

논문

## 기계학습 기반 회절파 분리 적용을 통한 GPR 탐사 자료의 도로 하부 공동 및 구조물 탐지 성능 향상

김수윤 · 변중무\*

한양대학교 자원환경공학과

### Improvement of Underground Cavity and Structure Detection Performance Through Machine Learning-based Diffraction Separation of GPR Data

Sooyoon Kim and Joongmoo Byun\*

Department of Earth Resources and Environmental Engineering, Hanyang University

#### 요약

최근 도심지 도로에서 빈번하게 발생하는 도로 파임의 주원인인 지하 공동의 발생을 파악하기 위해, 차량 부착형 지표투과레이더(GPR)를 통해 얻은 대량의 취득 자료를 효율적으로 처리하기 위한 기계학습 기반 공동 탐지 기술이 활발하게 연구되고 있다. 그러나 기계학습 자료 생성 시 단순한 영상 처리 기법들만 활용되고 있고, 탄성파 탐사나 GPR 자료 처리에 시도되었던 여러 기법들은 충분히 활용되지 못하고 있다. 이 연구에서는 지하 공동의 탐지가 대부분 회절파의 탐지에 의해 이루어진다는 점에 착안하여 GPR 자료로부터 회절파를 분리하여 YOLO v5 모델을 이용한 도로 하부 공동 탐지 모델의 성능을 향상시켰다. 탄성파에서 개발된 기계학습 기반 회절파 분리 기법을 GPR 자료에 맞게 변형한 후, GPR 현장 자료에서 회절파를 분리하여 공동 탐지 모델의 입력으로 사용하였다. 서울시 공공 개방 GPR 자료를 이용하여 제안된 방법의 성능을 검증한 결과, 회절파 분리를 이용했을 때 더 정확하게 공동 및 지하 구조물을 탐지하는 것을 확인하였다. 또한 제안된 회절파 분리 기법은 향후 GPR 탐사가 이용되는 다양한 분야에서 활용될 수 있을 것으로 기대된다.

#### 주요어

지표투과레이더, 도로 하부 공동, 기계학습, 객체탐지, 회절파 분리

#### ABSTRACT

Machine learning (ML)-based cavity detection using a large amount of survey data obtained from vehicle-mounted ground penetrating radar (GPR) has been actively studied to identify underground cavities. However, only simple image processing techniques have been used for preprocessing the ML input, and many conventional seismic and GPR data processing techniques, which have been used for decades, have not been fully exploited. In this study, based on the idea that a cavity can be identified using diffraction, we applied ML-based diffraction separation to GPR data to increase the accuracy of cavity detection using the YOLO v5 model. The original ML-based seismic diffraction separation technique was modified, and the separated diffraction image was used as the input to train the cavity detection model. The performance of the proposed method was verified using public GPR data released by the Seoul Metropolitan Government. Underground cavities and objects were more accurately detected using separated diffraction images. In the future, the proposed method can be useful in various fields in which GPR surveys are used.

#### KEYWORDS

Ground penetrating radar, Underground cavity, Machine learning, Object detection, Diffraction separation

Received: 16 August 2023; Revised: 12 September 2023; Accepted: 27 September 2023

\*Corresponding author

E-mail: jbyun@hanyang.ac.kr

Address: 222, Wangsimni-ro, Seongdong-gu, Seoul, Republic of Korea

©2023, Korean Society of Earth and Exploration Geophysicists

This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

## 서론

지표투과레이더(ground penetrating radar, GPR) 탐사는 레이더파를 이용하여 수 미터 심도 내외의 지하구조를 영상화할 수 있는 탐사법이다. GPR 탐사는 도로 안전(e.g., Kang *et al.*, 2020), 문화재(e.g., Oh *et al.*, 2019), 암반 절리면(e.g., Arosio, 2016), 터널 벽체(e.g., Choo *et al.*, 2019), 제방 안전(e.g., Chlaib *et al.*, 2014) 등의 조사에 다양하게 이용되고 있는데, 이 중 도로안전 분야에서는 최근 빈발하는 지반침하 사고로 인해 지하안전에 대한 평가를 위한 GPR 탐사가 지하안전관리에 관한 특별법으로 제정되면서 더욱 활발히 이용되고 있다. 특히 서울시의 경우 도로 및 도로 주변에서 매년 많은 공사가 이루어지고 도로의 교통량도 많기 때문에 시민 안전을 위해 주기적인 탐사 및 해석이 이루어지고 있다.

일반적으로 도로에서의 GPR 탐사는 차량형 다채널 GPR 장비로 신속하게 넓은 면적에 대해 자료를 취득한 후, 의심 영역에 대해 핸드형 장비로 정밀 탐사를 수행한다. 그러나 넓은 탐사 영역에서 방대한 양의 자료가 취득되기 때문에 전문가에 의한 직접적인 처리 및 해석에 한계가 있다(Kang *et al.*, 2020). 최근 이러한 반복 작업에 큰 효과를 보이는 기계학습 기법의 접목이 활발하게 진행되고 있다(e.g., Mehta *et al.*, 2021; Jeong *et al.*, 2022). 기계학습 기반 기법은 해석자의 주관적인 판단을 배제한 일관성 있는 해석 결과를 신속하게 제공하기 때문에, 1단계 탐사 자료에 적용하려는 많은 시도가 있었다(e.g., Choi *et al.*, 2022; Lee *et al.*, 2022; Zhu *et al.*, 2023).

기계학습 기반의 공동 탐지 기법들은 주로 특정한 신호 패턴을 기준으로 탐지하도록 학습시키는데, 도로 GPR 탐사의 주 관심사인 관로와 공동은 지하 매질과의 큰 물성 차와 고립된 구조로 인해 탐사 자료에서 주로 쌍곡선 형태의 회절파로 나타난다(Yoon *et al.*, 2016; Kim *et al.*, 2017; Kim *et al.*, 2021). 따라서 회절파 탐지에 초점을 맞춰 관로 또는 공동의 유무를 파악하기 위해 많은 연구가 진행되었는데, 초기에 진행된 연구에서는 2차원 단면 형태의 입력에 대해 Inception V1 (Chae *et al.*, 2019), Convolutional Support Vector Machine (Ozkaya *et al.*, 2020), Faster R-CNN (Gao *et al.*, 2021) 등 CNN (Convolutional Neural network) 기반의 다양한 종류의 기계학습 모델을 이용하여 공동 탐지를 수행했다.

그러나 입력 자료의 변화 없이 기계학습 모델만을 개선시킬 경우에는 성능 향상에 한계가 있기 때문에, 최근에는 공동의 고립된 구조를 좀 더 명확히 보여주는 3차원의 입력 자료를 2차원 자료와 동시에 이용할 수 있도록 하는 연구가 제안된 바 있다. Son *et al.* (2021)과 Li *et al.* (2023)의 연구는 3차원 GPR 자료를 입력으로 이용하여 공동의 위치를 탐지했으며, Kang *et al.* (2019)과 Kim *et al.* (2021)의 연구에서는 3차원 자료를 특정 형태의 2차원 자료로 변환하여 이용하였다. 이처

럼 3차원 탐사 자료를 기계학습 모델의 입력으로 이용할 경우, 2차원 단면만으로는 파악하기 어려운 공동의 형태를 구분할 수 있다는 장점이 있다. 그러나 입력 자료의 크기가 커지면서 기계학습 모델의 변수 또한 증가하여야 하고 학습 및 적용에 많은 시간과 비용이 소요된다는 문제점이 존재한다. 특히 학습을 위하여 정형화된 형태와 일정한 품질을 갖는 정답이 표시된 라벨링(labeling)된 자료를 준비하기 위해서는 많은 양의 탐사자료의 처리 및 숙련된 전문가에 의한 정확한 해석과 확인 절차가 필요하므로 이러한 형태의 자료를 확보하는 것은 매우 어렵다.

3차원 자료를 활용하는 방법의 어려움으로 인해, 2차원 자료의 전처리를 통해 객체 탐지 성능을 향상시키는 방법도 꾸준히 제안되고 있다. Benedetto *et al.* (2017)은 도로 조사에서 이용될 수 있는 기본적인 전처리 방법들을 소개했으며, Son *et al.* (2021)은 명암비 조절을 통한 자료 증대 기법을 이용했다. Yue *et al.* (2022)은 자료 증대를 위해 colour space transformation을 이용했으며, Ma *et al.* (2023)은 texture feature를 이용하여 분류 성능을 향상시켰다. 이렇듯 이제까지의 대부분의 연구는 최근 영상 처리에서 활용되는 방법들을 GPR 자료에 적용시켜 기계학습모델의 객체분리 성능을 향상시키는데 주력해 왔다. 그러나 이러한 간접적인 전처리 방법이 아닌 탐지하려는 목표물의 자료를 직접적으로 분리해 낼 수 있는 전처리 기법인 회절파 분리 기법과 같은 시도는 이루어지지 않았다.

GPR 자료는 탄성과 자료와 유사한 특성을 갖기 때문에 많은 연구에서 탄성과 탐사 자료에서 이용되었던 자료처리 기법을 GPR 자료처리에 이용하였다(Baker *et al.*, 2001). Schwarz (2019)는 GPR 탐사 자료 해석의 목표물이 되는 신호가 주로 회절파로 나타난다는 점에 주목하여 탄성과 자료를 위해 개발된 일관성을 이용한 회절파 분리 기법이 GPR 자료의 회절파를 정확하게 분리하는 것을 보여주었다. 또한 De Figueiredo (2013)의 연구에서는 탄성과 자료에서 회절파 궤적에서의 진폭 특성 분석 기법을 통한 회절원 영상화 기술이, GPR 자료에서 교량 하부의 배수관의 위치를 정확하게 파악하는 것을 보여주었다. 이와 같이 탄성과 자료에 적용되는 회절파 분리 기술은 GPR 자료의 전처리에 유용하게 이용될 수 있으며 이렇게 분리된 회절파를 공동탐지 기계학습모델의 입력 자료로 활용한다면 객체탐지 성능 향상에 기여할 수 있을 것이다.

이 연구에서는 2차원 GPR 탐사 자료에서의 도로 하부 공동 탐지 성능을 향상시키기 위해, 2차원 GPR 자료로부터 회절파를 분리한 후 2차원 자료와 함께 공동 탐지 모델의 입력 자료로 이용했다. GPR 자료에서의 정확한 회절파의 분리를 위해, 탄성과 자료의 회절파 분리를 위해서 제안된 기계학습 기반 회절파 분리 기법(Kim *et al.*, 2022)을 GPR 자료에 맞게 개선하여 이용하였다. 기존의 연구에서는 반사파와 회절파의 기본적인 특징을 갖는 일정 크기의 패치(patch)로 학습시킨 기계학

습 모델로 회절파를 분리하였으며 전이학습(transfer learning)을 통해 현장 자료에 대한 적용성을 향상시켰지만, 이 연구에서는 GPR 자료에 회절파 분리 기법을 적용할 수 있도록, GPR 자료 특성에 맞는 학습 자료를 생성 후 전이학습을 통해 기계학습 모델을 학습시켰다. 이 때 GPR 자료로는 서울시에서 제공하는 GPR 탐사 자료(<https://aihub.or.kr>)를 이용하였다. 학습된 회절파 분리 기계학습 모델을 통해 현장 GPR 자료의 회절파를 분리하였으며, 분리된 회절파를 이용하여 개선된 입력 자료를 통해 기존에 많은 연구에서 제시되었던 YOLO v5 기반의 도로 하부 공동 탐사 알고리즘의 성능을 향상시켰다. 마지막으로 개선된 자료로 학습된 공동 탐사 알고리즘의 서울시 자료에 대한 공동 탐지 성능을 평가하였다.

### 차량형 GPR 탐사 및 기계학습 기반 공동 탐지

#### 도로 하부 이상체 탐지를 위한 차량형 GPR 탐사 장비

최근 도로 GPR 탐사에는 차량 부착형 3차원 GPR 탐사 장비가 주로 이용되어 넓은 지역에 대해 빠르게 3차원 탐사 자료를 획득할 수 있다. 3차원 탐사 장비에서 획득되는 자료는 신호의 형태에 따라 A-scan, B-scan, C-scan, D-scan으로 구분한다(Fig. 1). A-scan은 단일 채널에서 획득되는 신호를 나타내며, B-scan은 장비 진행 방향에 평행인 단면에 대한 A-scan

자료의 집합이다. C-scan은 일정한 진행 거리에 대해 B-scan을 모은 볼륨에서 특정 기록 시간에 대한 단면이며, D-scan은 장비 진행 방향에 수직인 단면이다(Fig. 1).

도로 GPR 탐사에서 찾고자 하는 주대상체는 도로 하부 공동이며 주로 B-scan에서 회절파로 나타난다. 따라서 공동 탐지는 대부분 회절파의 탐지 및 분석에 초점을 맞춰 진행된다. 하지만 실제 차량형 GPR 탐사 장비에서 취득된 자료는 매우 넓은 탐사 구간에서 취득되고 공동 이외에도 다수의 회절파가 존재하기 때문에 전문가가 모든 자료에서 직접 공동의 위치를 분석하는 데 많은 어려움이 있기 때문에, 영상처리에 특화된 기계학습 기법을 도입하여 객체 탐지를 빠르고 정확하게 수행할 수 있도록 다양한 기법들을 활용하는 것이 중요하다. 일반적으로 기계학습 기반의 객체 탐지에 사용되는 모델은 두 계열로 나뉘는데, 영역 추정 단계와 분류 단계를 두 단계로 나눠서 수행하는 R-CNN (Girshick *et al.*, 2013), Pyramid networks (Lin *et al.*, 2017)과 같은 계열, 그리고 두 가지 작업을 한 단계로 처리하는 YOLO (Redmon *et al.*, 2016), SSD (Liu *et al.*, 2016) 계열이다. 특히 YOLO 모델은 영역 추정 및 분류를 동시에 수행하여 객체 탐지 속도가 빠르기 때문에, 도로 GPR 탐사 자료에 대한 공동 탐지 분야에서 꾸준히 사용되고 있다(e.g., Mehta *et al.*, 2021; Choi *et al.*, 2022; Jeong *et al.*, 2022; Lee *et al.*, 2022; Zhu *et al.*, 2023).

#### YOLO v5 객체탐지 모델을 이용한 도로 하부 공동 및 구조물 탐지

이 연구에서 제안하는 회절파 분리 방법을 통한 공동 탐지 성능 향상 효과를 검증하기 위해, 기존 연구들에서 제시되었던 YOLO 알고리즘 기반 도로 하부 공동 탐지 모델을 이용하였다. YOLO 알고리즘은 최근 공개된 v8을 포함하여 각 버전마다 성능 및 속도에 대한 개선이 이루어져 왔다. 이 연구에서는 분리된 회절파 영상의 추가로 인한 공동 탐지 성능의 향상을 검증하기 위해, 그동안 많은 연구에서 사용된 YOLO v5 모델을 이용하였다. YOLO v5는 2020년 Ultralytics에 의해 오픈소스로 공개되었으며(<https://github.com/ultralytics/yolov5>), 모델의 구조는 크게 backbone, neck, head의 3가지로 구분할 수 있다(Fig. 2).

먼저 backbone에서는 사전 학습된 네트워크를 이용하여 입력 영상으로부터 중요한 특징들을 추출한다. 이 구조는 사전에 학습된 모델을 이용하며 YOLO v5에서는 cross stage partial network (CSPNet; Wang *et al.*, 2020) 기반의 특징 추출 모델을 이용하였다. Neck에서는 backbone에서 전달된 특징을 정제 및 재수집하여 head로 전달하며 PAN (path aggregation network; Liu *et al.*, 2018) 구조가 이용되었다. 마지막으로 head에서 중심 좌표와 너비, 높이로 정의되는 앵커박스 및 객체 분류 확률 등의 최종 벡터를 출력한다. 최종 출력은 세 가지 스케일에서의 예측 결과이며 각 스케일의 그리드 셀마다 경계상자의 위치에 대한 정보, 객체가 경계상자 안에 존재할

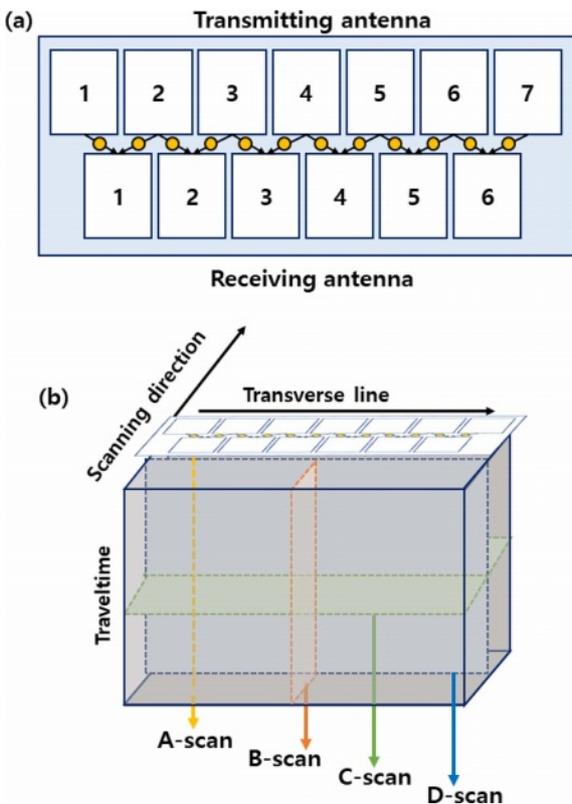


Fig. 1. (a) Schematic of transmitting and receiving antenna array of 3D GPR and (b) concepts of A-, B-, C- and D-scan in GPR data.

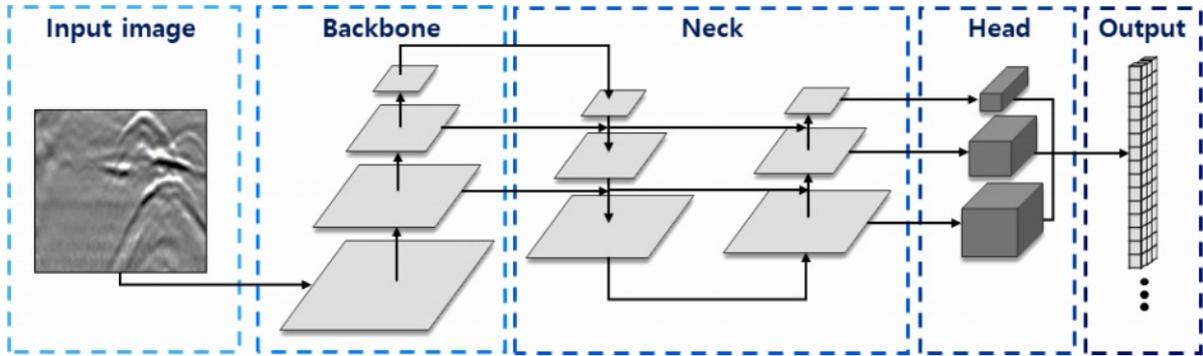


Fig. 2. Architecture of YOLO v5 model.

신뢰도, 각 클래스에 속할 확률로 구성된다(Fig. 2). 따라서 손실함수는 경계상자의 위치에 대한 항, 검출 객체의 신뢰도에 대한 항, 클래스를 분류하기 위한 항으로 총 3가지 함수의 조합으로 구성된다.

YOLO v5 모델은 학습 파라미터 수에 따라 YOLO v5n, YOLO v5s, YOLO v5m, YOLO v5l, YOLO v5x의 다섯 가지 버전으로 제공되며, 이 연구에서 이용된 YOLO v5m 모델의 경우 중간 정도의 정확도와 예측 속도를 보인다. YOLO 모델에서는 탐지된 객체의 정확도 평가지표로 mAP (mean average precision)를 이용한다. mAP는 검출 결과 중 정답과 일치하는 결과의 비율인 정밀도 지표(precision; 식 (1))와 정답 중 정확하게 검출된 비율을 나타내는 재현율 지표(recall; 식 (2))로부터 도출되며, 두 지표는 IoU (intersection over union) 값(Fig. 3)에 대해 교집합 영역을 정의하는 특정 임계값을 기준으로 검출 여부를 판단한다.

$$\text{Precision} = \frac{(\text{True positive})}{(\text{True positive})+(\text{False positive})} \quad (1)$$

$$\text{Recall} = \frac{(\text{True positive})}{(\text{True positive})+(\text{False negative})} \quad (2)$$

일반적으로 정밀도와 재현율 지표는 반비례 관계를 보이기 때문에, 정확한 평가를 위해 정밀도-재현율 그래프의 면적으로

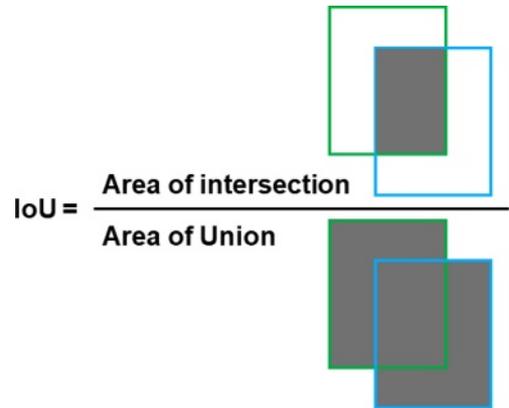


Fig. 3. Definition of intersection over union (IoU).

부터 AP를 계산한다. 이 연구에서는 서울시 도로 하부 GPR 자료에 대한 YOLO v5모델의 성능을 IoU가 0.5 이상일 때 참 긍정으로 정의하는 mAP@0.5 지표를 통해 제시한 연구(Jeong *et al.* (2022)를 참고하여, mAP@0.5 지표를 이용하여 YOLO 모델의 도로 하부 공동 탐지 성능을 평가했다.

### 기계학습 기반 회절파 분리

도로 하부에서 나타나는 공동의 경우 GPR 탐사 자료에서

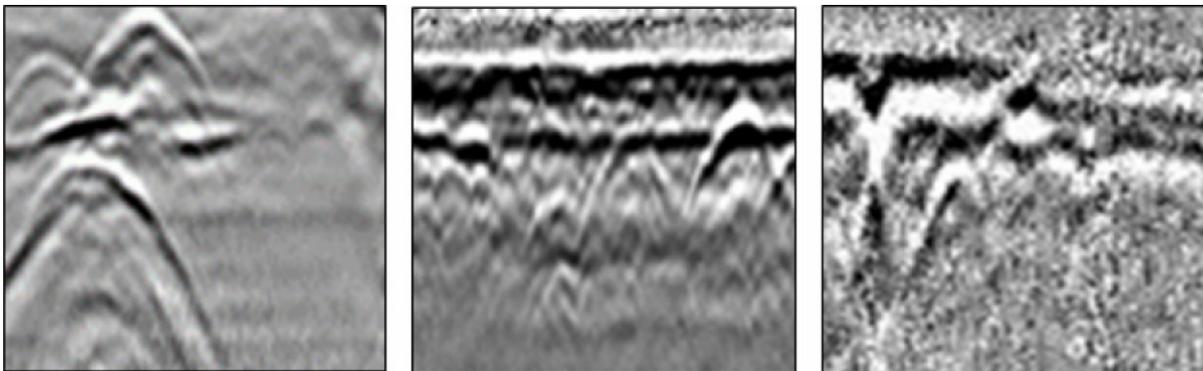


Fig. 4. Examples of road GPR data that show various diffraction patterns.

주로 회절파나 회절파의 중첩된 형태로 나타나는데, 공동의 형태나 지하 매질의 상태에 따라 회절파의 형태가 다양하게 나타난다. 실제 도로 GPR 탐사 자료에서 나타나는 회절파의 다양한 형태(Fig. 4)를 보면, 현장 자료에서는 회절파의 쌍곡선 끝 부분의 감쇠 차이나 회절파 사이의 중첩의 영향으로 인해 주로 비대칭 형태이다. 실제 서울지역 공동 30개소에 대해 조사한 결과 절반 정도가 불규칙한 형태를 보이며(Hong *et al.*, 2022), 대부분의 회절파가 반사면에 대한 신호들과 복잡하게 중첩되기 때문에 객체 탐지 모델이 정확하게 회절파 신호만을 포착하기 어렵다. 따라서 많은 신호들 사이에서 불규칙한 형태의 회절파만을 정확하게 분리해서 입력 자료로 활용한다면 기계학습모델의 학습에 큰 도움을 줄 가능성이 크다.

전통적으로 탄성파 자료의 회절파 분리에 쓰였던 방법들의 경우, 회절파와 반사파가 중첩되는 부분에서 분리 성능이 떨어지는 문제가 알려져 있지만, Kim *et al.* (2022)에서 제시한 기계학습 기반 탄성파자료 회절파 분리 방법의 경우 중첩되는 부분까지 진폭과 위상을 정확하게 분리하고 신호의 왜곡을 최소화하였다는 장점이 있다. 또한 기계학습 기반 방법이기 때문에 학습이 완료된 후 실제 현장에서의 적용이 매우 빠른 장점이 있기 때문에, 이 연구에서는 회절파 분리 방법(Kim *et al.*, 2022)을 기초로 하여 GPR 자료에서 회절파를 정확하게 분리하는 방법을 이용하고 분리된 회절파를 도로 하부 공동 탐지 모델에 입력 자료로 이용하였다.

**회절파 분리 방법**

회절파 분리 방법(Kim *et al.*, 2022)은, 탄성파 자료가 동일 벌림 모음자료(common offset data)에서 회절파의 경우 감쇠가 심한 쌍곡선 형태로 나타나고 반사파의 경우 감쇠가 적은 직선 또는 곡선 형태로 나타난다는 점에 착안하여, 기계학습 모델로 쌍곡선 형태의 회절파만을 분리해내는 방법이다. 그리고 학습에 동일 벌림 모음자료 전체 이미지가 아닌 일부분의 패치(patch) 형태를 사용하여 한 패치에 구현될 수 있는 다양한 형태의 반사파와 회절파 조합을 이용해 기계학습 기본 모델이 학습되어 있어, 새로운 자료에 적용시킬 때는 전이학습 기법을 이용하여 빠르게 재학습을 진행할 수 있는 장점이 있다.

**학습 자료의 생성**

기존의 회절파 분리 방법은 동일 벌림 모음자료(common offset data)에서 적용되는데 GPR의 B-scan 자료 또한 동일 벌림 모음자료에 해당하므로 바로 적용이 가능하다. 그러나 학습을 위해 생성된 인공 합성자료들은 탄성파 자료에서 나타나는 다양한 특성을 고려한 회절파와 반사파의 조합으로 생성되었지만 GPR 자료에서 나타나는 반사파와 회절파의 특성은 탄성파 자료와는 매우 다르다. 따라서 이 연구에서는 GPR 자료의 특성에 맞도록 학습 자료를 새롭게 생성하여 학습에 이용하였다.

탄성파 자료에서 나타나는 회절파는 인접한 반사파에 비해 진폭이 일반적으로 작게 나타나지만 GPR 자료에서 나타나는 회절파는 반사파와 비슷하거나 큰 진폭을 갖는다(Fig. 4). 또한 탄성파 자료의 회절파가 단층, 균열대, 암염 등에서 발생하며 쌍곡선의 정점이 반사파와 겹치는 반면에 GPR 자료의 회절파는 공동 또는 배관에서 나오는 경우도 많아 고립된 형태로 발생하는 경우도 고려해서 학습 자료를 생성해야 한다.

먼저 반사파의 생성을 위해 직선 또는 곡선 형태로 반사면 형태를 만든 후, 파형과의 합성곱을 통해 기본적인 반사파 신호를 만들었다. 여기에는 반사면의 경사, 곡률, 간격과 파형의 파장, 진폭 등을 특정 범위 내에서 다양하게 생성하여 여러 형태의 반사파 신호들이 만들어질 수 있도록 했다. 기본적인 회절파 신호 생성에는 정확한 쌍곡선 궤적 및 감쇠 형태의 모사가 필요하기 때문에 2차원 파동방정식의 유한차분법 기반 인공합성 모델링을 이용했으며, 회절파의 파장, 진폭, 쌍곡선 형태, 감쇠 경향을 특정 범위 내에서 생성했다.

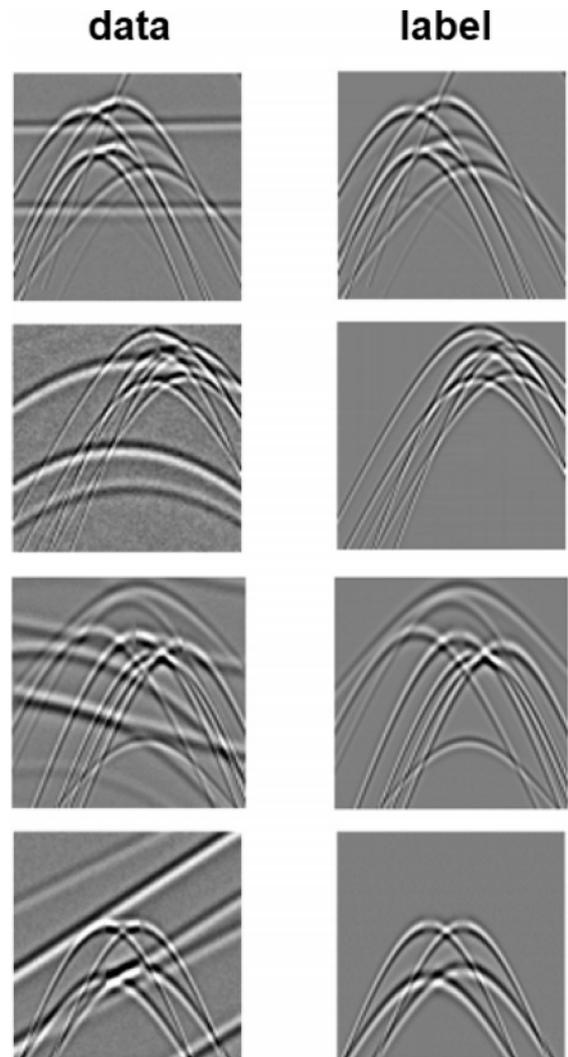


Fig. 5. Examples of newly generated training data for GPR data processing and their corresponding labels.

회절파가 충분히 나올 수 있도록 중첩 위치와 개수를 조절하며 반사파와 조합해서 GPR 자료에 적용 가능한 새로운 학습 자료(Fig. 5)를 만들었다. 실제 GPR 자료(Fig. 4)에서의 특성과 유사하게, 새로운 학습 자료에서는 대부분의 회절파의 정점 부분이 반사파와 중첩되고 소수의 고립된 회절파가 존재한다(Fig. 5). 새로운 학습 자료에 대응되는 정답 자료에는 반사파를 제외하고 회절파만이 존재하는 자료를 만들었다.

**기계학습 모델의 학습**

생성된 학습 자료에 대한 학습 과정에서는, 탄성과 회절분리를 위해 생성된 48,000개의 학습 자료로 미리 회절파의 분리가 학습되어있는 기계학습 모델에 대해, 원래 학습 자료 크기의 10% 정도에 해당되는 4,800개의 GPR 자료의 특성을 갖는 추가 자료를 통해 추가적인 학습을 시키는 전이 학습이 이용되었다. 다만 추가 학습 시 학습에 사용된 GPR 자료에 과적합 되는 것을 방지하기 위해 원래의 모델을 학습시킬 때 사용된 탄성과 자료의 특성을 갖는 자료들도 10% 혼합하여 사용하였다(Fig. 6). 이러한 전이 학습 방법은 기계학습 모델이 적은 학습 자료에 과적합 되는 문제를 방지하고 새로운 자료에 대한 예측 성능을 높일 수 있는 것으로 알려져 있다(Pan and Yang, 2010). 물론 회절파 분리 학습에 현장 GPR 자료를 다양하게 사용할 수 있다면 가장 높은 성능을 보이는 기계학습 모델을 얻을 수 있으나 학습의 정답 자료로 활용될 회절파가 분리된 GPR 자료를 만들기에는 여러 어려움이 따르므로 이 연구

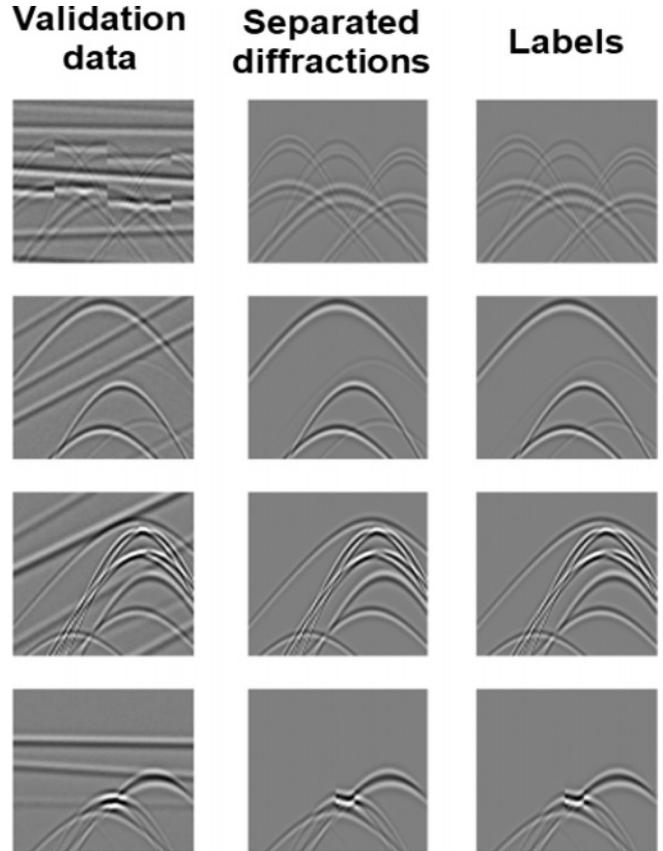


Fig. 7. Examples of diffraction separation results for validation dataset.

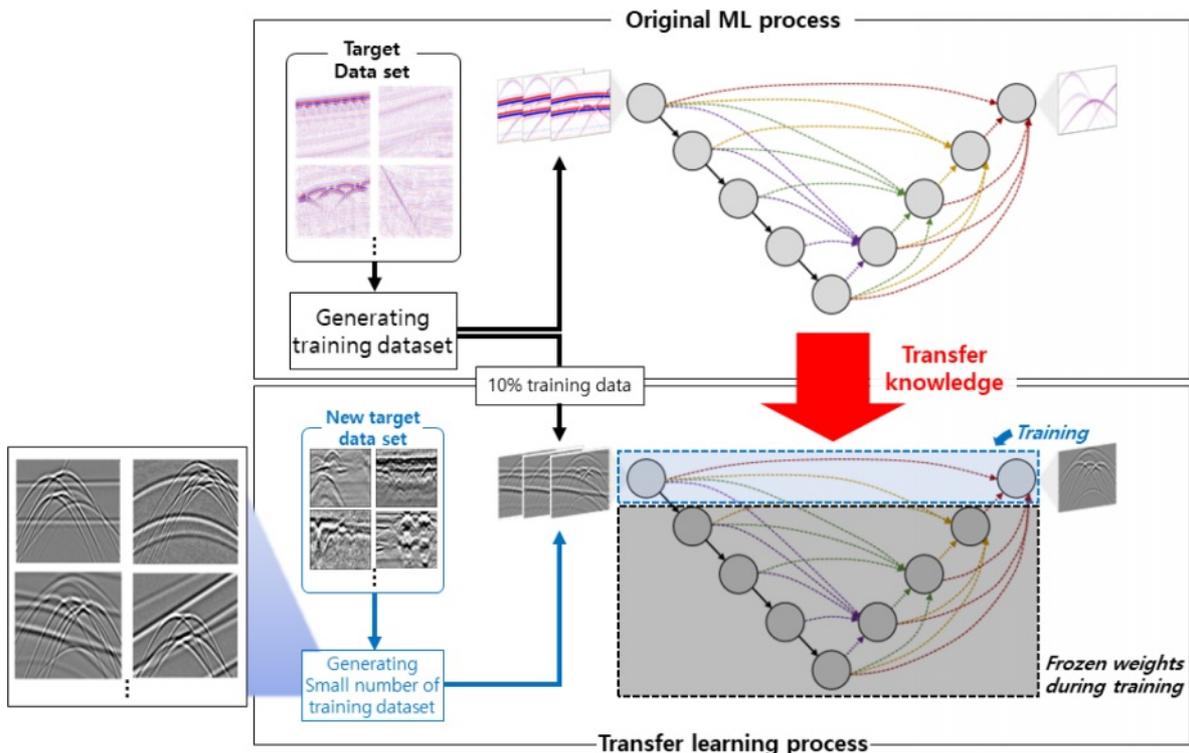


Fig. 6. Schematic diagram of transfer learning process using GPR data.

에서는 GPR 공동자료의 특성을 최대한 반영하는 합성자료를 이용하여 학습을 진행시켰다.

한편, 기계학습 모델의 구조는 영상 처리에서 뛰어난 성능을 보이는 Unet3+(Huang *et al.*, 2020) 구조를 수정하여 이용했으며 전이학습이 진행될 때는 입력과 출력에 가까운 합성곱 신경망들을 제외한 나머지 신경망이 학습되지 않도록 했다. 기계학습 처리 과정들은 Python의 Tensorflow 패키지를 이용해 수행했으며 모델의 학습이 완료된 후의 검증 자료(validation data)에 대한 회절파 분리 결과(Fig. 7)에서, 회절파와 반사파가 중첩되는 부분의 진폭 및 위상까지 정확하게 분리하는 것을 확인할 수 있었다.

### 서울시 자료에 대한 개발 알고리즘 적용 도로 하부 공동 및 물체 식별

#### 서울시 자료 소개

실제 현장 자료에서의 회절파 분리 결과 및 공동 탐지 성능의 변화를 확인하기 위해 서울시 GPR 탐사 자료를 이용했다. 서울시에서는 도로 하부 공동 탐지 알고리즘의 객관화된 성능 평가를 할 수 있도록 2015년부터 2022년까지 서울시에서 탐사된 GPR 자료 중 일부를 2023년에 AI Hub 사이트에 공개하였다(www.aihub.or.kr).

개발된 회절파 분리 알고리즘의 객관적인 성능 평가를 위해 이 연구에서는 2023년 4월 30일에 공개된 버전 1.0 자료를 이용했으며 제공되는 자료는 공동(대칭형, 비대칭형, 기타)과 비공동(맨홀, 종배관, 횡배관)을 포함하여 총 6개 클래스에 대해 B-scan과 C-scan 자료이다. 공개된 클래스별 자료의 개수(Table 1)는 동일한 위치에서의 B-scan과 C-scan 자료의 수가 일정하지 않아 일정한 형태의 3차원 입력 자료를 만들 수 없기 때문에 앞서 서론에서 설명한 것과 같이 3차원 자료를 입력 자료로 활용하는 데는 어려움이 있다. 이 연구에서는 제공되는 자료 중 B-scan 자료만을 이용하였으며 탐사 진행방향과

**Table 1.** Number of data for each class of Seoul open GPR data.

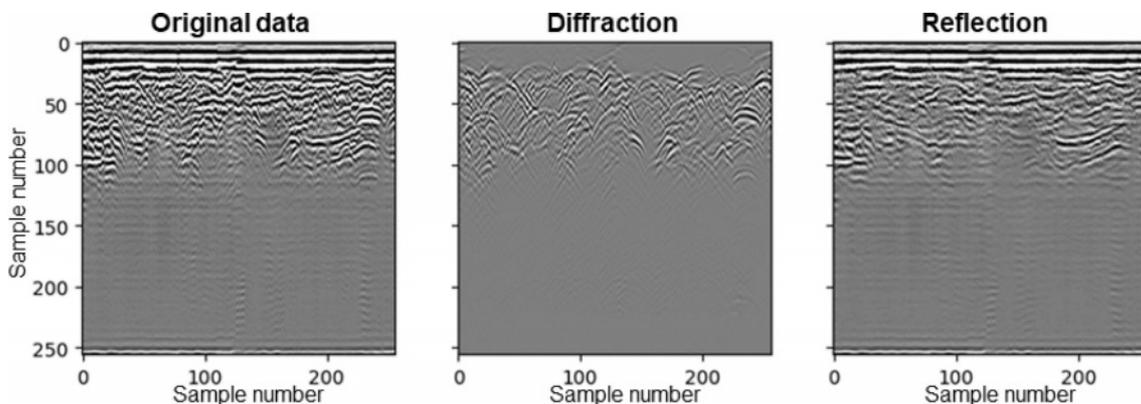
Type	Class	Number of B-scan	Number of C-scan
Training	Cavity (symmetric)	19,075	37,552
	Cavity (asymmetric)	11,205	20,107
	Cavity (others)	3,856	6,640
	Manhole	27,384	36,727
	Longitudinal pipe	3,650	2,023
	Transverse pipe	1,353	1,202
Validation	Cavity (symmetric)	2,384	4,694
	Cavity (asymmetric)	1,400	2,513
	Cavity (others)	482	830
	Manhole	3,423	4,590
	Longitudinal pipe	456	252
	Transverse pipe	169	150

나란히 있어 B-scan에서는 구분이 어려운 종배관 클래스는 제외하였다. 또한 일치하는 라벨링 자료가 존재하지 않는 B-scan 자료가 일부 존재하여 실제로는 총 62,830개의 자료를 이용하였다.

#### 회절파 분리

회절파 분리에는 3가지 파일을 모두 이용하였으며 제공된 자료가 0에서 255사이의 정수로 표현되는 자료형이기 때문에 회절파 분리 모델에 이용될 수 있도록 -1에서 1사이의 실수값으로 변환했다. 변환 시 신호가 없는 곳의 값이 0이 아닌 자료들은 0을 중심값으로 신호가 나타날 수 있도록 보정했다. 학습이 완료된 회절파 분리 모델에서 GPR 현장 자료의 회절파 분리를 진행했으며 분리 전, 후 및 전후 차이에 대한 예(Fig. 8)를 보면, 제안된 방법에 의해 분리된 회절파(Fig. 8b)가 복잡하게 뒤섞인 신호들 사이에서도 회절파만이 정확하게 분리된 것을 확인할 수 있다.

회절파 분리에 의해 얻어지는 자료(Fig. 8)는 회절파영상뿐



**Fig. 8.** Examples of prediction results for public GPR data released by the Seoul Metropolitan Government. Input, separated diffraction, and residual (reflection; originally separated diffraction) images are shown from left to right.

**Table 2.** mAP@0.5, precision, and recall scores of the YOLO v5-based cavity detection model for the original and pre-processed input data.

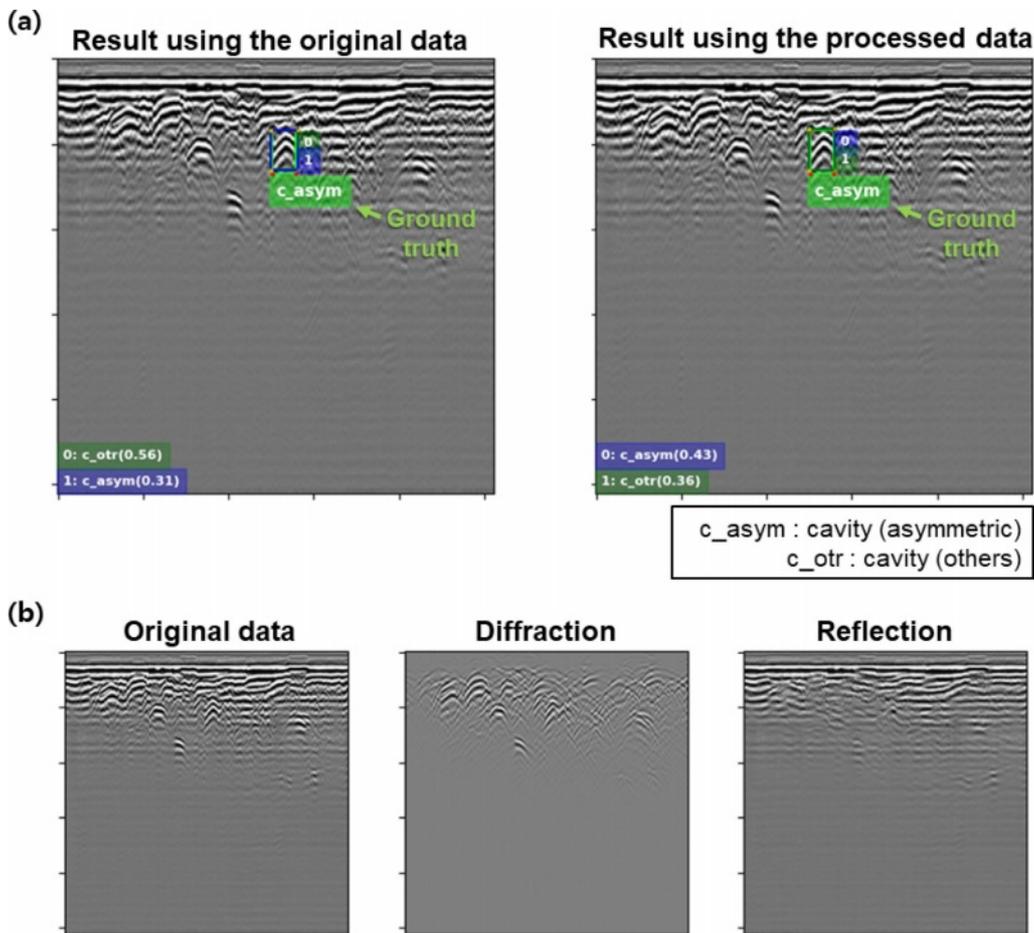
Class	Original input data			Pre-processed input data		
	mAP@0.5	Precision	Recall	mAP@0.5	Precision	Recall
All	0.564	0.538	0.636	0.611	0.481	0.732
Cavity (symmetric)	0.688	0.866	0.375	0.682	0.801	0.459
Cavity (asymmetric)	0.239	0.249	0.128	0.316	0.332	0.336
Cavity (others)	0.208	0.143	0.869	0.265	0.106	0.938
Manhole	0.693	0.64	0.811	0.836	0.564	0.927
pipe	0.994	0.791	1.0	0.956	0.604	1.0

만 아니라 원 자료에서 분리된 회절파를 빼서 얻을 수 있는 반사파영상도 있다. 이 연구에서는 YOLO v5 객체 탐지 모델의 입력 자료로 활용하기 위해 분리전의 원 자료와 분리에 의해 얻어진 회절파자료 및 반사파자료 세 가지를 병합하여 한 개의 RGB 영상 파일로 만들었다. 이 연구에서 제시된 회절파 분리 모델은 공동뿐만이 아닌 도로 하부에 존재하는 자갈, 콘크리트층 등으로부터 나온 회절파도 정확하게 분리한다. 따라서 공동에서 나타난 회절파에 대해서만 객체 탐지 모델이 학습할

수 있도록 분리 전의 신호들과 반사파에 대한 정보도 입력 자료로 함께 사용하였다.

### 공동 탐지 성능 평가

전처리된 입력 자료에 의한 공동 탐지 성능 향상 효과를 검증하기 위해, 전처리하지 않은 원 자료를 이용한 실험과 동일한 조건 하에서 YOLO v5 모델을 학습 및 비교하였다. 여기서 두 실험의 학습 및 검증 자료 구성, 기계학습 모델의 초모



**Fig. 9.** (a) Comparison of cavity detection performance in the cavity (asymmetric) class using original and processed data. (b) Original image, separated diffraction image predicted using proposed diffraction separation method, and reflection image calculated by subtracting the separated diffraction image from the original image.

수(hyperparameter) 설정을 동일하게 하였고, 원 자료를 이용한 입력 자료에서 원 자료로 RGB 3개의 채널을 구성하여 입력 채널 개수를 동일하게 설정했다.

전처리된 입력 자료를 이용한 공동 탐지 모델의 학습 결과는 전처리하지 않은 자료에서의 결과에 비해 전체적인 공동 탐지 성능이 향상되었다(Table 2). 대부분의 클래스에 대해 mAP@0.5 성능 지표가 상승한 것을 확인할 수 있으며 특히 비대칭형, 기타형 공동 및 맨홀 클래스에 대한 성능이 크게 향상되었다. 특히 대부분의 클래스에서 정밀도는 감소하고 재현율은 증가하는 양상을 보였는데, 회절파와 반사파를 입력 자료에 이용함으로써 공동 탐지 모델이 양성으로 판단하는 경우를 증가시키는 방향으로 개선되고 재현율이 비교적 크게 상승하면서 전체 성능 향상으로 이어졌다. 공동 탐지 모델의 경우 실제 공동을 찾지 못하는 위음성(false negative)이 적은 것이 중요하기 때문에, 재현율의 상승은 실질적인 성능 개선이 이루어졌다고 판단할 수 있는 근거가 되었다.

비대칭형 공동이 포함된 자료에서 예측 성능이 향상된 예시(Fig. 9)에서, 원 자료를 그대로 사용했을 때(Fig. 9a의 왼쪽)와

분리된 회절파를 포함한 입력 자료를 이용했을 때(Fig. 9a의 오른쪽)의 공동 탐지 결과에서 실제 공동이 위치하는 부분은 연두색의 경계상자 및 태그로 표시하였으며, 예측 결과는 신뢰도가 높게 나온 순서대로 번호를 매겨주었다(각각의 경계 상자 번호에 해당하는 예측 결과의 클래스와 신뢰도는 그림 왼쪽 하단에 표시함). 원 자료 사용 시에는 비대칭형 공동을 기타형 공동으로 잘못 예측하였으나 제안된 방법의 결과에서는 비대칭형 공동일 확률이 더 높다고 예측하였다(Fig. 9a). 공동 탐지에 활용된 분리된 회절파를 포함한 입력 자료(Fig. 9b)의 경우, 공동에서 발생한 회절파 신호가 비교적 정확하게 구분되고 결과적으로 탐지 성능이 높아진 것을 확인할 수 있다.

기타형 공동이 포함된 자료(Fig. 10)에서는 기존의 비대칭형 공동으로 예측한 탐지 결과에 비해 제안된 방법의 결과에서 더욱 정확하게 클래스를 예측하는 것을 확인할 수 있었다. 특히 공동의 회절파가 중첩된 반사파와 분리되어(Fig. 10b) 공동의 클래스 구분에 도움이 되었을 것으로 생각된다. 반면에 비대칭형 공동 클래스 예시(Figs. 11과 12)는 우리가 학습에 사용될 자료를 준비할 때 기준으로 삼았던 대부분의 서울시 자료

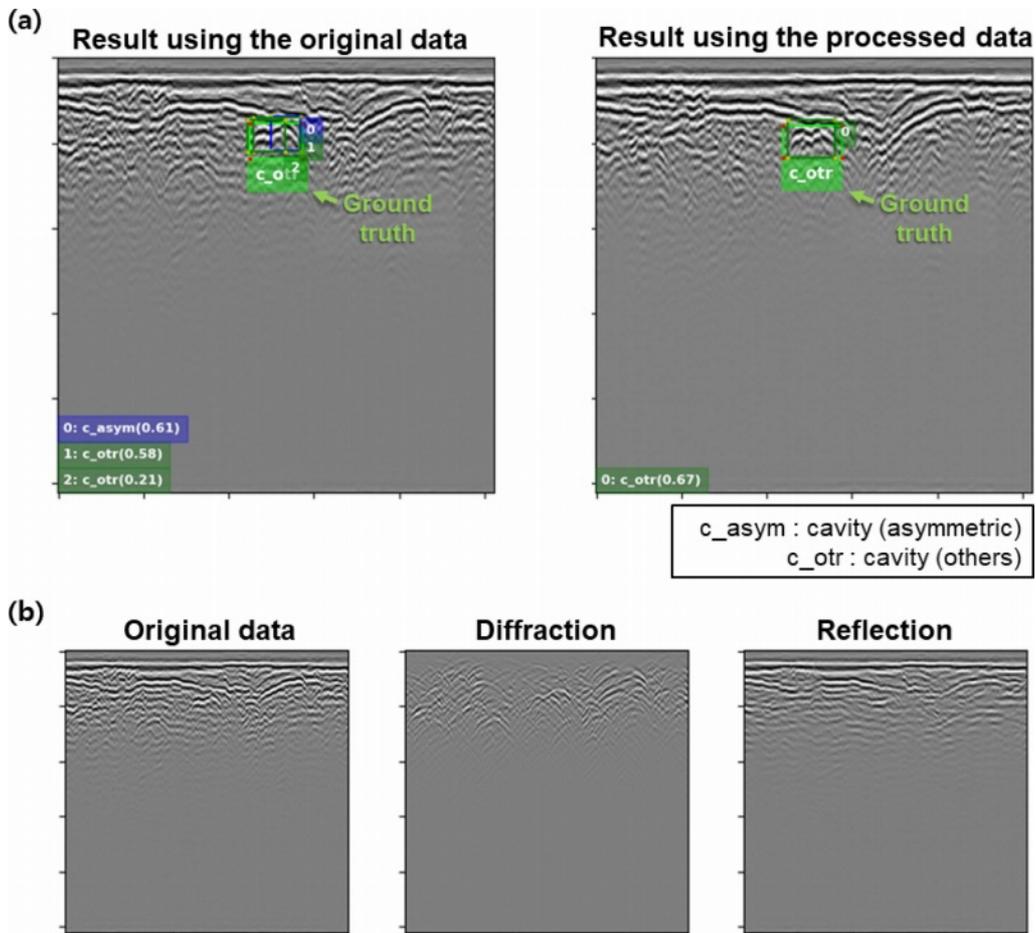
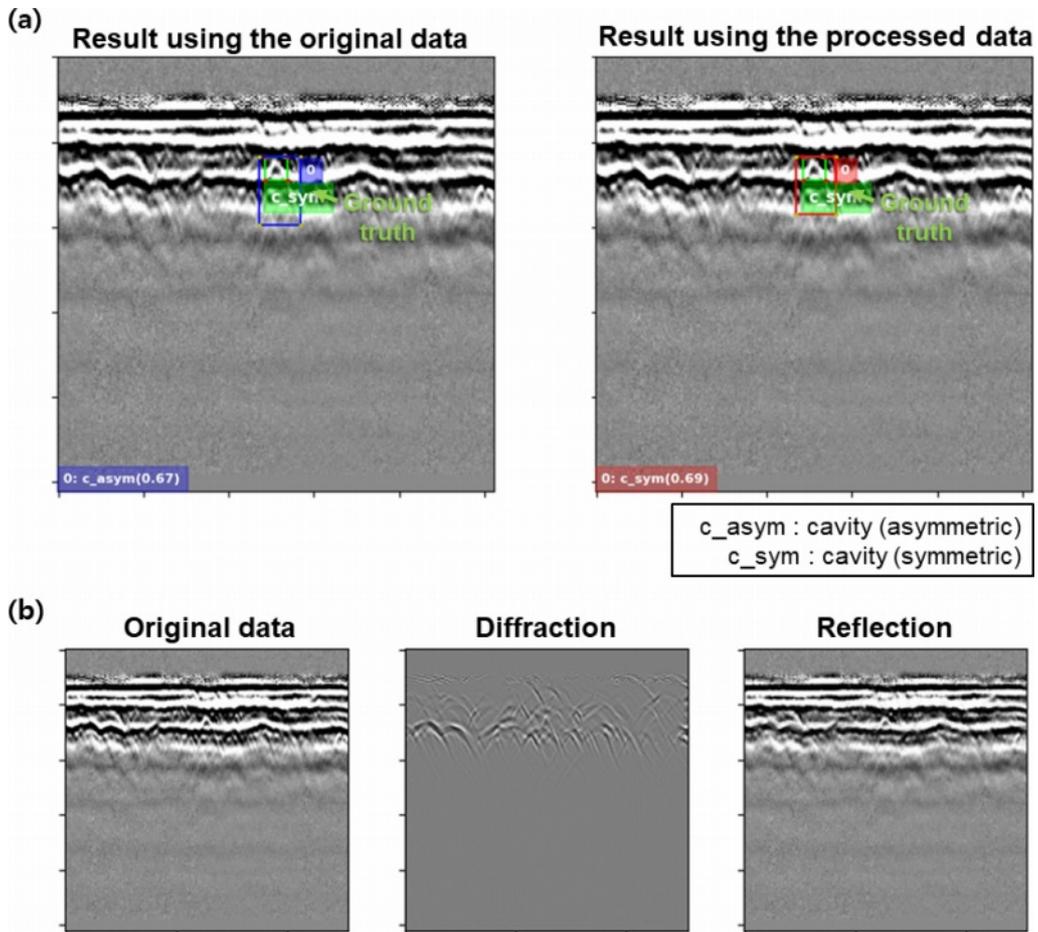
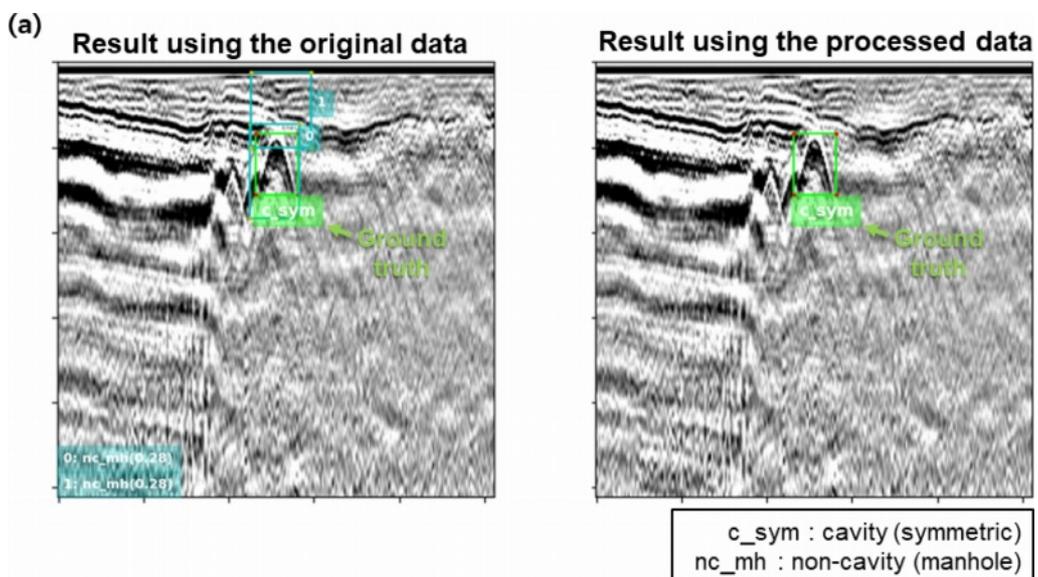


Fig. 10. (a) Comparison of cavity detection performance in the cavity (others) class using original and processed data. (b) Original image, separated diffraction image predicted using proposed diffraction separation method, and reflection image calculated by subtracting the separated diffraction image from the original image.



**Fig. 11.** (a) Comparison of cavity detection performance in the cavity (symmetric) class using original and processed data. (b) Original image, separated diffraction image predicted using proposed diffraction separation method, and reflection image calculated by subtracting the separated diffraction image from the original image.



**Fig. 12.** (a) Comparison of cavity detection performance in the cavity (symmetric) class using original and processed data. (b) Original image, separated diffraction image predicted using proposed diffraction separation method, and reflection image calculated by subtracting the separated diffraction image from the original image.

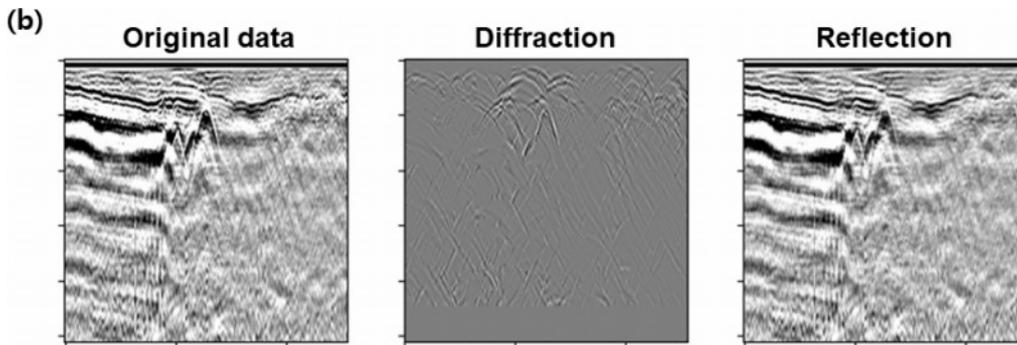


Fig. 12. Continued.

들과는 다르게 시간 샘플링을 달리하여 측정했거나 사용된 GPR 장비의 주주파수가 달라 매우 다른 신호 특성이 있다. 이들 신호들은 신호의 파장, 회절파 특성 등이 앞선 예(Figs. 9와 10)의 자료와 크게 차이나는 것을 알 수 있다. 특히 다른 대부분의 자료들과 약간 차이가 나는 Fig. 11의 예시에서는 회절파가 상당 부분 분리되어 공동 탐지 성능이 향상되었지만, 상당히 차이가 나는 Fig. 12에서는 회절파 분리가 정확하게 수행되

지 않아 공동의 위치가 탐지되지 않았다. 이러한 부분은 향후 GPR 자료의 특성을 반영하여 보다 다양한 신호의 파장에 대한 학습 자료를 포함할 수 있도록 학습 자료를 개선하거나 또는 자료 취득 시 지반 특성과 장비 설정의 차이에 따라 달라지는 B-scan 이미지에 적절한 전처리를 통해 보다 일관된 특성을 갖는 자료로 변환한 후 회절파 분리를 적용시키는 방법으로 보완 가능할 것으로 생각된다.

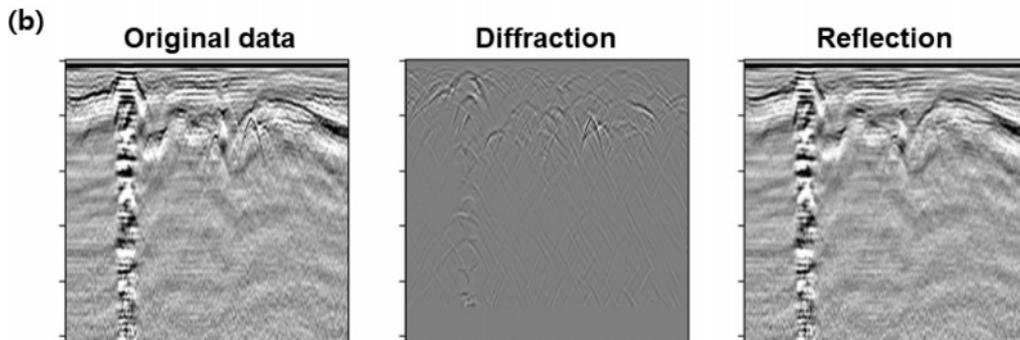
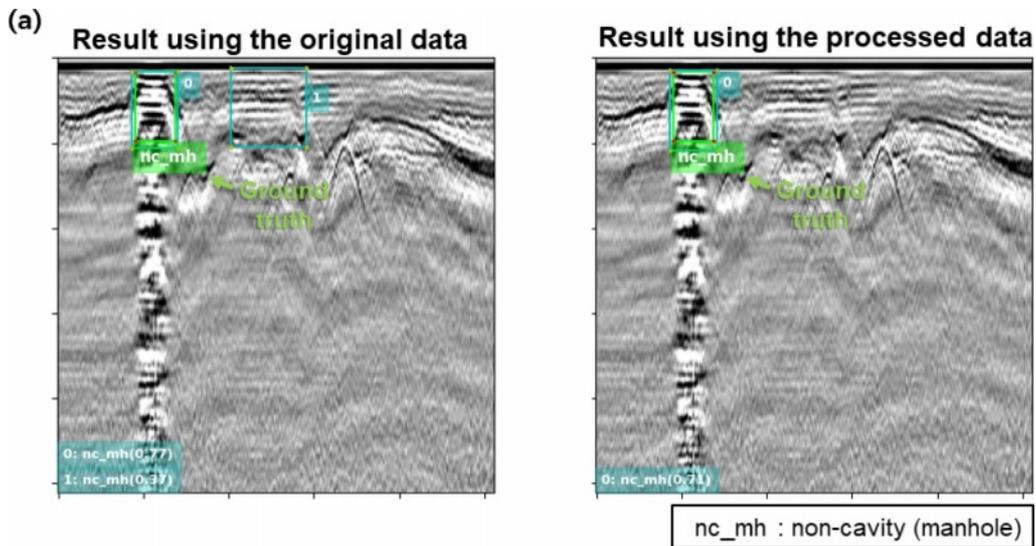
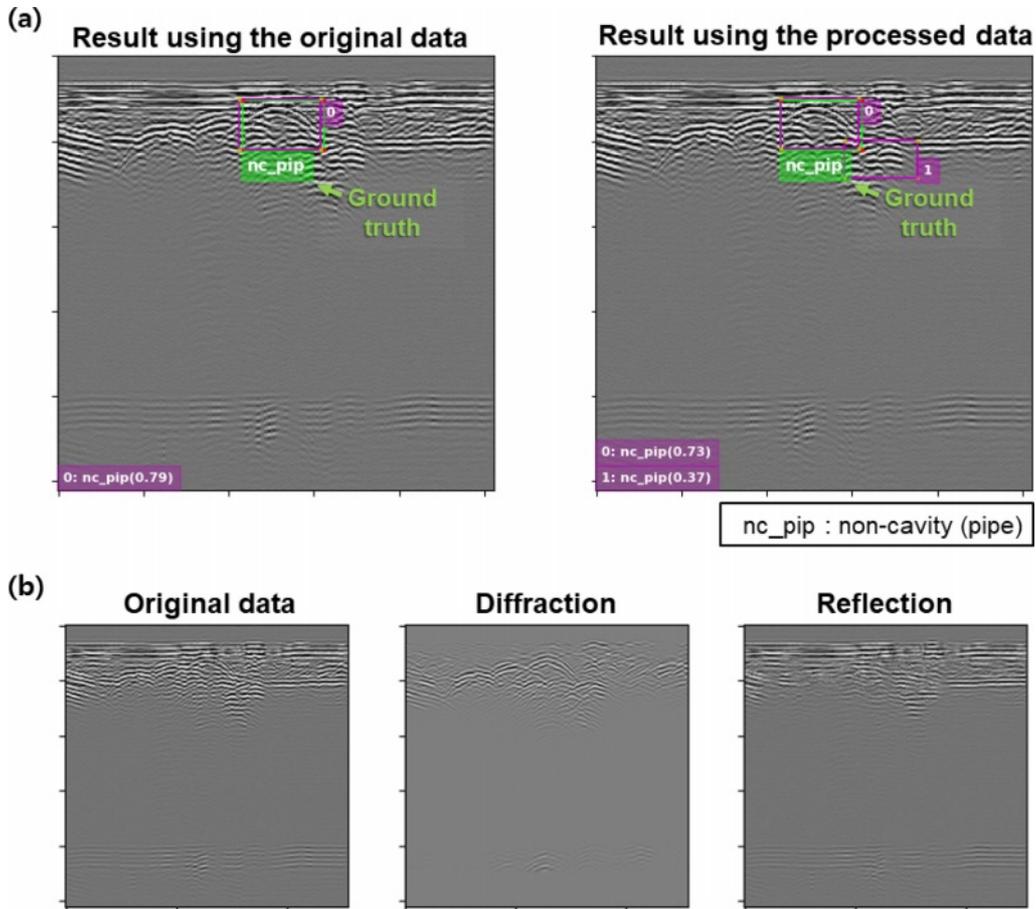


Fig. 13. (a) Comparison of object detection performance in the manhole class using original and processed data. (b) Original image, separated diffraction image predicted using proposed diffraction separation method, and reflection image calculated by subtracting the separated diffraction image from the original image.



**Fig. 14.** Examples of false detections in pipe class. (a) Comparison of object detection performance using original and processed data. (b) Original image, separated diffraction image predicted using proposed diffraction separation method and the reflection image calculated by subtracting the separated diffraction image from the original image.

맨홀 클래스의 자료는 상당히 특징적인 회절파, 반사파 패턴을 만들어내기 때문에 전반적인 탐지 성능이 높게 나타난다. 특히 전처리된 입력 자료에서 분리된 회절파, 반사파, 원 자료 모두에서 맨홀 클래스 신호의 특징이 확연히 나타나고(Fig. 13) 공동 탐지 모델의 성능이 전반적으로 향상되었기 때문에, 맨홀 클래스에 대한 탐지 성능이 눈에 띄게 향상되었다. 이와 대조적으로 파이프 클래스에 대한 성능은 감소한 것으로 나타났다. 재현율 지표는 두 실험 모두에서 높게 나타났지만 정밀도 지표가 크게 하락했다. 이는 상대적으로 양성 검출 비율이 높은 전처리 자료 사용 공동 탐지 모델에 의해 위양성(false positive) 비율이 증가하면서(Fig. 14) 정밀도 및 mAP@0.5 지표 하락으로 나타났다.

## 결론

이 연구에서는 GPR 탐사 자료에서 회절파 분리를 통해 도로 하부 공동 탐지 성능을 향상시키는 방법을 제안하였다. 회절파 분리를 위해 GPR 신호 특성을 반영한 분리 방법을 개발

하였으며, 현장 GPR 자료의 회절파가 비교적 정확하게 분리된 것을 확인하였다. 분리된 회절파 및 반사파를 원 자료와 함께 이용하여 YOLO v5 모델에서 공동 탐지를 수행한 결과, 분리 전의 원래 자료만 이용했을 경우에 비해 공동 탐지 성능이 향상되는 것을 확인할 수 있었다. 다만 현장의 지반 특성 및 탐사 기기의 설정 차이로 인한 자료 특성의 차이로 인해 회절파 분리가 정확하게 작동하지 못한 경우가 존재하였으며, 향후 다양한 GPR자료에 대한 회절파 분리성능을 높으려면 이러한 점을 고려한 후속 연구가 필요할 것으로 보인다. 또한 제안된 방법의 현장 적용성 검증에 이용된 서울시 공공 자료는 수만 개 이상의 라벨링된 자료를 제공하여 개발된 방법의 객관화된 성능 평가가 가능하도록 했지만, 현재 공개된 자료인 1.0 버전에서는 하나의 이미지 내에 여러 개의 클래스가 동시에 존재하는 경우에도 한 가지 클래스에 대한 라벨링만 되어 있어 객체탐지 모델의 학습 및 정확한 성능 평가가 어려운 문제가 있었다. 향후 이러한 부분이 개선된다면 보다 뛰어난 성능의 공동 탐지 모델 개발이 가능할 것으로 생각된다. 마지막으로 이 연구에서 제안한 GPR 자료에서의 회절파 분리 기법은 원래

자료에서 분리된 회절파를 제거하면서 반사면에 대한 정보를 강조하는 효과가 있기 때문에, 반사면의 위치 및 구조 정보가 중요한 콘크리트 두께 산정, 도로 하부 포장상태 영상화, 방사성 폐기물 처리장의 방벽 안정성 확인, 락볼트나 철근에 가려진 터널 배면 상태 점검 등의 응용 분야에서 활용이 가능할 것으로 기대된다.

## 감사의 글

이 논문은 2022년도 정부(교육부, 산업통상자원부)의 재원으로 K-CCUS 추진단의 지원을 받아 수행된 연구입니다 (KCCUS20220001, 온실가스 감축 혁신인재양성사업). 또한, 이 연구를 위해 귀중한 현장 자료를 제공해주신 한국지능정보사회진흥원의 AI 허브와 서울시 도로관리과에 감사사를 드립니다.

## References

- AI Hub 3D GPR data, 2023, <https://aihub.or.kr/> (June 20, 2023 Accessed)
- Arosio, D., 2016, Rock fracture characterization with GPR by means of deterministic deconvolution, *J. Appl. Geophys.*, **126**, 27-34, <https://doi.org/10.1016/j.jappgeo.2016.01.006>
- Baker, G. S., Steeples, D. W., Schmeissner, C., Pavlovic, M., and Plumb, R., 2001, Near-surface imaging using coincident seismic and GPR data, *Geophys. Res. Lett.*, **28(4)**, 627-630, <https://doi.org/10.1029/2000GL008538>
- Benedetto, A., Tosti, F., Ciampoli, L. B., and D'amico, F., 2017, An overview of ground-penetrating radar signal processing techniques for road inspections, *Signal processing*, **132**, 201-209, <https://doi.org/10.1016/j.sigpro.2016.05.016>
- Chae, J., Ko, H.-y., Lee, B.-g., and Kim, N., 2019, A study on the pipe position estimation in GPR images using deep learning based convolutional neural network, *Journal of Internet Computing and Services*, **20(4)**, 39-46 (in Korean with English abstract), <https://doi.org/10.7472/jksii.2019.20.4.39>
- Chlaib, H. K., Mahdi, H., Al-Shukri, H., Su, M. M., Catakli, A., and Abd, N., 2014, Using ground penetrating radar in levee assessment to detect small scale animal burrows, *J. Appl. Geophys.*, **103**, 121-131, <https://doi.org/10.1016/j.jappgeo.2014.01.011>
- Choi, B., Pyun, S., Choi, W., Jo, C.-h., and Yoon, J., 2022, Deep-learning-based GPR Data Interpretation Technique for Detecting Cavities in Urban Roads, *Geophys. and Geophys. Explor.*, **25(4)**, 189-200 (in Korean with English abstract), <https://doi.org/10.7582/GGE.2022.25.4.189>
- Choo, J.-H., Yoo, C.-K., Oh, Y.-C., and Lee, I.-M., 2019, Assessment of NATM tunnel lining thickness and its behind state utilizing GPR survey, *Journal of Korean Tunnelling and Underground Space Association*, **21(5)**, 717-733 (in Korean with English abstract), <https://doi.org/10.9711/KTAJ.2019.21.5.717>
- De Figueiredo, J., Oliveira, F., Esmi, E., Freitas, L., Schleicher, J., Novais, A., Sussner, P., and Green, S., 2013, Automatic detection and imaging of diffraction points using pattern recognition, *Geophys. Prospect.*, **61**, 368-379, <https://doi.org/10.1111/j.1365-2478.2012.01123.x>
- Gao, Y., Pei, L., Wang, S., and Li, W., 2021, Intelligent detection of urban road underground targets by using ground penetrating radar based on deep learning, *Journal of Physics: Conference Series, expanded abstracts*, **1757(1)**, 012081, <https://doi.org/10.1088/1742-6596/1757/1/012081>
- Girshick, R., Donahue, J., Darrell, T., and Malik, J., 2014, Rich feature hierarchies for accurate object detection and semantic segmentation, *IEEE conference on computer vision and pattern recognition, expanded abstracts*, 580-587, <https://doi.org/10.48550/arXiv.1311.2524>
- Hong, G., Kim, S. M., and Park, J. J., 2022, A Study on the Calculation of Cavity Filling Amount Using Ground Penetrating Radar and Cavity Shaping Equipment, *Journal of the Society of Disaster Information*, **18(2)**, 261-268 (in Korean with English abstract), <https://doi.org/10.15683/kosdi.2022.6.30.261>
- Huang, H., Lin, L., Tong, R., Hu, H., Zhang, Q., Iwamoto, Y., Han, X., Chen, Y.-W., and Wu, J., 2020, Unet 3+: A full-scale connected unet for medical image segmentation, *ICASSP 2020-2020 IEEE international conference on acoustics, speech and signal processing (ICASSP), expanded abstracts*, 1055-1059, <https://doi.org/10.1109/ICASSP40776.2020.9053405>
- Jeong, D., Yu, H., Cha, J., Seoyun, K., Ahn, H., Chi, Y., Lee, G., Noh, M., and Park, E., 2022, A Study on Building Ground Penetrating Radar Data and Artificial Intelligence-based Cavity Detection, *Proceedings of the Korea Software Congress 2022, expanded abstracts*, 300-302, <https://www.dbpia.co.kr/journal/articleDetail?nodeId=NODE11224084>
- Kang, M.-S., Kim, N., Lee, J. J., and An, Y.-K., 2020, Deep learning-based automated underground cavity detection using three-dimensional ground penetrating radar, *Structural Health Monitoring*, **19(1)**, 173-185, <https://doi.org/10.1177/1475921719838081>
- Kim, B., and Seol, S. J., 2017, Application of image processing techniques to GPR data for the reliability improvement in subsurface void analysis, *Geophys. and Geophys. Explor.*, **20(2)**, 61-71 (in Korean with English abstract), <http://doi.org/10.7582/GGE.2017.20.2.061>
- Kim, N., Kim, S., An, Y.-K., and Lee, J.-J., 2021, A novel 3D GPR image arrangement for deep learning-based underground object classification, *International Journal of Pavement Engineering*, **22(6)**, 740-751, <https://doi.org/10.1080/10298436.2019.1645846>
- Kim, S., Seol, S. J., Byun, J., and Oh, S., 2022, Extraction of diffractions from seismic data using convolutional U-net and transfer learning, *Geophysics*, **87(2)**, V117-V129, <https://doi.org/10.1190/geo2020-0847.1>
- Lee, S. Y., Song, K.-I., Kang, K. N., and Ryu, H. H., 2022,

- Comparison of performance of automatic detection model of GPR signal considering the heterogeneous ground, *Journal of Korean Tunnelling and Underground Space Association*, **24(4)**, 341-353 (in Korean with English abstract), <https://doi.org/10.9711/KTAJ.2022.24.4.341>
- Li, F., Yang, F., Qiao, X., Xing, W., Zhou, C., and Xing, H., 2023, 3D ground penetrating radar cavity identification algorithm for urban roads using transfer learning, *Measurement Science and Technology*, **34(5)**, 055106, <https://doi.org/10.1088/1361-6501/acb6e3>
- Lin, T.-Y., Dollár, P., Girshick, R., He, K., Hariharan, B., and Belongie, S., 2017, Feature pyramid networks for object detection, Proceedings of the IEEE conference on computer vision and pattern recognition, expanded abstracts, 2117-2125, <https://doi.org/10.48550/arXiv.1612.03144>
- Liu, S., Qi, L., Qin, H., Shi, J., and Jia, J., 2018, Path aggregation network for instance segmentation, IEEE conference on computer vision and pattern recognition, expanded abstracts, 8759-8768, [https://openaccess.thecvf.com/content\\_cvpr\\_2018/papers/Liu\\_Path\\_Aggregation\\_Network\\_CVPR\\_2018\\_paper.pdf](https://openaccess.thecvf.com/content_cvpr_2018/papers/Liu_Path_Aggregation_Network_CVPR_2018_paper.pdf)
- Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C.-Y., and Berg, A. C., 2016, Ssd: Single shot multibox detector, *Computer Vision—ECCV 2016: 14th European Conference, expanded abstracts*, 21-37, [https://doi.org/10.1007/978-3-319-46448-0\\_2](https://doi.org/10.1007/978-3-319-46448-0_2)
- Ma, G. H., Lee, J. W., Oh, H. J., Lee, S., and Kim, K., 2022, Evaluation of Concrete Bridge Deck Condition Using 3D GPR System, *International Journal of Highway Engineering*, **24(1)**, 9-15 (in Korean with English abstract), <https://doi.org/10.7855/IJHE.2022.24.1.009>
- Mehta, R., Fazeel, A., Rama, P., Danner, M., Bajcinca, N., Riedel, P.-B., and Schwabe, J., 2021, CNN-Based Sub-Surface Object Detection Using Ground Penetrating Radar, 11th International Workshop on Advanced Ground Penetrating Radar (IWAGPR), expanded abstracts, 1-5, <https://doi.org/10.1109/IWAGPR50767.2021.9843163>
- Oh, H., Kwon, M., and Jang, H., 2019, GPR Analysis on Underground Features and Foundation Structure of Cheomseongdae, Gyeongju, *Korean Journal of Cultural Heritage Studies*, **52(4)**, 264-271 (in Korean with English abstract), <https://doi.org/10.22755/KJCHS.2019.52.4.264>
- Ozkaya, U., Melgani, F., Bejiga, M. B., Seyfi, L., and Donelli, M., 2020, GPR B scan image analysis with deep learning methods, *Measurement*, **165**, 107770, <https://doi.org/10.1016/j.measurement.2020.107770>
- Pan, S. J., and Yang, Q., 2009, A survey on transfer learning, *IEEE Transactions on knowledge and data engineering*, **22(10)**, 1345-1359, <https://doi.org/10.1109/TKDE.2009.191>
- Redmon, J., Divvala, S., Girshick, R., and Farhadi, A., 2016, You only look once: Unified, real-time object detection, Proceedings of the IEEE conference on computer vision and pattern recognition, expanded abstracts, 779-788, <https://doi.org/10.48550/arXiv.1506.02640>
- Schwarz, B., 2019, Coherent wavefield subtraction for diffraction separation, *Geophysics*, **84(3)**, V157-V168, <https://doi.org/10.1190/geo2018-0368.1>
- Son, J.-W., Moon, G.-S., and Kim, Y., 2021, Automatic Detection System of Underground Pipe Using 3D GPR Exploration Data and Deep Convolutional Neural Networks, *Journal of the Korea Society of Computer and Information*, **26(2)**, 27-37 (in Korean with English abstract), <http://doi.org/10.9708/jksci.2021.26.02.027>
- Ultralytics, <https://github.com/ultralytics/yolov5/> (June 30, 2023 Accessed).
- Wang, C.-Y., Liao, H.-Y. M., Wu, Y.-H., Chen, P.-Y., Hsieh, J.-W., and Yeh, I.-H., 2020, CSPNet: A new backbone that can enhance learning capability of CNN, IEEE/CVF conference on computer vision and pattern recognition workshops, expanded abstracts, 390-391, <https://doi.org/10.48550/arXiv.1911.11929>
- Yoon, J.-S., Baek, J., Choi, Y. W., Choi, H., and Lee, C. M., 2016, Signal pattern analysis of ground penetrating radar for detecting road cavities, *International Journal of Highway Engineering*, **18(6)**, 61-67 (in Korean with English abstract), <https://doi.org/10.7855/IJHE.2016.18.6.061>
- Yue, G., Liu, C., Li, Y., Du, Y., and Guo, S., 2022, GPR Data Augmentation Methods by Incorporating Domain Knowledge, *Applied Sciences*, **12(21)**, 10896, <https://doi.org/10.3390/app122110896>
- Zhu, J., Zhao, D., and Luo, X., 2023, Evaluating the optimised YOLO-based defect detection method for subsurface diagnosis with ground penetrating radar, *Road Materials and Pavement Design*, 1-18, <https://doi.org/10.1080/14680629.2023.2199880>