

## Automatic Detection System of Underground Pipe Using 3D GPR Exploration Data and Deep Convolutional Neural Networks

Jeong-Woo Son\*, Gwi-Seong Moon\*, Yoon Kim\*

\*Student, Dept. of Computer Science and Engineering, Kangwon National University, Chuncheon, Korea

\*Student, Dept. of Computer Science and Engineering, Kangwon National University, Chuncheon, Korea

\*Professor, Dept. of Computer Science and Engineering, Kangwon National University, Chuncheon, Korea

### [Abstract]

In this paper, we propose Automatic detection system of underground pipe which automatically detects underground pipe to help experts. Actual location of underground pipe does not match with blueprint due to various factors such as ground changes over time, construction discrepancies, etc. So, various accidents occur during excavation or just by ageing. Locating underground utilities is done through GPR exploration to prevent these accidents but there are shortage of experts, because GPR data is enormous and takes long time to analyze. In this paper, To analyze 3D GPR data automatically, we use 3D image segmentation, one of deep learning technique, and propose proper data generation algorithm. We also propose data augmentation technique and pre-processing module that are adequate to GPR data. In experiment results, we found the possibility for pipe analysis using image segmentation through our system recorded the performance of F1 score 40.4%.

▶ **Key words:** Underground Pipe, GPR, Deep Learning, 3D Image Segmentation,  
Automatic Detection System of Underground Pipe

### [요 약]

본 논문에서는 관로를 자동으로 검출하는 지하 관로 자동 탐색 시스템을 제안한다. 시간에 따른 지반변화, 관로 시공 불일치 등 여러 가지 요인으로 실제 관로의 위치가 지하 관로 도면과 일치하지 않는다. 이로 인하여 굴착공사나 관로 노후화에 의한 여러 사고가 발생한다. 사고를 방지하기 위해 GPR(지표 투과 레이더, Ground Penetrating Radar) 탐사를 통해 지하시설물을 찾아내는 작업이 이루어지고 있지만, 분석을 담당할 수 있는 전문가의 수가 부족하다. GPR 데이터는 매우 방대하며 분석과정에도 오랜 시간이 걸리기 때문이다. 이에 본 논문에서는 3D GPR 데이터를 자동으로 분석하기 위해 딥 러닝 기술인 3D 이미지 분할을 사용하고, 이에 적합한 데이터 생성 알고리즘을 제안한다. 또한 GPR 데이터 특성에 맞는 데이터 증강 기법, 데이터 전처리 모듈을 제안한다. 실험 결과를 통해 제안한 시스템은 F1 Score 40.4%의 성능을 보였으며 이를 통해 이미지 분할을 이용한 관로 분석의 가능성을 확인하였다.

▶ **주제어:** 지하 관로, 지표 투과 레이더, 딥 러닝, 3D 이미지 분할, 지하 관로 자동 탐색 시스템

- First Author: Jeong-Woo Son, Co-author: Gwi-Seong Moon, Corresponding Author: Yoon Kim
- \*Jeong-Woo Son (jeongwoo12@kangwon.ac.kr), Dept. of Computer Science and Engineering, Kangwon National University
- \*Gwi-Seong Moon (msg0812@geo-vision.co.kr), Dept. of Computer Science and Engineering, Kangwon National University
- \*Yoon Kim (yooni@kangwon.ac.kr), Dept. of Computer Science and Engineering, Kangwon National University
- Received: 2020. 11. 20, Revised: 2021. 01. 18, Accepted: 2021. 01. 18.

## I. Introduction

시간에 따른 지반 변화와 도시의 발달로 인한 지하 시설물의 복잡도 증가, 관로 시공 불일치 등 여러 가지 요인으로 과거에 작성한 지하 관로 도면과 실제 관로의 위치 정보가 일치하지 않는다. 위와 같은 문제로 현재까지도 지하 관로 위치 정보가 부정확하거나 정보 자체가 없는 경우가 다수이며, 이로 인해 굴착공사나 관로 노후화에 의한 수도관 파열, 지반 함몰 등의 사고가 발생하고 있다[1]. 이러한 사고를 막기 위해 GPR(지표 투과 레이더, Ground Penetrating Radar) 탐사로 지하시설물의 정확한 위치 파악을 시행하고 있다[2]. 하지만 GPR 탐사 데이터 분석 작업에서 많은 어려움을 가지고 있다. 첫 번째는 방대한 GPR 데이터를 사람의 눈으로 보고 객체를 판단해야하기 때문에 일관적인 정확성이 떨어진다. 두 번째는 GPR 탐사 데이터의 특성상 객체의 특징이 명확하지 않아 정확한 분석을 위해 많은 시간과 전문가들의 노동력이 필요하다. 이 문제를 해결하기 위해서는 자동으로 GPR 탐사 데이터를 분석하고 관로를 찾아내어 전문가들의 수작업을 보조해주는 관로 자동 탐색 시스템 개발이 필요하다. 최근 딥 러닝 연구가 활발히 진행되면서 학습을 통한 다양한 분야의 기술들이 발달되고 있다[3,4]. GPR 데이터 분석도 마찬가지로 딥 러닝을 통한 자동화 기술을 연구하고 있지만 GPR 데이터에 대한 관로 분석 자동화 기술은 아직 많이 발전되지 않았다. 기존의 딥 러닝을 활용한 관로 분석은 이미지 분류(Classification), 객체 검출(Object Detection) 등을 활용하여 관로의 위치를 추정하는 연구가 있다[5,6]. 관로 분석에 이미지 분류 알고리즘을 사용하면 분석한 데이터의 관로 유무는 알 수 있어도 관로의 위치는 알 수 없다는 문제점이 있다. 객체 검출을 활용한 관로 탐색은 관로의 위치를 경계박스로 표현하여 이미지 분류의 문제점을 보완하였지만 GPR 데이터는 단면만 보고 특징을 뽑아내기 힘들기 때문에 2D 이미지로 분석하기에 한계가 있다. 이러한 문제를 해결하기 위해 본 논문에서는 3D 이미지 분할(Segmentation)을 사용하여 GPR 데이터에서 관로의 정확한 위치를 분석하는 관로 자동 탐색 시스템을 제안한다. 학습에 사용한 정답 데이터는 전문가들이 찾아낸 관로 좌표를 자체 관로 생성 알고리즘을 통해 이미지 분할 작업에 사용할 수 있게 가공하여 사용한다. 본 논문에서 사용한 데이터는 훈련 데이터 세트 60개, 테스트 데이터 세트 6개이며 이미지 분할의 정량적인 평가는 정밀도, 재현율, F1 Score로 평가한다.

본 논문은 GPR 데이터를 이용한 자동 관로 분석 분야에서 다음과 같은 기여를 한다.

- 기존 방식과 달리 3D 이미지 분할을 사용함으로 GPR 데이터의 연속성을 활용하여 정확하게 객체를 분석한다.
- 이미지 분할 학습에 사용할 수 있는 GPR 정답 데이터 생성 알고리즘을 제안한다.
- 이미지 분할을 사용함으로 관로 최상단 좌표 추출이 가능하고 이로 인해 전문가의 수작업을 보조할 수 있다. 관로 최상단 좌표는 관로 분석 전문가가 관로의 위치를 저장할 때 사용한다.

본 논문의 구성은 다음과 같다. 2장에서는 GPR 분석 및 관련된 연구를 기술한다. 3장에서는 제안한 GPR 탐사 데이터 세트 생성 알고리즘과 GPR 탐사 데이터의 특성에 맞게 제안한 데이터 전처리 모듈, 데이터 증강 방법을 설명하고 학습에 사용한 학습 모델과 손실 함수를 소개한다. 4장에서는 실험 및 실험 결과를 분석하고 5장에서 결론을 도출한다.

## II. Preliminaries

### 1. Related works

이번 장에서는 GPR의 기초 개념과 GPR 탐사 데이터의 특성에 대해 설명한다. 또한 GPR 데이터 특성에 맞는 딥 러닝 기술을 소개하고 설명한다.

#### 1.1 Ground Penetrating Radar

GPR 탐사란 전자기파를 이용하여 관로, 공동과 같은 지하구조 및 지하시설물을 탐사하는 기술이다. GPR은 송신 안테나를 통해서 땅속으로 전자기파를 방출하고 유전율의 차이가 발생하는 곳에서 신호가 반사 및 투과된다. 반사된 신호는 수신 안테나에서 수신되고 신호를 분석하여 땅속의 관로, 공동 등을 구별한다. 안테나는 주파수에 따라 해상도와 탐사 가능한 심도가 달라진다. 고주파수의 안테나를 사용하면 해상도는 높아지지만 탐사 가능 심도가 얕아지고 저주파수로 갈수록 해상도는 낮아지지만 탐사 가능 심도가 깊어진다. 따라서 탐사하려는 객체의 예상 심도에




Fig. 1. GPR data - (a) Raw data, (b) Filtering data




Fig. 2. Longitudinal section analysis - (a) Underground pipe, (b) Gravel layer, (c) Underground cavity, (d) Sand layer, (e) PE corrugated pipe




Fig. 3. Flat section analysis - (a) Underground pipe, (b) Gravel layer, (c) Underground cavity, (d) Sand layer, (e) PE corrugated pipe




Fig. 4. Cross section analysis - (a) Underground pipe, (b) Gravel layer, (c) Underground cavity, (d) Sand layer, (e) PE corrugated pipe

따라 적절한 주파수의 안테나를 사용해야 한다[7]. GPR 탐사를 통해 취득한 데이터는 이진 파일로 이루어져 있으며 채널 수, 채널 간격, 트레이스 샘플링 수, 트레이스 샘플링 간격, 심도 샘플링 수, 심도 샘플링 간격 정보가 들어있고 GPR 데이터 값이 들어있다. 데이터 파싱을 통해 이러한 정보를 읽어내어 이미지화시키고 Band Pass Filter, Gain 등 여러 필터링을 통해 사람의 눈으로 분석이 가능한 데이터로 가공하여 사용한다[8]. Fig 1은 GPR 원시 데이터와 필터링 후 데이터 예시이다.

### 1.2 GPR Data Analysis

GPR 탐사 데이터는 3D로 취득되며 종단면, 평단면, 횡단면으로 잘라내어 분석할 수 있지만 한 단면만의 정보로는 관로에 대한 명확한 특징을 찾지 못하여 세 단면을 종합적으로 판단하여 관로를 검출한다. Fig 2, 3, 4는 GPR 탐사 데이터를 종단면, 평단면, 횡단면으로 잘라내어 분석한 예시로 관로, 자갈층, 모래층 등을 분석하였을 때 종단면은 5가지 유형의 데이터가 모두 쌍곡선 형태의 유사한 특징을 가지고 있다. 평단면과 횡단면도 마찬가지로 단면만 보고는 정확한 분석이 불가능하다. 그리고 한 단면을 잘라내어 보았을 때 지하 시설물이 묻혀있는 방향에 따라 객체의 모양이 완전히 다르게 보인다. 이러한 문제점 때문에 단면만 보고 분석하면 한계가 있으므로 종단면, 평단면, 횡단면 모두를 고려한 분석 방법이 필요하다.

### 1.3 GPR Pipe Data Analysis Using Deep Learning

딥 러닝을 활용하여 GPR 데이터를 분석하고 지하구조 및 지하시설물을 탐지하는 여러 연구가 진행되고 있다 [9-11]. 본 논문에서는 GPR 데이터를 분석하여 지하시설물인 관로를 자동으로 탐색하는 연구를 진행한다. 이미지 분류를 활용한 연구는 데이터에 관로가 있는지에 대한 관로 유무를 판단하여 관로의 위치를 추정하였다[5]. 하지만 이미지 분류는 이미지가 관로인지 아닌지만 판단하기 때문에 관로의 정확한 위치를 찾을 수 없다. 객체 검출 알고리즘을 활용하여 관로의 위치를 찾는 연구도 있다[6]. 객체 검출 알고리즘을 통해 경계박스로 관로의 위치를 나타내어 이미지 분류의 한계를 보완할 수 있지만 GPR 데이터는 단면만 보고 관로를 판단하기에 한계가 있다. 쌍곡선 형태의 특징을 찾았다더라도 다른 구조물과 구별할 수 없고 관로가 묻혀있는 방향에 따라 특징이 다르게 나타날 수도 있다. 본 논문에서는 GPR 탐사 데이터의 종단면, 평단면, 횡단면을 모두 고려하여 분석이 가능한 3D 이미지 분할 모델을 사용한다. 3D 이미지 분할 모델을 사용하려면 이에 맞는 정답 데이터 생성이 중요하다. 3D 이미지 분할 모델의 정답 데이터는 GPR 탐사 데이터 분석 전문가가 추출한 관로의 좌표를 이용하여 제안한 알고리즘을 통해 가공하여 사용한다. 제안한 관로 생성 알고리즘은 III. The Proposed Scheme의 1.2번에서 자세히 설명한다.

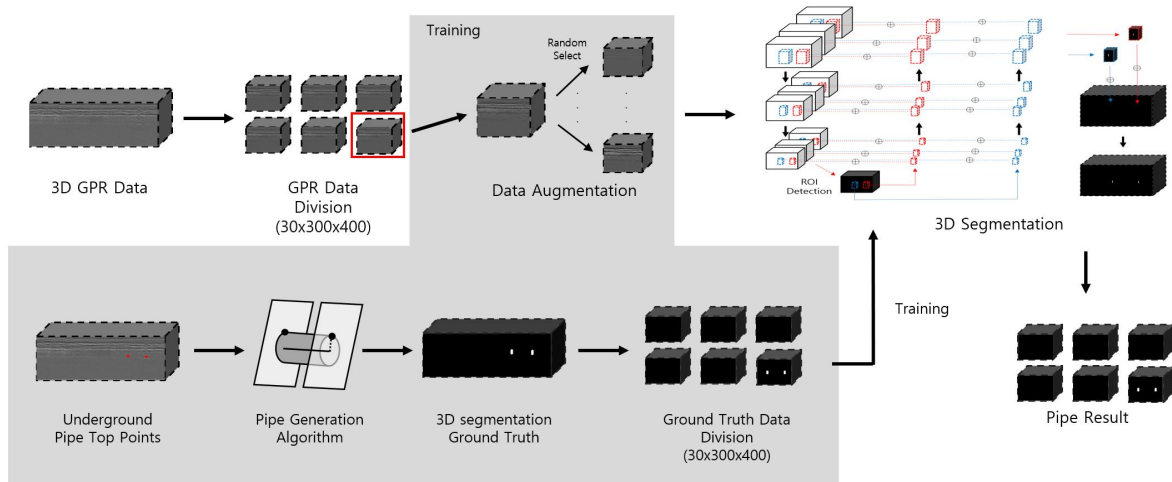


Fig. 5. Automatic detection system of underground pipe

1.4 3D Segmentation

이미지 분할이란 이미지를 구성하는 모든 픽셀을 개별적으로 분류하여 분할 결과를 취득하는 기술이다. Fig 6은 대표적인 이미지 분할 모델인 FCN의 이미지 분할 결과 예시이다[12].




Fig. 6. Example of segmentation network structure

딥 러닝이 발달되면서 이미지 분할 기술을 CT (컴퓨터 단층촬영, Computer Tomography), MRI(자기공명 영상법, Magnetic Resonance Imaging)와 같은 3D 의료 영상과 접목하여 비정상적인 부위를 찾아내고 있다. 하지만 종양과 같이 특징이 명확하지 않은 객체는 한 단면만 보고 분석하기에 한계가 있다. 이를 극복하고자 3D 데이터의 연속성을 고려한 3D 이미지 분할 기술이 도입되고 있다 [13, 14]. GPR 탐사 데이터는 한 단면이 아닌 모든 단면의 연속성을 모두 고려해야 하는 점이 의료 데이터 분석과 유사하므로 본 논문에서는 3D 이미지 분할 기술을 적용하여 관로 자동 탐색 시스템을 설계하였다.

III. The Proposed Scheme

이 장에서는 본 연구에서 설계한 GPR 탐사 데이터와 정답 관로 데이터의 구축 방법을 자세하게 설명하고 GPR 탐사 데이터 특성에 맞게 제안한 데이터 전처리 모듈과 데이터 증강 방법을 설명한다. 그리고 관로 자동 탐색 시스템에 사용된 딥 러닝 학습 모델과 손실 함수를 소개한다. 제안하는 자동 관로 탐색 시스템 구성은 Fig 5와 같다.

1. 데이터 구축

GPR 탐사 데이터는 이진 파일로 이루어져 있으며 GPR 탐사기에 따라 다르지만 보통 채널 수, 채널 간격, 트레이스 샘플링 수, 트레이스 샘플링 간격, 심도 샘플링 수, 심도 샘플링 간격 그리고 GPR 데이터 값이 포함되어 있다. 3D 이미지로 비교하면 채널은 z축, 트레이스는 x축, 심도는 y축이고 샘플링 수는 픽셀 개수, 샘플링 간격은 픽셀 간격을 실제로 측정한 거리를 의미한다.

1.1 GPR 탐사 데이터

GPR 탐사 데이터는 채널 수, 트레이스 샘플링 수, 심도 샘플링 수와 GPR 데이터 값을 이용하여 채널별 종단면을 하나의 이미지로 만들고 만든 이미지들을 이어 붙여 3D 이미지 형태인 tiff 데이터로 가공한다. 본 논문에서 사용하는 GPR 데이터는 30채널로 구성되어 있다. 상·하수 관로는 보통 심도 2m 이내에 매설되어 있고 관로 탐사에 적합한 주파수의 안테나를 사용한 GPR 데이터를 사용한다. 관로 탐사에 적합한 GPR 데이터이기 때문에 가탐심도가 2m 부근이고 가탐심도보다 깊은 데이터는 해상도가 매우 떨어져 분석이 어렵다. 그리고 GPR 데이터는 너비가 일정하지 않아 한번에 데이터를 다 읽기에는 메모리 초과 문제가 발생할 수

있다. 이로 인해 학습을 위한 GPR 데이터 세트는 분석할 수 없는 데이터를 삭제하고 일정한 너비로 잘라내어 30 x 300 x 400(채널 x 높이 x 너비) 크기의 패치 단위로 구축한다.




Fig. 7. GPR dataset construction process - (a) Total GPR data, (b) Cut non-using data (c) Data divided by constant width

### 1.2 정답 관로 데이터

GPR 분석 전문가는 GPR 탐사 데이터에서 관로라고 판단한 객체의 최상단 좌표를 추출한다. Fig 8은 GPR 데이터에서 관로 최상단 좌표를 찍어낸 예시이다.




Fig. 8. Top coordinate of pipe in GPR data

현재 관로 정보는 GPR 데이터 분석 전문가들이 수작업으로 GPR 탐사 데이터를 분석하여 관로의 처음 시작 부분, 관로가 꺾이는 부분, 관로가 끝나는 부분의 관로 최상단 좌표와 관로 직경 정보 등을 저장하여 만들어진다. 하지만 이미지 분할 문제에서 최상단 좌표만 찾는 것은 심한 클래스 불균형 문제가 일어나 학습이 불가능하다. 이러한 문제를 해결하기 위해 제안한 관로 생성 알고리즘을 이용하여 학습 가능한 이미지 분할 정답 관로 데이터를 3D 형태의 tiff 데이터로 가공한다. Fig 9는 GPR 데이터와 관로 생성 알고리즘을 통해 만든 관로 정답 이미지의 한 단면이다. 이렇게 만든 정답 관로 데이터도 객체가 매우 작아 클

래스 불균형 문제가 발생한다. 본 논문에서는 다이소 손실 함수를 이용하여 문제를 해결하였다. 손실 함수에 대해서는 5. Loss Function에서 자세히 설명한다.

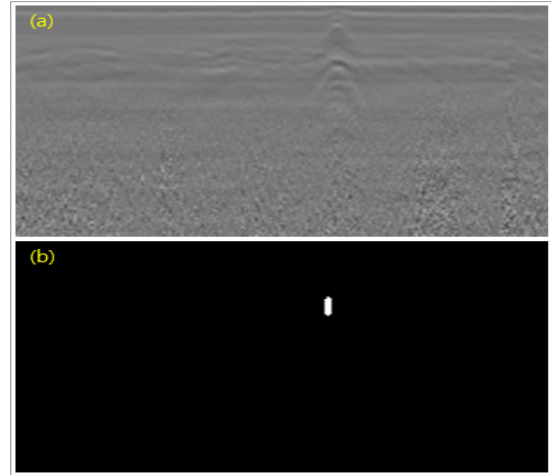


Fig. 9. GPR longitudinal section (a) GPR data, (b) Ground Truth

제안한 관로 생성 알고리즘은 아래와 같다.

---

**Algorithm 1** 전문가의 관로 탐사 데이터 정보를 이용한 정답 관로 생성.  $c$ 는 채널,  $h$ 는 데이터의 높이,  $w$ 는 데이터의 너비이다.

---

**Input** 3차원 입력 데이터  $G=\{g_{111} \dots g_{chw}\}$ , 관로 1지점 최상단 좌표  $P_1(x_1, y_1, z_1)$ , 관로 2지점 최상단 좌표  $P_2(x_2, y_2, z_2)$ , 관로 트레이스 샘플링 간격  $x_{cell}$ , 심도 샘플링 간격  $y_{cell}$ , 채널 간격  $z_{cell}$ , 관로 직경  $D$

**Output** 정답 관로 데이터  $GT$

**Method**

1.  $P_1, P_2$ 에 관로 직경 반지름을 내린 관로 중심 좌표 :

$$y'_1 = y_1 + (D/2)/y_{cell} \quad y'_2 = y_2 + (D/2)/y_{cell}$$

$$P'_1 = (x_1, y'_1, z_1) \quad P'_2 = (x_2, y'_2, z_2)$$

2.  $P'_1$ 과  $P'_2$ 의 방향 벡터 :

$$\overrightarrow{P'_1 P'_2} = (x_2 - x_1, y'_2 - y'_1, z_2 - z_1) = (a, b, c)$$

3.  $\overrightarrow{P'_1 P'_2}$ 을 법선벡터로  $P'_1$ 을 포함하는 평면의 방정식과  $P'_2$ 을 포함하는 평면의 방정식 :
-

$$Plane_1 = a(x - x_1) + b(y - y_1) + c(z - z_1)$$

$$Plane_2 = a(x - x_2) + b(y - y_2) + c(z - z_2)$$

4. 외적을 이용한 점과 직선 사이의 거리 :

$P$ 는 중심선 중 임의의 좌표  
 $A$ 는 관로 여부를 확인할 좌표  
 $\overrightarrow{PA}$  =  $P$ 와  $A$ 의 방향 벡터  
 $\overrightarrow{P_1P_2}$  와  $\overrightarrow{PA}$  에  $x_{cell}$ ,  $y_{cell}$ ,  $z_{cell}$ 을  
 이용하여 실 거리 비율 반영

$$Distance = \frac{|\overrightarrow{PA} \times \overrightarrow{P_1P_2}|}{|\overrightarrow{P_1P_2}|}$$

5. 관로 생성 알고리즘 :

```

for z = 1 to c do
  for y = 1 to h do
    for x = 1 to w do
      if (Plane1 ≥ 0 and Plane2 ≤ 0)
        if (Distance ≤ D/2) GTzyx = 255
      else GTzyx = 0
    
```




Fig. 10. Example of pipe generation

## 2. Data Preprocessing Module

GPR 탐사는 여러 개의 안테나를 통해 각각 종단면을 뽑아내어 3D GPR 원시 데이터를 취득한다. 취득한 데이터는 여러 필터링을 통해 분석이 가능한 데이터로 가공하고 사람의 눈으로 확인할 수 있게 정규화를 하여 이미지화 한다. 하지만 채널별로 원시 데이터 값의 차이가 큰 경우 채널마다 데이터의 밝기가 일정하지 않고 실제로 이런 경우가 많다. 채널별 데이터가 일정하지 않다면 딥 러닝 학습 시 3D 데이터의 연속성을 이용하기에 적합하지 않고 학습

이 원활하게 진행되지 않는다. 이러한 문제 때문에 이를 해결할 수 있는 데이터 전처리가 필요하다. 본 논문에서 제안한 데이터 전처리 모듈은 다음과 같다.

**Algorithm 2** GPR 탐사 데이터 전처리 모듈.  $c$ 는 채널,  $h$ 는 데이터의 높이,  $w$ 는 데이터의 너비이다.

**Input** 3차원 입력 데이터  $G \{g_{111} \dots g_{chw}\}$

학습 가능한 파라미터  $s, b$   
 초깃값  $s = 1, b = 0$

**Output** 전처리 후 데이터  $result$

**Method**

1.  $m_c = \frac{1}{h \times w} \sum_{y=1}^h \sum_{x=1}^w g_{cyx}$  //채널 별 데이터 평균
2.  $v_c = \frac{1}{h \times w} \sum_{y=1}^h \sum_{x=1}^w (g_{cyx} - m_c)^2$  //채널 별 데이터 분산
3.  $norm_c = \frac{g_{chw} - m_c}{\sqrt{v_c}}$  //채널 별 데이터 normalize
4.  $result_c = s \times norm_c + b$  //scale, bias 조정

데이터 전처리 모듈은 딥 러닝 모델의 앞에 적용되며 학습에 적합한 데이터로 변환한다.




Fig. 11. Example of original GPR data by channel

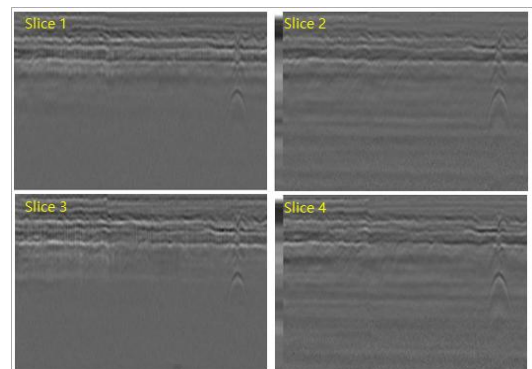


Fig. 12. Example of GPR data by channel after preprocessing

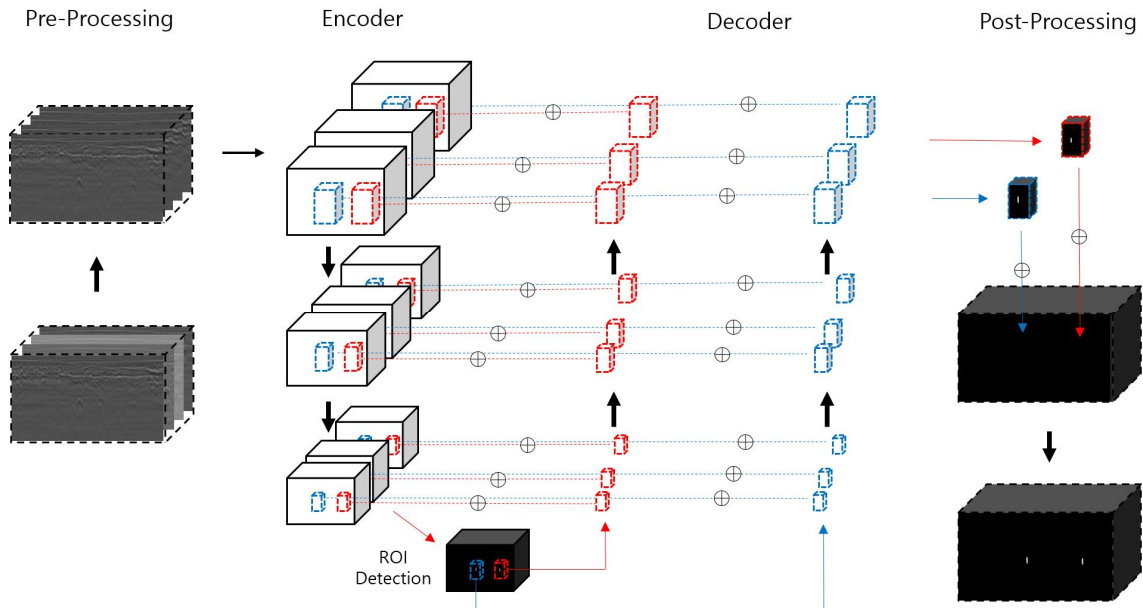


Fig. 13. 3D RU-Net

### 3. Data Augmentation

데이터 증강이란 데이터에 인위적인 변화를 주어 데이터를 확보하는 기법이다. 데이터 증강은 부족한 데이터의 수를 늘려 과적합을 방지한다. 대량의 데이터 확보에 어려움이 있는 GPR 데이터는 데이터 증강이 필수적이다. 일반적인 이미지 데이터 증강 기법은 많이 개발되어있다[15]. 하지만 일반적인 이미지와 GPR 데이터는 특성이 다르기 때문에 일반적인 데이터 증강 기법을 사용하기에 무리가 있다. 따라서 GPR 데이터의 특성을 고려한 데이터 증강 기법이 필요하다. 제안한 데이터 증강 기법은 명암비 조절이다. GPR 탐사 데이터는 관로의 종류나 땅 속의 매질 상태 등 여러 가지 이유로 유전율이 달라져 관로의 특징이 흐리게 또는 진하게 나올 수도 있다[16]. 이 특성을 바탕으로 명암비 계수를 조정하여 데이터의 명암을 다양하게 변화시켜 데이터 증강을 한다. 제안한 데이터 증강 기법의 수식은 아래와 같다.

$$g(x, y, z) = f(x, y, z) + (f(x, y, z) - m_z) \times \alpha \quad (1)$$

$f(x, y, z)$ 는 원본 데이터,  $g(x, y, z)$ 는 명암비 적용 데이터,  $m_z$ 는 채널 별 데이터의 평균값,  $\alpha$ 는 명암비 계수이다. 본 연구에서는 명암비 계수를  $[-0.8, 0.8]$  사이의 무작위 값으로 사용하여 데이터 증강을 한다. Fig 14는 명암비 계수를  $-0.8, 0, 0.8$ 로 설정하여 적용한 결과이다.




Fig. 14. Example of GPR data contrast adjustment  
(a)  $\alpha = -0.8$ , (b) Original, (c)  $\alpha = 0.8$

### 4. Deep Learning Model

본 논문에서 사용한 학습 모델은 3D 분할 모델인 3D RU-Net이다[14]. 3D 데이터는 크기가 매우 크기 때문에 보통 데이터를 작은 패치 크기로 잘라서 사용한다. 작은 패치로 잘라내게 되면 학습 속도가 느리고 객체가 잘려서 학습이 불안정해질 가능성이 높다. 3D RU-Net은 학습을 통해 객체가 있을만한 관심 영역(ROI)을 찾고 관심 영역 안의 객체를 이미지 분할함으로 학습에 사용하는 메모리를 줄였다. 메모리의 한계로 작은 패치 크기를 사용해야 하는 3D 이미지 분할의 문제점을 관심 영역을 이용해 보완한 모델이다. Fig 13은 관로가 두 개인 데이터에 3D

RU-Net을 적용한 예시이다. 데이터 전처리 모듈을 통해 채널 간 데이터를 일정하게 만들고 딥 러닝 모델의 입력으로 들어간다. Encoder 모델에서 관심 영역을 찾아 추출하고 Decoder 모델에서 추출한 관심영역 안의 객체를 이미징 분할한다. 마지막으로 이미지 분할 결과를 통합하여 최종 예측 결과를 뽑는다.

## 5. Loss Function

이미지 분할 작업에서 객체가 작다면 객체와 배경의 픽셀 비율 차이가 매우 크기 때문에 클래스 불균형 문제가 생긴다. GPR 탐사 데이터에서 관로는 데이터의 크기에 비해 매우 작은 객체이기 때문에 클래스 불균형 문제를 피할 수 없다. 클래스 불균형 문제가 있는 데이터에 평균 제곱 오차 손실 함수나 교차 엔트로피 손실 함수를 사용한다면 다수의 클래스에 편향되어 학습이 원활하게 진행되지 않는다. 본 연구에서는 클래스 불균형 문제를 해결하기 위해 다이슨 손실 함수를 사용한다[17]. 다이슨 손실 함수는 다이슨 유사 계수를 이용한 손실 함수로 배경을 제외한 정답 관로 영역과 예측한 관로 영역이 겹쳐지도록 학습된다. 배경 영역과는 상관없이 정답 관로 영역과 예측 관로 영역이 겹쳐질수록 손실 값이 0과 가까워지고 겹쳐지지 않는다면 손실 값은 떨어지지 않는다. 아무리 객체가 작더라도 다수의 배경에 편향되지 않고 객체의 정답과 예측결과가 겹쳐지도록 학습을 진행한다. 다이슨 손실 함수의 수식은 다음과 같다.

$$Dice Loss = 1 - 2 \times \frac{\sum_{i=1}^N (p_i \times g_i)}{\sum_{i=1}^N p_i + \sum_{i=1}^N g_i} \quad (2)$$

$N$ 은 데이터의 픽셀 수,  $p_i$ 는 예측 픽셀의 값,  $g_i$ 는 정답 픽셀의 값이다.

## IV. Experiment

### 1. Dataset

데이터 세트는 60개의 훈련 데이터 세트, 6개의 테스트 데이터 세트로 구성되어 있으며, GPR 데이터와 정답 관로 데이터는 30 x 300 x 400(채널, 높이, 너비)의 패치 단위로 잘라내어 사용한다. 이 때 훈련에 사용하는 데이터는 패치 단위로 잘라낸 데이터에 관로가 포함되어 있는 데이

터만 사용하고 테스트 데이터는 관로가 포함되지 않은 데이터도 함께 사용한다. Fig 15는 훈련 데이터와 테스트 데이터의 선별 예시이다.

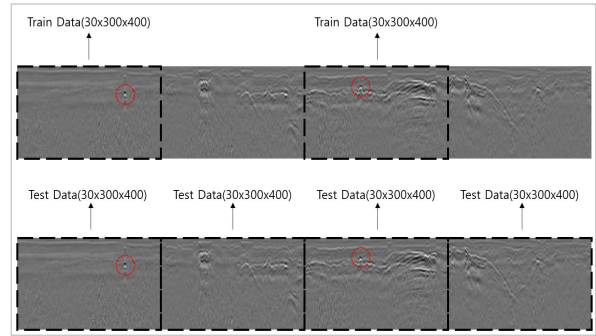


Fig. 15. Train, Test data selection

관로가 포함된 데이터만 훈련에 사용하는 이유는 데이터 클래스 불균형 문제 때문이다. 훈련에 모든 데이터를 사용하면 관로가 포함되어 있는 데이터가 극히 소량이기 때문에 학습이 원활하게 이루어지지 않는다. 테스트에 사용한 데이터 세트는 Table 1과 같다. Number of data divided는 패치단위로 잘라내었을 때 분할된 데이터 개수이다.

Table 1. Test Dataset

GPR Data	Data Size(Channel x Width x Height)	Number of data divided
Test 1	30 x 8870 x 512	23
Test 2	30 x 1961 x 512	5
Test 3	30 x 3232 x 512	9
Test 4	30 x 4501 x 512	12
Test 5	30 x 5047 x 512	13
Test 6	30 x 5056 x 512	13

### 2. Experiment

본 논문에서 제안한 관로 탐색 시스템의 성능을 평가하기 위해 실험을 진행하였다. 실험은 60개의 훈련 데이터 세트와 6개의 테스트 데이터 세트로 나누어 실험하였다. 각각의 데이터 세트는 30x300x400 패치단위로 잘라내었다. 이 때 훈련 데이터는 패치단위로 잘라낸 데이터 중 관로가 포함되어 있는 데이터만 사용한다. 패치단위로 잘라낸 훈련데이터는 446장이고 테스트 데이터는 75장이다. 본 논문에서 제안한 데이터 증강 기법과 전처리 모듈을 사용하여 학습에 적합한 데이터로 가공하였고 3D RU-Net과 다이슨 손실 함수를 이용하여 학습을 진행하였다. 실험 환경은 Table 2와 같다.




Fig. 16. Experiment result – (a) GPR data, (b) Ground Truth images, (c) Prediction images, (d) Overlap between Ground Truth and Prediction. Blue – Ground Truth, Red – Prediction, Green – Overlap of Ground Truth and Prediction.

Table 2. Experiment environment

OS	Window 10 pro
CPU	Ryzen 7 1700
GPU	GTX 1080Ti 11GB
RAM	32GB

### 3. Performance Metrics

이미지 분할의 정량적인 평가를 위해 성능 평가 지표인 Precision, Recall, F1 Score를 이용하였다. 평가를 진행한 GPR 데이터와 정답 데이터간의 모든 픽셀에 대해서 TP(True Positive), FP(False Positive, FN(False Negative)을 구하고 성능평가를 진행하였다.

#### 3.1 Precision

정밀도는 학습 모델이 예측한 관로 중 실제 관로가 포함되어 있는 비율이다. 정밀도의 계산식은 다음과 같다.

$$Precision = \frac{TP}{TP+FP} \quad (3)$$

#### 3.2 Recall

재현율은 실제 관로 중에서 학습 모델이 관로라고 예측한 비율이다. 재현율의 계산식은 다음과 같다.

$$Recall = \frac{TP}{TP+FN} \quad (4)$$

#### 3.3 F1 Score

F1 Score란 정밀도와 재현율의 조화 평균이다. F1 Score의 계산식은 다음과 같다.

$$F1\ Score = 2 \times \frac{precision \times recall}{precision + recall} \quad (5)$$

### 4. Experiment Result and Analysis

Table 3과 Fig 16은 제안한 정답 데이터를 이용한 이미지 분할 실험 결과이다. Table 3은 테스트 데이터 세트에 대한 3D 이미지 분할의 정량적 평가 결과이다. Fig 16의 (d)를 통해 정답 데이터와 예측한 데이터가 어느 정도 겹쳐있는지를 분석하였고 실제 분석 전문가들이 관로의 위치를 판단하는 최상단 좌표가 거의 비슷한 것을 눈으로 볼

Table 3. Experiment Result

Dataset	Precision	Recall	F1 Score
Test 1	0.3277	0.4357	0.3741
Test 2	0.6781	0.5816	0.6262
Test 3	0.3849	0.5604	0.4563
Test 4	0.3378	0.2542	0.2901
Test 5	0.2932	0.3886	0.3342
Test 6	0.5729	0.2449	0.3432
Avg.	0.4324	0.4109	0.4040

수 있다. Fig 16의 4번째 줄의 (d)를 보면 정답 데이터와 예측 데이터가 겹쳐있지 않지만 비슷한 곳을 예측하여 최상단 좌표만을 보았을 때 거의 일치한다. GPR 데이터는 공개되어 있는 다른 데이터 세트와 달리 데이터 생성에 한계가 있기 때문에 현재 GPR 데이터 분석 전문가들이 원하는 분석 시스템은 관로가 있는 위치를 대략적으로 찾아내어 주면 수정하여 사용하는 시스템이다. 따라서 이미지 분할의 정량적인 평가도 중요하지만 실제 그 위치에 대략적으로 관로가 있는지도 중요한 요소이다. Fig 16의 4번째 줄의 결과는 이미지 분할의 정량적 평가에는 성능이 저하되지만 관로의 위치를 대략적으로 찾아낸 것을 볼 수 있다. Table 4는 테스트 데이터에서 관로의 대략적인 위치를 찾아낸 관로의 수(Number of Correct), 실제로 관로가 있지만 찾지 못한 관로의 수(Number of Missing Pipe), 오 탐지한 관로의 수(Number of Error)를 정리한 표이다. 제안한 정답 관로 데이터를 이용하여 학습한 이미지 분할 결과를 통해 실제 관로 검출의 유의미한 결과를 도출하였다.

Table 4. Pipe detect analysis

Dataset	Number of Correct	Number of Missing Pipe	Number of Error
Test 1	6	0	6
Test 2	1	0	1
Test 3	3	0	6
Test 4	1	0	3
Test 5	2	0	0
Test 6	2	1	0

## V. Conclusions

본 논문에서는 GPR 탐사 데이터 분석 작업 효율을 증가시키기 위해 딥 러닝을 이용한 자동 관로 탐색 시스템을 제안한다. 단면의 특징이 명확하지 않은 GPR 탐사 데이터를 분석하기 위해 딥 러닝 기술 중 하나인 3D 이미지 분할을 사용하여 데이터의 연속성을 활용하였다. 학습을 위한

데이터 세트는 3D 데이터로 GPR 탐사 데이터와 제안한 관로 생성 알고리즘을 통해 만든 정답 데이터로 구성되어 있다. 그리고 GPR 탐사 데이터 특성에 맞는 데이터 전처리와 데이터 증강 기법을 제안하였다. 실험결과를 통해 제안한 시스템은 F1 Score 40.4%의 성능을 보였으며 이를 통해 이미지 분할을 이용한 관로 분석의 가능성을 확인하였다.

## ACKNOWLEDGEMENT

This work was supported by Institute of Information & communications Technology Planning & Evaluation (IITP) grant funded by the Korea government (MSIT) (No. 2018-0-00754)

## REFERENCES

- [1] D. Y. Lee, "Analysis of Sewer Pipe Defect and Ground Subsidence Risk By Using CCTV and GPR Monitoring Results", J. Korean Geosynthetics Society, Vol. 17, No. 3, pp. 47-55, Sep. 2018. DOI: <http://dx.doi.org/10.12814/jkgs.2018.17.3.047>
- [2] Daniels, David J. "Ground penetrating radar.", John Wiley & Sons, Inc, 2005.
- [3] Lee, JaeWon, DoHyeon Kim, and Yoon Kim. "Online Video Synopsis via Multiple Object Detection.", Journal of the Korea Society of Computer and Information, Vol. 24, No. 8, pp. 19-28, Aug. 2019. DOI: <https://doi.org/10.9708/jksci.2019.24.08.019>
- [4] Lee, Dong-Ryeol, and Yoon Kim. "Multi-scale face detector using anchor free method." Journal of the Korea Society of Computer and Information, Vol. 25, No. 7, pp. 47-55, Jul. 2020. DOI: <https://doi.org/10.9708/jksci.2020.25.07.047>
- [5] J. Chae, H. Ko, B. Lee, and N. Kim, "A Study on the Pipe Position Estimation in GPR Images Using Deep Learning Based Convolutional Neural Network," Journal of Internet Computing and Services, Vol. 20, No. 4, pp. 39-46, Aug. 2019. DOI: <https://doi.org/10.7472/jksii.2019.20.4.39>
- [6] H.-Y. Ko and N. Kim, "Performance Analysis of Detecting buried pipelines in GPR images using Faster R-CNN", Journal of Convergence for Information Technology, Vol. 9, No. 5, pp. 21-26, May 2019. DOI: <https://doi.org/10.22156/CS4SMB.2019.9.5.021>
- [7] Kim, Y. T., Kim, B., Kim, J. W. Park, H. M. , and Yoon, J. S. "Determining the Optimal Frequency of Ground Penetrating Radar for Detecting Voids in Pavements", Int. J. Highw. Eng. Vol. 18, No. 2, pp. 37-42, Mar. 2016. DOI: <https://doi.org/10.7855/IJHE.2016.18.2.037>


- [8] Bianchini Ciampoli, Luca, et al. "Signal processing of GPR data for road surveys." *Geosciences*, Vol. 9, No. 2, pp. 96, Feb. 2019. DOI: <https://doi.org/10.3390/geosciences9020096>
- [9] Park, Byeongjin, et al. "Underground object classification for urban roads using instantaneous phase analysis of Ground-Penetrating Radar (GPR) Data." *Remote Sensing*, Vol. 10, No. 9, pp. 1417, Sep. 2018. DOI: <https://doi.org/10.3390/rs10091417>
- [10] Kim, Namgyu, et al. "Deep learning-based underground object detection for urban road pavement." *International Journal of Pavement Engineering*, Vol. 21, No. 13, pp. 1638-1650, Dec. 2020. DOI: <https://doi.org/10.1080/10298436.2018.1559317>
- [11] Dinh, Kien, Nenad Gucunski, and Trung H. Duong. "An algorithm for automatic localization and detection of rebars from GPR data of concrete bridge decks." *Automation in Construction*, Vol. 89, pp. 292-298, May. 2018. DOI: <https://doi.org/10.1016/j.autcon.2018.02.017>
- [12] Long, Jonathan, Evan Shelhamer, and Trevor Darrell. "Fully convolutional networks for semantic segmentation." In: *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 3431-3440, Mar. 2015.
- [13] Çiçek, Özgün, et al. "3D U-Net: learning dense volumetric segmentation from sparse annotation." *International conference on medical image computing and computer-assisted intervention*, pp. 424-432, Jun. 2016. DOI: [https://doi.org/10.1007/978-3-319-46723-8\\_49](https://doi.org/10.1007/978-3-319-46723-8_49)
- [14] Huang, Yi-Jie, et al. "3-D RoI-Aware U-Net for Accurate and Efficient Colorectal Tumor Segmentation." *IEEE Transactions on Cybernetics*, Feb. 2020. DOI: <https://doi.org/10.1109/tcyb.2020.2980145>
- [15] Shorten, Connor, and Taghi M. Khoshgoftaar. "A survey on image data augmentation for deep learning." *Journal of Big Data*, Vol. 6, No.1, pp. 60, Jul. 2019. DOI: <https://doi.org/10.1186/s40537-019-0197-0>
- [16] Hyun, Seung-Yeup. "Characteristic Changes in Ground-Penetrating Radar Responses from Dielectric-Filled Nonmetallic Pipes Buried in Inhomogeneous Ground.", *The Journal of Korean Institute of Electromagnetic Engineering and Science*, Vol. 30, No. 5, pp. 399-406, May 2019. DOI: <https://doi.org/10.5515/KJKIEES.2019.30.5.399>
- [17] Dice, Lee R. "Measures of the amount of ecologic association between species.", *Ecology*, Vol. 26, No. 3, pp. 297-302, Jul. 1945. DOI: <https://doi.org/10.2307/1932409>

## Authors



Jeong-Woo Son received the B.S. degrees in Computer Science and Engineering from Kangwon National University, Korea, in 2019. He is currently a M.S. Student in the department of Computer Science and

Engineering at Kangwon National University. His research interests are in the areas of machine learning and computer vision.



Gwi-Seong Moon received the B.S. degrees in Mechanical Engineering from Sungkyunkwan University, Korea, in 2015, and he received the M.S. degrees in Computer Science and Engineering from

Kangwon National University, Korea, in 2018. He is currently a Ph.D. Student in the department of Computer Science and Engineering at Kangwon National University. His research interests are in the areas of machine learning and computer vision.



Yoon Kim received a B.S. degree in 1993, an M.S. degree in 1995, and a Ph.D. degree in 2003, in electronic engineering with the Department of Electronic Engineering from Korea University. In 2004, he joined the

Department of Computer Science and Engineering, Kangwon National University, where he is currently a professor. From 1995 to 1999, he was with the LG-Philips LCD Co., where he was involved in research and development on digital image equipment. His research interests are in the areas of machine learning, multimedia communications, and computer vision.