

# Faster R-CNN을 활용한 GPR 영상에서의 지하배관 위치추적 성능분석

고형용<sup>1</sup>, 김남기<sup>2\*</sup>

<sup>1</sup>경기대학교 컴퓨터과학과 학생, <sup>2</sup>경기대학교 컴퓨터과학과 교수

## Performance Analysis of Detecting buried pipelines in GPR images using Faster R-CNN

Hyoung-Yong Ko<sup>1</sup>, Nam-gi Kim<sup>2\*</sup>

<sup>1</sup>Student, Department of Computer Science, Kyonggi University

<sup>2</sup>Professor, Department of Computer Science, Kyonggi University

요 약 도심지에는 상·하수관로, 가스관, 수소관 등 필요에 따라 여러 가지 배관이 매설된다. 매설된 배관은 시간이 경과됨에 따라 균열 등으로 노후화되면서 폭발, 누수 등의 사고 발생 위험을 가지게 된다. 이러한 위험을 방지하기 위해 많은 노후 배관 수리, 교체되지만, 배관의 위치 또한 변경될 수 있다. 변경된 배관의 위치를 확인하지 못하면 배관을 건드리러 사고가 발생할 수 있다. 본 논문에서는 GPR을 사용하여 지하 단면 영상을 얻고, Faster R-CNN을 활용하여 지하 배관의 위치를 추정해보고, augmentation을 적용하여 부족한 데이터를 늘려서 실험을 진행하였다.

주제어 : 지하 배관, Faster R-CNN, 지표 투과 레이더, 딥러닝, VGGnet, 어그멘테이션

Abstract Various pipes are buried in the city as needed, such as water pipes, gas pipes and hydrogen pipes. As the time passes, buried pipes becomes aged due to crack, etc. these pipes has the risk of accidents such as explosion and leakage. To prevent the risks, many pipes are repaired or replaced, but the location of the pipes can also be changed. Failure to identify the location of the altered pipe may cause an accident by touching the pipe. In this paper, we propose a method to detect buried pipes by gathering the GPR images by using GPR and Learning with Faster R-CNN. Then experiments was carried out by raw data sets and data sets augmentation applied to increase the amount of images.

Key Words : Buried pipelines, Faster R-CNN, GPR, Deep learning, VGGnet, Augmentation

### 1. 서론

도시의 대형화로 도심지 개발 공사가 증가하면서 필요에 따라 상·하수관로, 가스관 등 수많은 배관이 매설되고 있다. 매설된 배관은 시간이 경과됨에 따라 균열 및 파손 등에 의해 손상되면서 폭발, 누수, 지반함몰 등의 사고 발생위험이

있다. 이러한 사고 위험을 예방하기 위해 보강 및 교체를 한다. 다만 수차례의 보강공사 및 새로운 배관의 매설로, 여러 가지 배관이 인접한 위치에 존재하게 된다. 배관관련 문서 등으로 배관의 위치를 대략적으로 파악하고 공사가 진행되지만, 확인되지 않은 배관을 건드리면 폭발, 누수, 지반함몰 등의 위험한 사고발생 위험이 있다. 이를 해결하기 위해

\*This work was supported by Kyonggi University's Graduate Research Assistantship 2019.

\*This work was partially supported by the Basic Science Research Program through the National Research Foundation of Korea, funded by the Ministry of Education under Grant NRF-2017R1D1A1B04027874

\*Corresponding Author : Nam-gi Kim([ngkim@kgu.ac.kr](mailto:ngkim@kgu.ac.kr))

Received March 15, 2019

Revised April 24, 2019

Accepted May 20, 2019

Published May 28, 2019

GPR(Ground Penetrating Radar)와 Faster R-CNN (Faster Region-based Convolutional Neural Network)을 활용해보고자 한다. GPR은 지하에 묻힌 물체를 탐지하기 위해 송신 안테나로부터 전자파를 방사하여 되돌아오는 반사파를 수신해서 지하영상 단면화를 수행한다 [1]. 그리고 GPR에서 얻은 지하영상 단면은 해당 지하 지점의 토지상태, 금속류의 물체 위치 등을 대략적으로 파악할 수 있다. 그리고 GPR에서 얻은 지하 영상 단면을 객체 탐지 방법 중 딥러닝 기반의 Faster R-CNN에 학습해보고자 한다. 이렇게 GPR과 물체 탐지 방법들을 활용하여 지하 탐지 문제를 해결하려는 연구가 진행되었으며, GPR과 딥러닝 기법을 활용한 연구도 여러 가지 진행되었지만, 실험은 방해요소가 거의 없는 지하 1m의 표면 데이터이거나 대부분 시뮬레이터로 만든 가상 데이터가 사용되었다[2-5]. 본 논문에서는 실제 GPR 이미지를 Faster R-CNN을 이용하여 GPR에서 얻은 배관의 정보를 학습하고, 간단한 Augmentation으로 검출 정확성 향상을 시키고자 하였다. Augmentation 진행 후 학습 데이터의 수 조정, stepsize 조정 2가지 방법으로 정밀도 변화를 측정했다.

## 2. 관련연구

### 2.1 Ground Penetrating Rader (GPR)

GPR은 전자파를 송신하고, 되돌아오는 반사파를 수신하여 지하영상을 단면화한다. GPR 탐사방법은 다음 Fig. 1 처럼 진행된다.

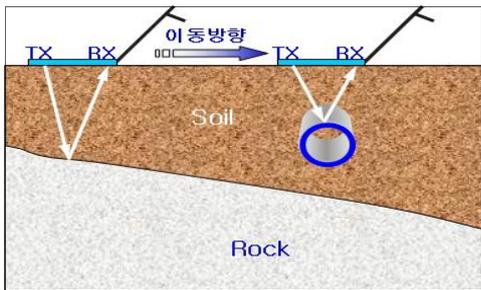


Fig. 1. GPR Exploration path

Fig. 1과 같이 탐사가 완료되면 Fig. 2의 영상을 얻을 수 있다. 매설된 배관은 아래 Fig. 2의 박스와 같이 포물선 형태로 나타나며, GPR 영상에서의 포물선 크기는 배관의 실제 크기에 영향을 받는다. 또한 매질상태정도에 따라 배관의 포물선형태의 선명도나 모양이 제대로 나오지 않거나,

배관처럼 포물선 형태를 띄우는 지점도 발생할 수 있어서 찾기가 쉽지 않다.

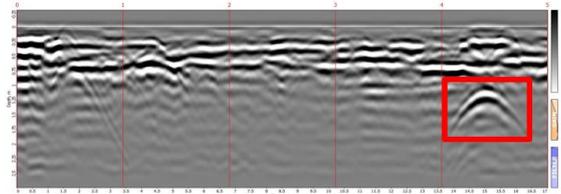


Fig. 2. GPR Sample Image

### 2.2 Faster R-CNN

Faster R-CNN은 객체를 탐지하는 딥러닝 기반 모델이다. Faster R-CNN은 이전 모델인 R-CNN[6] 과 Fast R-CNN[7]에서 Region Proposal을 담당하는 Selective Search 알고리즘을 RPN (Region Proposal Network)으로 대체해서 훈련 및 추론속도와 정확도를 향상시킨 모델이다. Selective Search 알고리즘은 Region Proposal에서 좋은 성과를 보였지만, CPU에서 동작해서 전체적인 학습 및 추론 시간에서 Selective Search 알고리즘으로 인해 병목현상이 발생해서 전체적인 속도가 느려진다. 이에 비해 RPN은 GPU에서도 동작이 되고, Faster R-CNN와 네트워크를 공유해서 계산속도가 향상되고, 정확도도 향상되었다[8,9]. 그래서 Faster R-CNN은 RPN과 Object Detection으로 구성된다. RPN은 입력된 이미지에서 물체가 있을만한 여러 후보 regions을 제안하고, Object Detection에서는 RPN에서 제안한 regions에 대한 분류를 진행하게 된다. 본 논문은 GPR로부터 얻은 이미지 속 배관위치 정보를 Faster R-CNN으로 학습하여 배관의 위치를 추정해보고자 한다.

Faster R-CNN은 크게 RPN과 Object Detection으로 구성되며, Fig. 3과 같은 구조이다.

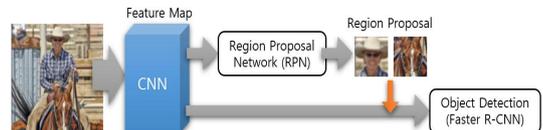


Fig. 3. Faster R-CNN Process

Faster R-CNN은 CNN을 통해서 입력 이미지의 feature map을 계산한다. feature map 계산이 완료되면, RPN에서는 object로 판단되는 region을 제안하고, Faster R-CNN에서 제안된 region가 어떤 object인지 판단한다.

### 2.3 VGGNet

VGGNet은 2014년 ILSVRC에서 K. Simonyan, A. Zisserman이 제안한 모델이다. 이 모델은 네트워크의 깊이가 성능과 연관된다는 점을 보여주었다. 제안된 여러 가지 VGGNet 모델 중 가장 좋은 것은 16개의 Convolutional/Fully Connected Layers로 이뤄지며, 모든 convolutional Layers는 3x3, 모든 pooling Layers는 2x2로 이루어져 있다. 실험에서 사용된 모델은 13-Layer로 다음 Fig. 4처럼 구성되어 있다[10].

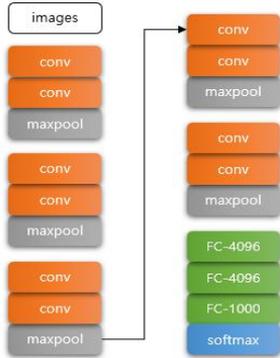


Fig. 4. Faster R-CNN 13-Layer Structure

### 2.4 Data augmentation

딥러닝 학습 진행은 많은 양의 데이터를 필요로 한다. 하지만 GPR 기계를 직접 운용하려면, 도로 일부분의 통행을 제한하는 등의 어려움이 있어서 많은 양의 데이터를 수집하기가 쉽지 않다. 따라서 적은 양의 데이터로 모델을 효율적으로 학습하기 위해서 데이터를 늘려야 될 필요가 있다. 데이터를 수집하면서 GPR 주파수, 수집범위 등에 따라 데이터가 달라지는 것을 확인하였다. 이를 이용하여 수집된 데이터를 확대, 회전으로 데이터를 늘릴 수 있었다[11].

## 3. 실험

### 3.1 실험모델

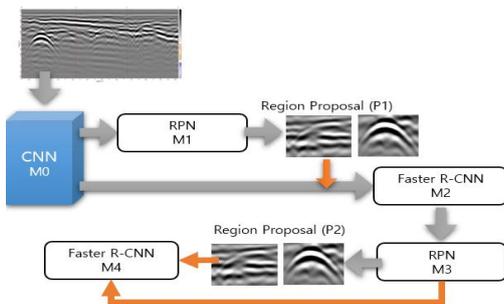


Fig. 5. Faster R-CNN Learning Process

Faster R-CNN은 위 Fig. 5처럼 학습이 진행된다. ImageNet에서 제공되는 데이터 셋으로 미리 학습된 CNN 모델 M0을 기반으로 fine-tuning 목적으로 GPR 이미지를 넣어서 RPN을 학습한다. 학습된 RPN M1으로 Region P1을 추출하고, M0과 P1을 기반으로 Faster R-CNN을 학습하여 모델 M2를 얻는다. M2의 convolution feature map을 고정하고 RPN 학습을 진행하여 모델 M3를 얻고, RPN M3를 기반으로 region P2를 추출하고, M3와 P2로 Feature R-CNN을 학습하여 최종적으로 모델 M4를 얻는다.

### 3.2 실험환경

Table 1. Experiment Environment

Parameters	Version
OS	Ubuntu 16.04
Graphic	GTX 1080
CUDA	8.0
cuDNN	5.1
Python	2.7
Tensorflow	1.2
model	VGGNet(13-Layer)

실험환경은 Table 1과 같이 구성되었다. Faster R-CNN에서 CNN은 VGGNet을 사용했으며, ImageNet에서 제공되는 데이터 셋으로 미리 훈련한 모델을 불러와서 fine-tuning 작업을 거쳤다. 훈련은 다음 표 1 환경 하에서 진행되었다.

### 3.3 실험 데이터

본 연구는 GPR 지하단면 이미지에서 배관을 찾는 과정이다. 실험에 사용된 이미지는 울산광역시에서 얻은 데이터로, GPR 300MHz, 500MHz 규격을 사용해서 얻은 지하 2-10m 데이터이다.

데이터 셋은 GPR 영상에서 나타나는 배관의 선명도에 따라 A, B, C 데이터 셋으로 나누었다.

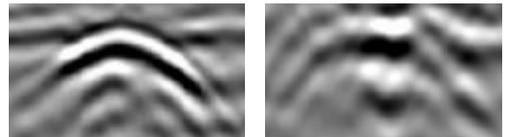


Fig. 6. Data set A

데이터집합 A는 총 71장으로 Fig. 6처럼 명확하게 포물선을 구분할 수 있는 정도를 의미한다.

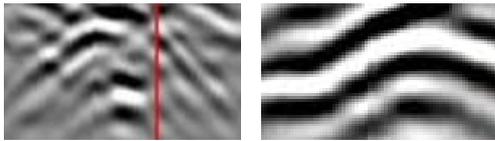


Fig. 7. Data set B

데이터집합 B는 총 13장으로 Fig. 7과 같이 명확하지는 않지만 포물선으로 예측해볼 수 있는 정도를 의미하며, 포물선의 모양이 약간 이상하거나 선명하지 않은 이미지를 포함하고 있다.

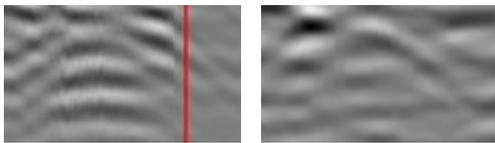


Fig. 8. Data set C

데이터 집합 C는 총 11장으로 포물선이라고 구분하기 어려운 정도를 의미한다. 실제로 배관이 존재하지만, GPR 영상에서는 Fig. 8처럼 나타나는 이미지를 포함하고 있다.

### 3.4 실험방법

실험은 3가지 방법으로 진행되었다. 데이터 셋에 Augmentation 미적용과 적용해보고, epoch당 step size를 조정해서 실험을 진행하였다.

#### 3.4.1 Augmentation 미적용 실험결과

실험 3.4.1은 데이터 셋 B, C의 자료가 A에 비해 현저히 부족하므로 데이터 셋 A로 학습하고, 실험을 진행하였다. Table 2는 Table 3에서 사용된 기호에 대한 의미이다.

Table 2. Experiment result symbol meaning

Symbol	mean
$O_A$	Number of actual pipes, Actual O
O	Number of pipes precisely predicted
X	Number of pipes mistakenly predicted
?	Number of pipes not found

Table 3. Experiment result

Results	$O_A$	O	X	?
A	11	11	0	0
B	22	14	1	8
C	23	2	2	21

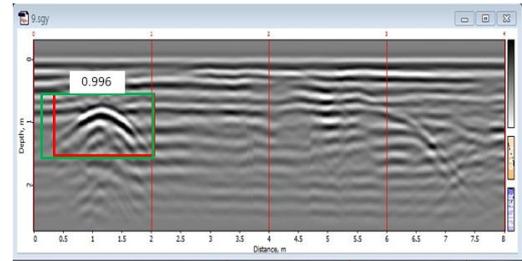


Fig. 9. Data set A verification image example

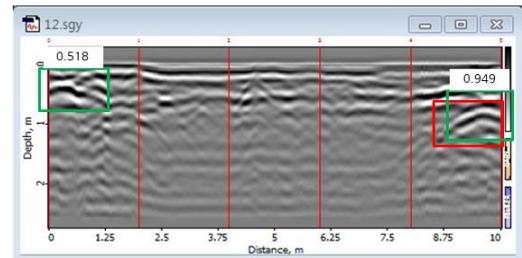


Fig. 10. Data set B verification image example

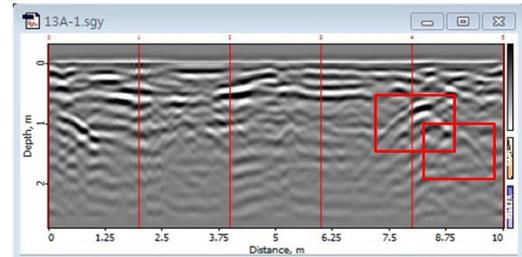


Fig. 11. Data set C verification image example

실험 A은 데이터집합 A 60장 학습, 11장 검증으로 진행하였다. Fig. 9는 검출된 사진 예시이며, Table 3은 실험 1의 전체 검출결과를 나타낸 표로, 명확하게 포물선 형태를 지닌 데이터는 제대로 검출하고 있다.

실험 B는 데이터집합 A 60장 학습하고 Fig. 10과 같은 데이터집합 B 11장 검증으로 진행했다. 포물선이라고 추정되는 이미지는 분류하지만, 모두 추정하지는 못하는 결과를 확인할 수 있다.

실험 C는 데이터집합 A 60장 학습, Fig. 11과 같은 데이터집합 C 11장 검증으로 진행했다. 뚜렷한 배관만을 학습한 모델로는 포물선이 선명하지 않은 대부분의 배관을 탐지하지 못하는 결과를 얻었다.

#### 3.4.2 Augmentation 적용 실험결과

Augmentation은 데이터 셋 A, B를 사용해서 진행되었으며, 데이터 셋 C는 데이터 셋 B와 비슷한 형태이나, 포물

선 형태가 희미해서 학습에 방해될 수 있어서 제외하고 진행하였다. Augmentation은 간단하게 포물선 이미지의 각도를 좌측이나 우측으로 1-3도까지 바꾸면서 생성하였다. 실험은 학습 데이터 수 조정, epoch당 step size 조정 2가지 방법으로 진행하였다.

Table 4와 Fig. 12는 학습 데이터 수와 step size를 조정하면서 측정한 결과이다. 원본 실험데이터가 불충분하므로 augmentation은 400장까지만 진행하였다. 결과에서 확인할 수 있듯이 데이터의 수가 늘어날수록 정확도가 향상되는 것을 확인할 수 있다. 또한 100-300장까지는 stepsize 1000에서 최적의 성능을 보여주고 있고, 400장은 stepsize 1500에서 최적의 성능을 보여주고 있다. 그 이후로는 비슷한 이미지가 너무 많이 학습되어서 오버피팅되는 결과가 나타났다.



Fig. 12. Graph result with augmentation applied

Table 4. Result with augmentation applied

Step Data \	500	1000	1500	2000	2500
100	0.394	<b>0.421</b>	0.367	0.368	0.368
200	0.520	<b>0.528</b>	0.444	0.516	0.443
300	0.425	<b>0.520</b>	0.432	0.456	0.372
400	0.473	0.513	<b>0.553</b>	0.442	0.438

#### 4. 결론 및 향후연구

GPR 영상에 딥러닝 기법 중에 하나인 Faster R-CNN을 적용하여 배관 위치를 추정해보는 연구를 진행하였다. 실제로 측정한 데이터로만 학습하였고, 데이터 수가 학습하기에는 적어서 낮은 정확도를 보이고 있다. 다만, 간단한 augmentation을 적용하여 데이터의 수를 늘려서 학습을 진행했을 때 정확도가 향상되는 점을 확인하였다. 향후 연구로는 이미지 전처리 후 학습 진행, 배관크기에 따라 개별 학습진행, 임계값 변경, 효율적인 augmentation 방법 적용 등을 통해서 적은 이미지에도 만족할만한 정확도를 보여

주는 방법을 연구하고자 한다. 또한, 배관 이외에 지반함몰, 매질상태 등에 따라 배관이 없음에도 불구하고 포물선 형태를 띠는 곳을 따로 개별 학습하여 정확도를 개선해보려고 한다.

#### REFERENCES

- [1] D. Daniels. (2004). *Ground penetrating rader*. The Institution of Engineering and Technology Publishing.
- [2] D. Y. Lee. (2018). Analysis of sewer pipe defect and ground subsidence risk by using CCTV and GPR monitoring results. *Journal of Korean Geosynthetics Society*, 17(3), 47-55. DOI : 10.12814/jkgss.2018.17.3.047
- [3] M. G. Huici. (2013). *Accurate ground penetrating radar numerical modeling for automatic detection and recognition of antipersonnel landmines*. Doctoral dissertation. Rheinischen Friedrich Wilhelms Universität Bonn, Bonn.
- [4] Q. Dou, L. Wei, D. R. Magee & A. G. Cohn. (2017). Real-time hyperbola recognition and fitting in GPR data. *IEEE Transactions on Geoscience and Remote Sensing*, 55(1), 51-62. DOI : 10.1109/TGRS.2016.2592679
- [5] M. C. Lee, H. C. Shin & J. H. Yoon. (2011). A study on the ground following and location marking method for mine detection system. *Journal of the Korea Institute of Military Science and Technology*, 14(6), 1002-1008. DOI : 10.9766/KIMST.2011.14.6.1002
- [6] R. Girshick, J. Donahue, T. Darrell & J. Malik. (2014). Rich feature hierarchies for accurate object detection and semantic segmentation. *2014 IEEE Conference on Computer Vision and Pattern Recognition* (pp. 580-587). DOI : 10.1109/CVPR.2014.81
- [7] R. Girshick. (2015, Sep). Fast R-CNN. *2015 International Conference on Computer Vision* (pp. 1440-1448). DOI : 10.1109/ICCV.2015.169
- [8] S. Ren, K. He, R. Girshick & J. Sun. (2017). Faster R-CNN: Towards real-time object detection with region proposal networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(6), 1137-1149. DOI : 10.1109/TPAMI.2016.2577031
- [9] S. J. Shin, J. K. Park, Y. Y. Kim, J. H. Jang & I. C. Moon. (2017). Analsys of the effect of convolutional neural network model on training and prediction in Faster

R-CNN. *Journal of Korean Institute of Industrial Engineers*, 1-5.

- [10] K. Simonyan & A. Zisserman. (2015, Apr). Very deep convolutional networks for large-scale image recognition. *Proceedings of International Conference on Learning Representations* (pp. 1-14).
- [11] C. J. Kim, S. K. Ko, B. E. Kim, H. D. Jung & C. S. Cho. (2018). Object detection based on data augmentation using image rotation. *Journal of Institute of Electronics and Information Engineers*, 545-548.

고 형 용(Ko, Hyoung Yong)

[정회원]



- 2018년 2월 : 경기대학교 컴퓨터과학과 (공학사)
- 2018년 3월 ~ 현재 : 경기대학교 컴퓨터 과학과 석사과정
- 관심분야 : 딥러닝, 네트워크
- E-Mail : kgu15460@gmail.com

김 남 기(Kim, Nam Gil)

[정회원]



- 2005년 2월 : KAIST 전자계산학(공학 박사)
- 2005년 2월 : 삼성전자 통신연구소 책임연구원
- 2007년 2월 ~ 현재 : 경기대학교 컴퓨터 과학과 교수

- 관심분야 : 통신시스템, 네트워크
- E-Mail : ngkim@kgu.ac.kr