$; z 为原始数据,服从原始数据集的分布 $p_z(z)$; $E_{x \sim p_{\text{data}}(x)} \{ \ln[D(x)] \}$ 为根据鉴别器识别真图像的对数损失构建的数学期望; $E_{z \sim p_z(z)} \{ \ln\{1 - D[G(z)]\} \}$ 为通过鉴别器识别假图像的对数损失构建的数学期望。训练过程中,生成器与鉴别器的目标均是提升自身的性能,生成器致力于输出足够真实的处理后雷达图像来欺骗鉴别器,使其无法分辨出虚假图像与真实图像间的差别。而鉴别器则尽量准确对虚假图像和真实图像做出分辨,并给出正确的评估结果。训练初期,鉴别器可以轻易区分真实图像与生成器的虚假图像,分别给出代表真实的“1”标签和代表虚假的“0”标签,即 $D[G(z)] = 1$ 、 $D(x) = 0$; 训练后期,当网络获得最佳数据处理性能的情况下,鉴别器无法准确分辨真实和虚假图像,会倾向给予所有图像中立的“0.5”标签,即 $D[G(z)] = D(x) = 0.5$,标志该生成式对抗网络的训练达到了理想状态; L_{FM} 为特征匹配损失,用来计算生成器图像与真实图像在鉴别器每一中间层之间的特征差距,进而帮助生成器产生在多个特征空间内都和真实图像相似的图像,以提升图像处理结果的真实性; $D_k^{(i)}$ 为第 k 个分辨率鉴别器的第 i 层输出; T 为每个分辨率鉴别器的总卷积层数; N_i 为鉴别器第 i 层的权重参数数量; λ_{GAN} 和 λ_{FM} 分别为这两种损失项赋予的权重值。

2 工程应用

2.1 数据采集

使用探地雷达设备,在黑龙江峰岩山隧道对初衬进行无损检测。探地雷达主机型号为 MALA

ProEx,天线选用 800 MHz 屏蔽天线,如图 2(a)所示。探测现场如图 2(b)所示,沿隧道大里程方向,在拱顶、左右拱腰和左右边墙划分 5 条测线开展连续探测,共探测 895 m 初衬施工段。天线采用测距轮激发模式,间隔为 0.02 m,主机采样频率为 12 044 MHz,采集时窗为 40 ns,采样点数量为 512。



(a) 探地雷达设备



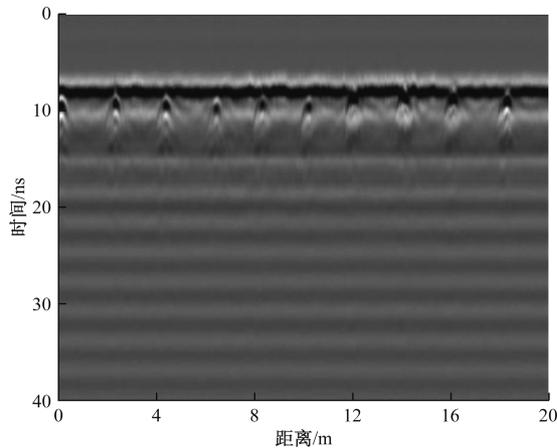
(b) 现场检测

图 2 隧道初衬探地雷达设备及现场检测

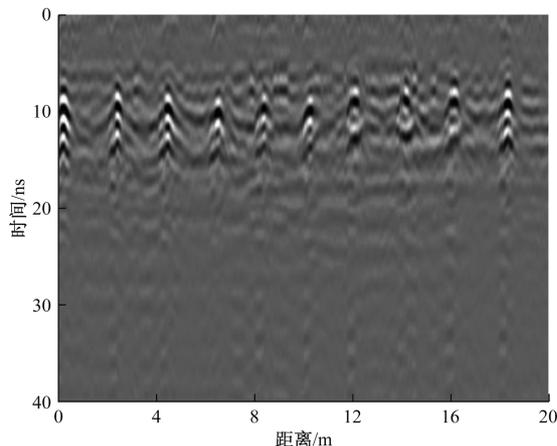
共探测了 375 段 B-scan 剖面数据,每段 B-scan 剖面内包含约 1 000 道 A-scan 时域波形。图 3(a) 为原始数据示例。可以发现,受到噪声和电磁波能量衰减的影响,初衬深层的回波信号基本被条状的干扰信号所淹没,只能隐约观察到初衬钢拱架顶端的反射信号,给探地雷达数据解释以及后续的初衬质量检查工作带来了困难。为得到清晰的探测图像,根据抽取平均值、信号增益、移除背景噪声、带通巴特沃斯滤波、平滑处理的处理流程,对原始数据进行处理,相关参数值列于表 1。经过流程处理后的探地雷达图像如图 3(b)所示,此时清晰显示出了初衬深层钢拱架和脱空病害的反射波形。

2.2 网络训练

将原始数据图像与其对应的处理后图像一一配对,图像尺寸均标准化为 $2\,000 \times 1\,000$ 像素,共形成 375 组原始图像-处理后图像数据对。随机选择其中 338 组数据对作为训练集,其中原始数据输



(a) 原始探地雷达图像



(b) 处理后探地雷达图像

图 3 工程实测数据示例

表 1 原始数据处理流程

处理方法	参数名称	参数值	描述
抽取平均值	平均窗口宽度/ns	1.25	移除较长周期的低频噪声
信号增益	增益系数	1	补偿深层信号能量衰减
移除背景噪声	背景噪声移除时间窗/ns	40	去除重复的背景噪声
带通巴特沃斯滤波	滤波频率范围/MHz	300~1 200	保留有效探测频段信号
平滑处理	平滑测线数	3 道测线	移除随机噪声

入生成式对抗网络进行特征提取和像素重建,处理后图像作为真实值(Ground truth)来引导网络权重参数的更新方向,是网络输出结果的最终目标。网络共训练了100个周期,训练过程在配置了型号为Intel i9-9920X CPU与NVIDIA RTX 2080 Ti GPU的工作站上进行,训练所用优化器为Adam,学习率设置为0.000 1,训练完成共花费4.55 h,训练曲线如图4所示。

网络的训练是一个动态的过程,生成器与鉴别

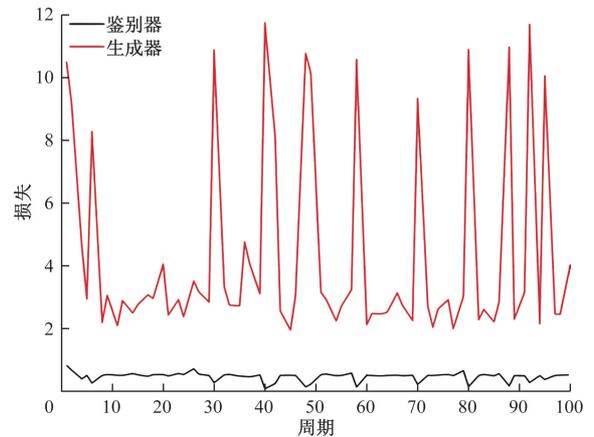


图 4 网络训练损失曲线

器处于对抗的状态中,当生成器损失处于极大值时,鉴别器损失则处于极小值,说明此时生成器较弱而鉴别器性能较强,反之亦然。最终,选取第100个周期的生成器网络权重作为最终权重,生成器已学习到原始数据与处理后图像之间的非线性映射关系,并通过识别有效回波信号与其他干扰信号的特征,将干扰信号有效分离出来,并将剩余的反射回波特征重建为清晰的B-scan图像,而鉴别器逐渐无法准确辨别生成器的结果与真实结果。

2.3 网络测试

将未选入训练集的37组原始图像-处理后图像数据对作为测试集,用来测试训练好的生成式对抗网络的数据处理性能。测试流程为:原始图像输入生成器,得到生成器输出的处理后图像,然后将生成器处理图像与人工处理图像进行对比,以测试网络性能。以图5(a)中展示原始数据为例,图5(b)和图5(c)分别为使用训练好的网络和人工处理该原始数据得到的结果。可以观察到,二者在视觉上基本完全一致,网络对探地雷达数据中复杂的钢拱架反射波形进行了正确的重建,初衬脱空回波等图像细节也基本从干扰信号内恢复,同时,网络也自动对探地雷达信号进行了增益和平滑处理。

通过对网络处理测试集内37组数据对的处理结果进行定量评估,网络处理结果与原始数据之间的平均信噪比(signal-to-noise ratio, SNR)为0.58 dB,而使用人工处理得到的探地雷达图像,与原始图像间的平均信噪比为0.59 dB。平均信噪比越大,代表有效信号强度水平越高于无干扰信号强度水平,该结果定量地证明了网络处理原始数据的性能和人工处理效果一致。另外,生成式对抗网络在处理所有37张原始图像仅耗时2.87 s,而人工

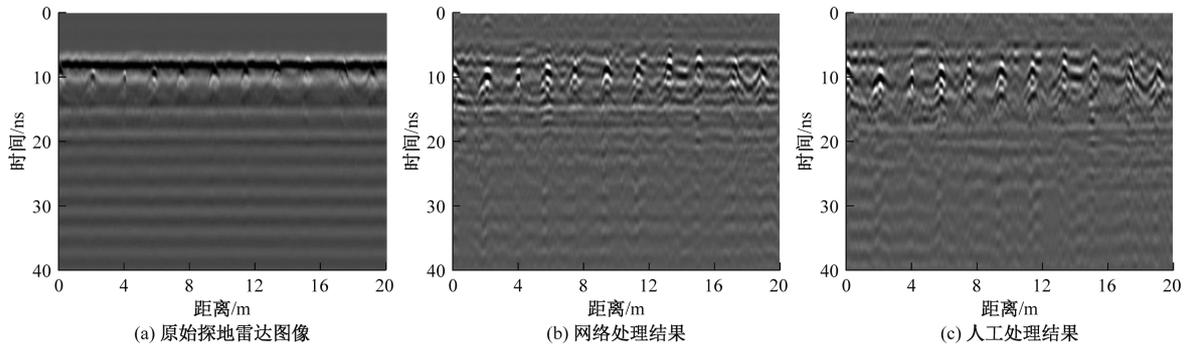


图5 网络数据处理性能测试结果

处理这些数据则需要约 123 s,如果使用的处理软件不支持批处理功能,每次只处理单张原始图像,处理时间还会大大加长。可见,使用本文提出的基于生成式对抗网络的探地雷达处理方法,可以在保证处理效果的前提下,极大提高探地雷达数据处理工作的效率。

3 结论

针对传统探地雷达数据处理工作中人工处理流程烦琐、对技术人员经验知识要求高等问题,基于生成式对抗算法,提出了一种隧道衬砌探地雷达数据智能处理网络。

该网络由多个不同分辨率的生成器与鉴别器组成,其中低分辨率的生成器与鉴别器负责接收小尺寸的探地雷达原始数据,从中提取关于有效回波和干扰信号的全局特征,并保证重建出探地雷达图像在整体上的和谐性。高分辨率生成器与鉴别器则用来处理大尺寸的探地雷达数据,进一步对局部细节进行修饰,从而实现由探地雷达原始数据到具有清晰回波信号的处理后图像之间的端到端自动转换。

该网络在工程实测数据处理任务中得到了成功应用,以信噪比为指标对结果进行评估,网络处理原始数据的效果与人工处理效果基本相当,但网络处理数据的效率要远远优于人工处理方式,大幅度节省了内业数据处理的时间与工作量,并且该方法无须手动输入参数,避免了对技术人员主观经验的依赖。

参考文献

- [1] 殷岱,梅深. 2022年交通运输行业发展统计公报[J]. 水道港口, 2023, 44(6): 1002-1006.
- [2] 巩江峰,王伟,王芳,等. 截至2023年底中国铁路隧道情况统计及2023年新开通重点项目隧道情况介绍[J]. 隧道建设(中英文), 2024, 44(2): 377-392.
- [3] 李俊,张鼎博,张昕炜,等. 基于光纤光栅传感与视频位移计技术的运营期铁路隧道结构安全监测[J]. 激光与光电子学进展, 2023, 60(23): 177-185.
- [4] 吕春林. 探地雷达检测技术在隧道初期支护检测中的应用[J]. 北方交通, 2023(6): 75-78.
- [5] 任永强,段兴龙. 探地雷达在隧道衬砌质量检测中的应用研究[J]. 甘肃科技纵横, 2023, 52(2): 54-58.
- [6] 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(S1): 627-634.
- [7] 潘贵,侯忠非. 三维探地雷达技术在沉陷成因探测及处治效果评价中的应用[J]. 科技和产业, 2024, 24(3): 180-186.
- [8] 林皓,肖建平,刘志航,等. 基于深度学习的铁路路基雷达检测信号中强干扰压制方法研究[J]. 地球物理学进展, 2023, 38(6): 2714-2723.
- [9] FOROOZAN F, ASIF A. Time-reversal ground-penetrating radar: range estimation with Cramer-Rao lower bounds[J]. IEEE Transactions on Geoscience and Remote Sensing, 2010, 48(10): 3698-3708.
- [10] RASHED E A. GPR background removal using a directional total variation minimisation approach[J]. Journal of Geophysics and Engineering, 2015, 12(6): 897-908.
- [11] 杨洁,王云龙,张雪,等. 基于正演模拟的地下典型目标体探地雷达图像特征分析与评价[J]. 科学技术与工程, 2023, 23(20): 8540-8551.
- [12] 王庆. 探地雷达应用于隧道检测技术的波形识别[J]. 工程技术研究, 2017(9): 126-127.
- [13] 刘秋卓,丁浩. 基于GPRMAX正演模拟的关于探地雷达空气耦合天线在隧道衬砌质量检测中的可行性研究[J]. 公路交通技术, 2018, 34(4): 95-101.
- [14] LUO J, LEI W, HOU F, et al. GPR B-scan image denoising via multi-scale convolutional autoencoder with data augmentation[J]. Electronics, 2021, 10(11): 1269.
- [15] 吴延凯,卢旭,魏育奇,等. 基于无损检测技术的白加黑路面病害探测与评价[J]. 科技和产业, 2022, 22(8): 329-335.
- [16] 李鹏晶. 探地雷达在公路工程检测中的应用分析[J]. 价值工程, 2022, 41(15): 144-146.

- [17] 王卫光, 乔旭, 杨峰. 探地雷达在华阳一矿隐伏陷落柱构造探测中的应用[J]. 煤矿现代化, 2024, 33(2): 64-67, 72.
- [18] 齐善鲁, 范宝德, 张迪. 改进小波阈值去噪算法在 GPR 数据处理中的应用[J]. 电子测量技术, 2023, 46(1): 17-24.
- [19] 吴学礼, 王壮壮, 习炳权, 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.
- [20] 唐伟. 隧道工程车载探地雷达检测应用分析[J]. 广东建材, 2024, 40(3): 63-65.
- [21] 闫永峰. 探地雷达在水利工程隧道衬砌脱空质量检测中的应用[J]. 广东水利水电. 2023(2): 15-19.
- [22] SHIN H, ROTH H R, GAO M, et al. Deep convolutional neural networks for computer-aided detection; CNN architectures, dataset characteristics and transfer learning[J]. IEEE Transactions on Medical Imaging, 2016, 35: 1285-1298.
- [23] HE X, WANG C, ZHENG R, et al. GPR image denoising with NSST-UNET and an improved BM3D[J]. Digital Signal Processing, 2022, 123: 103402.
- [24] WEN L, LI X, GAO L. A transfer convolutional neural network for fault diagnosis based on ResNet-50 [J]. Neural Computing & Applications, 2020, 32: 6111-6124.
- [25] SZEGEDY C, IOFFE S, VANHOUCKE V, et al. Inception-v4, Inception-ResNet and the impact of residual connections on learning[C]//Proceedings of the AAAI Conference on Artificial Intelligence. San Francisco: AAAI, 2017: 4278-4284.
- [26] BAILI J, LAHOUAR S, HERGLI M, et al. GPR signal de-noising by discrete wavelet transform[J]. NDT & E International, 2009, 42(8): 696-703.
- [27] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial networks[J]. Communications of the ACM, 2020, 63(11): 139-144.
- [28] ISOLA P, ZHU J, ZHOU T, et al. A image-to-image translation with conditional adversarial networks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, Hawaii: IEEE, 2017: 1125-1134.
- [29] WANG T, LIU M, ZHU J, et al. High-resolution image synthesis and semantic manipulation with conditional GANs[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Salt Lake City: IEEE, 2018: 8798-8807.

An Intelligent Processing Method for Tunnel Lining Ground Penetrating Radar Data Based on Generative Adversarial Network

NING Changyuan¹, SUN Hongpeng¹, ZHANG Donghao², SHI Weijian³, ZHANG Siyuan³, QIN Hui²

(1. Longjian Road and Bridge Co., Ltd., Harbin 150036, China;

2. School of Infrastructure Engineering, Dalian University of Technology, Dalian 116024, Liaoning, China;

3. Longjian Road and Bridge First Engineering Co., Ltd., Harbin 150000, China)

Abstract: Ground penetrating radar(GPR) is widely used for inspecting the quality of tunnel linings. However, the raw GPR data often cannot be directly interpreted and requires various pre-processing such as denoising, gain adjustment, and image smoothing to observe meaningful information. Considering that GPR data processing is currently predominantly manual, with a complex workflow and subjective parameter selection, an end-to-end data processing method is proposed based on generative adversarial network(GAN) that transforms raw GPR data into images with clear signals. The GAN consists of a series of generators and discriminators at different scales, capable of intelligently recognizing both global and local features of GPR data and automatically performing comprehensive processing operations on the raw data. This method has been successfully applied to the processing of actual GPR data for initial lining quality inspection, achieving results comparable to manual processing and a significantly higher data processing efficiency.

Keywords: tunnel lining; ground penetrating radar; data processing; deep learning; generative adversarial network