

GPR 영상에서 CNN을 이용한 지뢰 식별 연구

이현기, 마정목*
국방대학교 국방과학학과

A Study on Mine Detection in GPR Images Using CNN

Hyun-gi Lee, Jung-mok Ma*
Department of Defense Science, Korea National Defense University

요약 우리나라의 지뢰지대는 여의도 면적의 44배인 128km²이며, 매설량은 최소 82만 8천개에 달한다. 지표투과레이더는 기존 지뢰탐지기로 찾아내지 못했던 목함파 발목 지뢰 등 비금속 지뢰까지 탐지가 가능하고, 탐지된 지뢰를 영상으로 확인할 수 있다는 점에서 탐지율은 월등히 높아지고 오경보율은 저하되는 등 지뢰 탐지 성능이 기존 금속탐지기보다 매우 향상되었다. 최근에는 영상 식별 성능을 강화하기 위하여 레이더 신호에 인공지능을 접목한 연구가 증가하고 있으나, 군사보안 상의 이유로 실제 지뢰의 GPR 데이터는 민간에서 연구가 진행되기가 어려웠다. 본 논문에서는 실제 군에서 사용 예정인 지뢰탐지기-II의 GPR 영상 데이터를 기반으로 CNN(Convolutional Neural Network) 모델에 적용하여 99.5%의 정확도를 확인하였으며, 시뮬레이션을 통한 연구와 비교하여 실제 데이터를 학습한 모델의 성능이 우수함을 확인하였다. 또한 토양별로 실험을 진행하여 사양토, 부엽토, 수풀에서 각각 100%, 99%, 98.9%의 정확도를 보임을 확인하였다. 앞으로 실제 야전에서 지뢰탐지기-II를 운용하며 지속적으로 데이터를 구축해 나간다면 정확도는 더욱 높아질 것으로 기대된다. 향후 지뢰 유사물질의 파형에 대한 개별 학습을 통해 오경보율을 줄여 나가는 연구를 수행할 예정이다.

Abstract The landmine zone in the Republic of Korea is 128km² and the landmines buried total at least 828,000 units. Ground penetrating radar (GPR) has improved mine detection performance, compared to metal detection, in that it can detect non-metallic landmines not found by conventional detectors. Also, GPR can check the detected landmines via video, increasing the detection rate and lowering the false alarm rate. Even though many studies on artificial intelligence with radar signals have been discussed to enhance the performance of image identification, private-level research based on actual GPR data has been difficult to conduct owing to military security. This paper confirmed 99.5% accuracy by applying a Convolutional Neural Network (CNN) model based on GPR data from Mine Detector II, scheduled for use by the army, which is more accurate than in previous studies. In addition, we conducted experiments based on three soil types and confirmed accuracies of 100%, 99%, and 98.9%. We expect accuracy will increase further with the accumulation of data from field operations. In the future, research will be conducted to reduce the false alarm rate by learning the waveforms of mine-like substances.

Keywords : Mine Detection, Gound Penetrating Radar, Deep Learning, Convolutional Neural Network, Accuracy

*Corresponding Author : Jung-mok Ma(Korea National Defense Univ.)

email: jxm@gmail.co.kr

Received March 31, 2022

Accepted June 3, 2022

Revised May 4, 2022

Published June 30, 2022

1. 서론

1.1 연구배경

지구상에는 약 13만 5천개의 지뢰가 63개국의 무기 고에 보관 중이고, 2020년에만 최소한 7,073명 이상이 지뢰로 인한 사상자가 발생하였다. 전 세계적인 노력으로 지뢰의 수는 점차 줄어들고 있으나 지뢰로 인한 사상자는 지속적으로 증가하는 추세이다[1]. 국방부에 따르면, 우리나라의 지뢰지대는 여의도 면적의 44배인 128 km²이며 매설량은 최소 82만 8천개에 달한다. 특히 비무장지대와 서해 5도 민통선 지역에 82만 5천개가 묻혀있으며 전방 이외의 35개소에도 3천여 발이 매설되어 있다. 이중에서도 무게가 100g으로 가볍고 플라스틱으로 만들어진 발목지뢰와 파괴력이 큰 목함지뢰는 집중호우 시 물살에 휩쓸려 쉽게 유실되어 국민의 안전에 큰 위협이 되어왔다.

이러한 지뢰의 위험요소로 인하여 지뢰 제거의 필요성이 지속적으로 제기되었으나 기존에 군이 운용 중인 지뢰탐지기(PRS-17K)는 비금속 지뢰에 대한 탐지가 불가능하였다. 이에 우리 군에서는 Fig. 1에서 보이는 지표투과레이더(GPR: Ground Penetrating Radar, 이하 GPR)를 적용한 지뢰탐지기-II(PRS-20K)를 개발하여 양산 계약을 체결하였다. GPR은 기존 지뢰탐지기로 찾아내지 못했던 목함과 발목 지뢰 등 비금속 지뢰까지 탐지가 가능하고, 탐지된 지뢰를 영상으로 확인할 수 있어 탐지율은 월등히 높아지고 오경보율은 저하되는 등 지뢰탐지 성능이 기존 금속탐지기보다 훨씬 향상되었다.




Fig. 1. Composition of PRS-20K

최근에는 지뢰탐지기의 영상 식별 성능을 강화하기 위해 GPR 신호에 영상 처리 분야에 많이 활용되는 머신러닝을 접목한 연구사례가 증가하는 추세이다. 그중에서

도 특히 딥러닝 기반의 CNN을 활용한 이미지 분류 성능은 기존 알고리즘보다 우수한 모습을 보였다. 딥러닝 기반 CNN 기술로는 대표적으로 Alexnet[2], VggNet[3], Inception[4] 등과 같은 다중 클래스 분류 모델들이 있다. 또한 많은 양의 데이터를 활용하여 이미지 분류에서 우수한 사전 학습된 CNN 모델을 활용하는 ImageNet[5]은 데이터가 많지 않은 이미지 분류에서도 좋은 모습을 보이고 있다.

그러나 현재 군에서 사용 중인 실제 지뢰의 GPR 영상은 비밀로 관리되고 있어 민간에서의 데이터 획득이 쉽지 않다. 따라서 CNN을 활용한 지뢰식별에 대한 연구는 전무한 상태이며, 야전에서 지뢰탐지기-II를 활용하여 지뢰식별 시 운용병 또는 간부의 경험에 의존해야 한다는 문제점을 가지고 있다. 따라서 지뢰탐지기-II를 활용한 실제 지뢰의 GPR 영상으로 CNN을 통한 이미지 분류 모형에 대한 활발한 연구가 필요하다.

이러한 인식을 바탕으로 기존의 지뢰탐지 연구와 GPR 데이터를 활용한 이미지 분류 모형에 대한 선행연구를 확인하고, 육군 데이터랩에서 실제 지뢰의 GPR 데이터를 획득하였다. 데이터가 충분하지 않기 때문에 사전 학습된 CNN모델 중 Inception v3 모델을 사용하여 실험을 진행하고, 관련된 선행 연구들과 분류 정확도의 비교를 통해 CNN을 활용한 지뢰탐지의 실효성을 제시하고자 하였다. 본 논문의 연구절차는 Fig. 2와 같다.

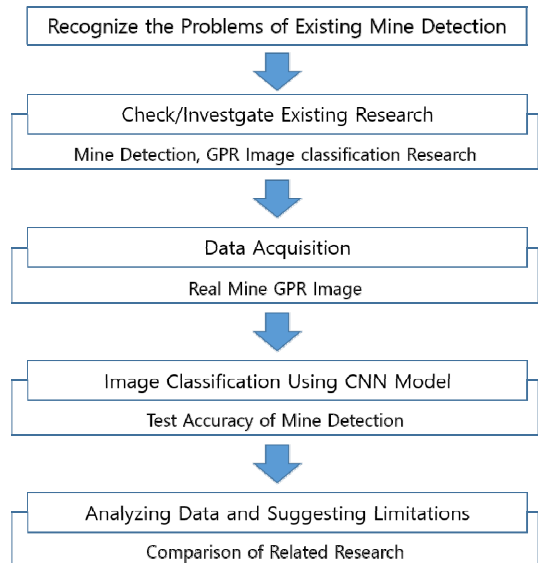


Fig. 2. A diagram of experimental procedures

1.2 관련연구

국내외에서 다양한 이론을 바탕으로 GPR 영상으로부터 지하공동이나 배관, 지뢰를 탐지하기 위한 연구가 발표되었다. S. Lameri et al[6]은 gprMax 시뮬레이션을 통해 생성한 영상을 CNN 알고리즘을 이용하여 학습시킨 뒤 실물지뢰의 GPR 영상을 이용하여 지뢰를 식별하여 95%의 식별율을 보였다. 함종현[7]은 실물 지뢰 GPR 영상에 여러 가지 필터를 적용하여 최적의 탐지 알고리즘을 제안하였다. 채지훈[8]은 Inception v1 모델을 사용하여 GPR 영상에서 배관의 위치를 탐지하는 모델을 제안하였고 모델은 94.1%의 탐지율을 보였다. 김동현[9]은 배열형 GPR 시스템을 이용하여 지뢰탐지 시스템을 구성하고 영상형성을 위한 신호처리 알고리즘을 구성하였다. 신호처리 알고리즘을 통해 탐지율을 94.4%까지 높이고 딥러닝을 통한 식별율과 비교하는 연구를 진행하였다. 유영준[10]은 gprMax 시뮬레이션을 통해 생성한 영상을 VGGNet 모델을 통해 학습시켜 지하배관을 식별하는 모델을 제안하였고 측정된 학습 모델의 정확도는 약 92.3%로 나타났다.

많은 연구들이 실제 환경에서 GPR 데이터를 수집하기 위해서는 많은 인력과 시간이 필요하기 때문에 시뮬레이션을 활용하여 가상의 데이터를 통해 실험을 진행하고 있었다. 반면에 본 연구에서는 육군교육사령부에서 지뢰탐지기-II를 사용하여 실시한 전투실험 결과를 바탕으로 실물지뢰에 대한 GPR 영상에서 지뢰가 존재하는 영역, 존재하지 않는 영역을 추출하고 이를 각각 라벨링하여 학습, 검증 및 평가 데이터를 구축하였다. 연구에서 확인하고자 하는 사항은 두 가지이다. 첫 번째, 실제 지뢰 영상으로 학습된 모델로 지뢰와 지뢰가 아닌 영상 판별의 정확도를 기존 연구와 비교해 봄으로써 야전에서

의 실효성을 확인하고, 두 번째, 사양토, 부엽토, 수풀에서 수집된 파형을 구분하여 평가한 뒤 그 정확도를 통해 지뢰탐지기-II의 야전 운용 시 지형별 특성에 대해 확인할 것이다. 이는 군에서 운용 예정인 지뢰탐지기-II를 활용한 실제 지뢰의 GPR 영상을 CNN에 접목하여 지뢰탐지에 활용한 첫 논문이며 시뮬레이션을 사용한 가상데이터를 통해 지하공동이나 배관, 지뢰를 탐색하였던 기존 논문들과 목적과 방법에 차이가 있다. 관련 연구들과 본 연구의 차이점을 비교하여 정리하면 Table 1과 같다.

2. 이론적 배경

2.1 Ground Penetrating Rader (GPR)

GPR은 안테나를 통해 전파를 송신하고, 반사되는 전파를 안테나로 수신하여 지하영상을 단면화한다. GPR 탐사방법은 다음 Fig. 3처럼 진행된다.

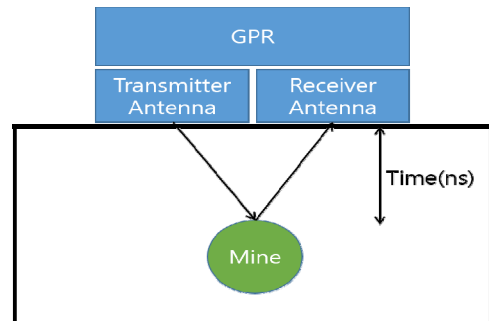


Fig. 3. Concept of GPR




Fig. 4. GPR Sample Image

Fig. 3와 같이 탐사를 진행하면 Fig. 4의 영상을 얻을 수 있다. 매설된 지뢰는 아래 Fig. 4의 빨간색 박스와 같이 포물선 형태로 나타나며, 그 크기는 지뢰의 실제 크기에 영향을 받는다. 또한 매질의 상태나 종류에 따라 포물

Table 1. Related research

	Objective	Method	Data
S. Lameri et al[6]	Mine detection	Convolutional Neural Network	Virtual data
J.H.Ham[7]	Mine detection	Frequency shifting filtering	Real data
J.H.Chae[8]	Pipe position Estimation	Convolutional Neural Network	Virtual data
D.H.Kim[9]	Mine detection	Signal processing	Real data
Y.J.Yoo[10]	Pipe position Estimation	Convolutional Neural Network	Virtual data
This paper	Mine detection	Convolutional Neural Network	Real data

선 형태의 선명도나 모양이 제대로 나오지 않거나, 포물선 형태가 보이지 않는 지점도 발생할 수 있어 식별이 쉽지 않다.

2.2 CNN(Convolutional Neural Network)

CNN은 최근 딥러닝 기반의 영상 및 이미지 인식에서 좋은 성능을 보여주고 있다. CNN은 합성곱층(convolutional layer), 풀링층(pooling layer), 드랍아웃 계층(dropout layer), 완전 연결층(fully connected layer) 등을 여러 층으로 쌓아서 만들어진 구조를 갖는다. 대부분의 모델들이 여러 합성곱 계층을 거치고 나온 특성맵(feature map)들을 다시 합성곱층을 거치도록 하거나 풀링층을 거치도록 깊게 연결되어 있고 마지막 후반부에는 완전 연결층을 거치도록 하여 입력된 영상 및 이미지의 종류를 판별하게 된다[11].




Fig. 5. A diagram of CNN model

Fig. 5는 CNN 모델의 구조를 추상화하여 나타낸 그림이다. 그림에서 합성곱 계층은 필터에 의해 특징을 추출하고 이를 바탕으로 특성맵들을 만든다. 다수의 특징들을 추출하고 싶다면 가중치 값을 갖는 2차원의 값으로 이루어진 필터의 개수를 조정한다. 풀링층은 특성맵의 크기를 줄여서 연산량을 감소시킨다. max-pooling 방식을 사용하여 연산 과정을 여러 번 거치게 되면 입력한 이미지를 대표하는 특징들을 얻을 수 있게 된다. CNN에서 네트워크가 깊고 넓어지게 되면 위의 과정을 반복적으로 거치게 되고 이를 통해 점점 작아진 특성맵 내부에 입력한 이미지의 특징이 압축된다. 하지만 이렇게 압축되고 네트워크의 망이 깊어지다 보면 학습한 이미지에 대해서만 과적합(overfitting)되는 문제가 발생할 수 있다. CNN에서는 문제를 예방하기 위해서 드랍아웃 계층을 사용한다. 이는 연결되어 있는 뉴런들을 일정한 비율로 무시하는 방식으로 추출된 모든 특징들을 학습에 반영하지 않도록 하여 문제를 예방할 수 있다. CNN에서는 마지막으로 완전 연결층을 두는데 이 층은 연결되어 있는 뉴런들로 추출된 특징값들을 softmax 함수를 통해서 분류하기 위해 사용된다.

2.3 Inception v3

Inception v3는 42개의 계층으로 구성된 신경망이며 여러 제약 조건에서도 잘 수행될 수 있는 구조이다. 기존의 Inception 모델과의 차이점은 합성곱층에서 사용되는 필터의 크기를 7x7에서 3x3으로 분해하고, 비대칭 합성곱으로 분해하여 연산량과 파라미터의 양을 축소하고 효율적인 연산을 가능하게 한 것이다. 이러한 구조로 Inception v3는 연산의 복잡도를 줄이고 파라미터 수를 적게 사용하면서도 더 난해한 분류 문제를 해결하고 학습 속도를 향상시킨다는 장점이 있다.

3. 지뢰 식별 모델

본 연구에서 실물지뢰 GPR 영상 이미지 분류 과정은 데이터 수집 및 전처리, 실물지뢰 GPR 이미지 분류 모델 학습, 실물지뢰 GPR 이미지 분류 모델 평가 단계로 구성된다. 첫 번째 데이터 수집 및 전처리 단계에서는 실물지뢰의 GPR 영상을 수집하고 GPR 영상에서 명확하게 지뢰가 존재하는 영역과 존재하지 않는 영역을 추출하여 라벨링한다. 두 번째 이미지 분류 모델 학습단계에서는 지뢰가 존재하는 영역을 식별하기 위한 CNN 모델을 구축하여 준비된 이미지를 학습시킨다. 마지막으로 이미지 분류 모델 평가 단계에서는 준비된 지뢰 이미지 평가 데이터를 이용하여 분류의 정확도를 확인한다.

3.1 실물지뢰 GPR영상 데이터 수집 및 전처리

데이터 세트는 육군교육사령부 AI소요관리과에서 2021년 6월 21일부터 25일까지 공병학교에서 실시한 전투실험을 통해 수집된 M14, M16, 목함지뢰, 수지반 보병지뢰, M15, M19 파형 데이터 783개를 육군 데이터 랩에서 획득하였다. 전투실험 조건은 아래 Table 2와 같다. 본 실험에서는 그 중 오정보 물체와 탐지속도가 0.5m/s를 초과하는 데이터를 제외한 318개의 데이터를 사용하였다.

학습에 사용할 데이터는 원본 GPR 영상에서 명확하게 지뢰가 존재하는 영역과 존재하지 않는 영역의 좌표를 획득하여 라벨링하였다. 원본 GPR에서 추출된 지뢰가 존재하는 영상은 Fig. 6과 같은 포물선 모양을 나타내고 지뢰가 존재하지 않는 영상은 Fig. 7과 같은 패턴을 나타낸다.

Table 2. Conditions of Combat experiment

Soil	Sandy loam, Leaf mold, Bush
Depth of mine	5cm, 10cm, 15cm(Anti-personnel mine) 10cm, 20cm, 30cm(Anti-tank mine)
Buried angle	0°, 45°, 90°(M14)
Detection speed	Below 0.5m/s Above 0.5m/s
Distance from ground	0cm, 5cm




Fig. 6. Extracted image with mine




Fig. 7. Extracted image without mine

전처리 작업을 거친 전체 데이터 6,360개를 80:10:10의 비율로 서로 중복되지 않도록 랜덤하게 훈련 데이터(training data) 5,088장, 검증 데이터(validation data) 636장, 평가 데이터(test data) 636장으로 나누었다. 각각의 역할을 살펴보면 먼저 훈련 데이터는 학습을 통해 분류 모델을 만들기 위한 것이며, 검증 데이터는 훈련 데이터로 학습된 모델을 평가하여 훈련 손실 값과 검증 손실 값의 차이를 비교 분석하고 모델의 파라미터 값을 조정하여 과대적합을 줄여준다. 마지막으로 평가 데이터는 최종 모델의 성능을 평가하는 것이다. 성능 평가에는 다양한 평가지표가 있지만 이번 연구에서는 정확도(accuracy)로 확인하였다.

3.2 이미지 분류 모델 학습

실제 데이터 수집 및 전처리 단계를 거친 GPR 이미지 데이터는 사전 학습된 CNN 모델에 재학습시키는 과정을 거친다. 사전 학습된 CNN 모델을 재학습하는 데에는 아래 Fig. 8와 같은 두 가지 방법을 사용할 수 있다.

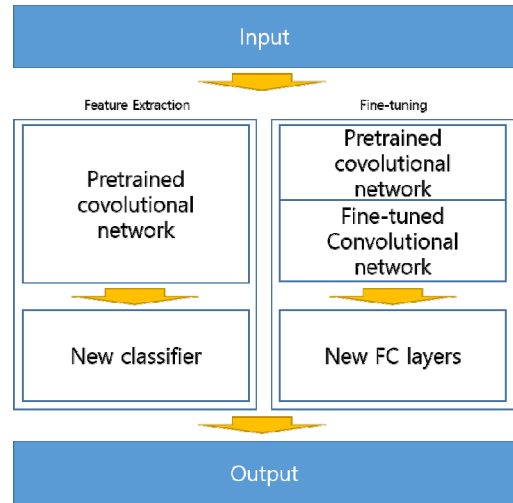


Fig. 8. Feature extraction and Fine-tuning[12]

첫 번째로 특징 추출(feature Extraction) 방법이 있는데 이 방법은 사전 학습된 모델의 완전 연결층을 제외한 다른 계층의 가중치는 고정시키고 완전 연결층의 가중치만 갱신하여 훈련시키는 방법이다. 두 번째 방법으로는 파인 튜닝(fine-tuning)으로 완전 연결층을 주어진 데이터로 재학습 시킨 완전 연결층으로 교체할 뿐만 아니라 완전 연결층을 제외한 다른 계층 모두, 혹은 일부를 주어진 데이터로 재학습 시키는 방법이다[12]. 특징 추출 방법에 비해서 파인 튜닝 방법은 전체적인 모델의 가중치를 원하는 데이터에 맞는 가중치로 바꾸기 때문에 더 좋은 성능을 기대 할 수 있다. 따라서 본 논문에서는 파인 튜닝 모델 방법을 적용한 Inception v3 모델을 사용하였다.

전체 데이터에 대해 총 40번(epoch=40)의 학습이 이루어졌으며, 전체 데이터에 대해 한번 학습 시 100개의 batch-size로 2000번을 나누어 수행하였다. 실험은 기계학습을 위한 클라우드 기반 환경인 google colab jupyter notebook GPU 가속기 모드를 사용하였고, python 3.7.13과 구글에서 배포한 기계학습 라이브러리인 tensorflow 2.8 환경에서 실험하였다.

3.3 이미지 분류 모델 평가

첫 번째, 지뢰 GPR 파형 이미지를 학습한 모델의 분류 정확도 실험 결과는 99.5%의 정확도를 보여 군에서 인공지능을 접목하여 지뢰를 탐지할 시 실효성이 높음을 알 수 있었다. GPR 시뮬레이션을 사용하여 만들어진 GPR 파형을 학습시킨 기존의 연구와 정확도를 비교해보면 Table 3과 같다.

Table 3. Comparison of related research

	Test accuracy
This model(All type)	99.5%
This model(Sandy loam)	100%
This model(Leaf mold)	99%
This model(Bush)	98.9%
S. Lameri et al[6]	95%
J.H.Chae[8]	94.1%
Y.J.Yoo[10]	92.3%

기존의 연구는 S. Lameri et al의 연구를 제외하고 평가 또한 만들어진 GPR 파형 데이터를 통해 실시하였고, 상대적으로 배관은 지뢰보다 크기 때문에 지뢰에 비해서 식별이 쉽다는 것을 감안하였을 때 실제 지뢰의 GPR 파형을 학습한 모델의 성능이 우수함을 알 수 있었다.

두 번째, 토양별로 수집된 파형을 학습한 모델의 분류 정확도를 실험하기 위해 사양토에서 실험한 2,760개, 부엽토와 수풀에서 실험한 각각 1,800개의 데이터로 첫 번째 실험과 동일한 방법으로 실험해 보았다. 그 실험 결과는 각각 Table 3과 같다.

실험 결과, 모든 토양에서 지뢰 식별의 정확도가 기존 연구 결과보다 우수함을 알 수 있었다. 또한 직관적으로도 실험을 위해 잘 조성된 사양토보다 낙엽이나 풀잎이 함께 섞인 부엽토와 수풀에서 정확도가 떨어질 것으로 예측할 수 있었으나 실험을 통해 정량적으로 확인할 수 있었다.

4. 결론

본 논문에서는 우리 군에서 실제 운용 예정인 PRS-20k의 GPR 영상에서 지뢰를 식별하기 위한 CNN 모델을 제시하고 이를 실험하였다. 실제 지뢰의 GPR 영상 데이터는 군사보안 상의 이유로 민간에서 활용이 어려워 관련된 연구가 진행되지 않았다. 따라서 본 연구에

서는 실제 지뢰의 데이터를 활용하여 CNN을 이용한 이미지 분류를 통해 그 실효성을 증명하고자 하였다.

이미지 분류 모델으로는 학습 속도가 빠르고 적은 데이터로도 우수한 성능을 나타내는 Inception v3 모델을 적용하였다. 뿐만 아니라 사양토, 부엽토, 수풀에서 수집된 M14, M16, 목함지뢰, 수직반보병지뢰, M15, M19의 파형 이미지 6,360장의 이미지로 모델을 학습하였다. 결과적으로 시뮬레이션을 사용한 기존연구의 모델들보다 높은 99.5%의 정확도를 보임을 확인하였으며, 각 지형별로는 사양토에서 100%, 부엽토에서 99%, 수풀에서 98.9%의 정확도를 보임을 확인하였다. 또한 앞으로 실제 야전에서 지뢰탐지기-II를 운용하며 지속적으로 데이터를 구축해 나간다면 정확도는 더욱 높아질 것으로 기대된다. 하지만 제시한 모델은 유사물질과 지뢰를 구분하기 어렵다는 한계가 있다. 향후 이러한 오경보율을 줄이기 위해 유사물질의 파형을 따로 개별 학습하여 정확도를 개선해 나갈 필요가 있다.

References

- [1] Landmine Monitor 2021. International Campaign to Ban Landmines, 2021. Available From: <http://www.the-monitor.org/media/3318354/Landmine-Monitor-2021-Web.pdf> (accessed Mar 30, 2022)
- [2] A. Krizhevsky, I. Sutskever, G. E. Hinton, "ImageNet classification with deep convolutional neural networks", *Communication of the ACM*, Vol.60, Issue 6, pp.84-90, June 2017.
DOI: <https://dx.doi.org/10.1145/3065386>
- [3] K. Simonyan, A. Zisserman, "Very Deep Convolution Networks for Large-scale Image Recognition", *International conference on Learning Representation(ICLR)*, 2015.
DOI: <https://doi.org/10.48550/arXiv.1409.1556>
- [4] C. Szegedy, W. Liu, Yangqing Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. vanhoucke, A. Rabinovich, "Going deeper with convolutions", *Computer Vision and Pattern Recognition*, 2015.
DOI: <https://doi.org/10.48550/arXiv.1409.4842>
- [5] O. Russakovsky, J. Deng, H. Su, J. Krause, S. Satheesh, S. Ma, Z. Huang, A. Karpathy, A. Khosla, M. Bernstein, A. C. Berg, L. Fei-Fei, "ImageNet Large Scale Visual Recognition Challenge", *International Journal of Computer Vision*, Vol 115, No.3, pp.211-252, December 2015.
DOI: <https://doi.org/10.1007/s11263-015-0816-y>
- [6] S. Lameri, F. Lombardi, P. Bestagini, M. Lualdi, S. Tubaro, "Landmine detection from GPR data using

convolutional neural networks”, *European Signal Processing Conference (EUSIPCO)*, IEEE, Kos, Greece, pp.508-512, Aug. 2017.

DOI: <https://doi.org/10.23919/EUSIPCO.2017.8081259>

- [7] J. H. Hahm, M. J. Kim, E. D. Heo, S. D. Kim, D. H. Kim, S. H. Choi, “Ground Penetrating Radar based Hand-held Landmine Detection System using Frequency Shifting Filtering”, *Journal of The Institute of Electronics and Information Engineers*, Vol.54, No.5, pp.74-84, May 2017.
DOI: <https://doi.org/10.5573/ieie.2017.54.5.74>
- [8] J. H. Chae, H. Y. Ko, B. G. Lece, N. G. 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, 2019
DOI: <https://doi.org/10.7472/ksii.2019.20.4.39>
- [9] D. H. Kim, S. H. Choi, “A Study on Signal Processing of Array-type Ultra Wideband based Ground Penetrating Radar for Landmine Detection”, *Journal of The Institute of Electronics and Information Engineers*, Vol.58, No.9, pp.91-96, Sep. 2021
DOI: <https://doi.org/10.5573/ieie.2021.58.9.91>
- [10] Y. J. Yoo, D. H. Kim, M. H. Lee, J. K. Lee, “Simulated Data Based Deep Neural Network Training for Underground Cavity Detection”, *Journal of Korean Institute of Communications and Information Sciences*, Vol.46, No.5, pp.923-927, May 2021.
DOI: <https://doi.org/10.7840/kics.2021.46.5.923>
- [11] W. Rawat, Z. Wang, “Deep Convolutional Neural Networks for Image Classification: A Comprehensive Review”, *Neural Computation*, Vol.29, No.9, pp.2352-2449, 2017.
DOI: https://doi.org/10.1162/neco_a_00990
- [12] R. Yamashita, M. Nishio, R. K. G. Do, K. Togashi, “Convolutional neural networks: an overview and application in radiology”, *Insights Into Imaging*, Vol 9, No.4, pp.611-629, 2018.
DOI: <https://doi.org/10.1007/s13244-018-0639-9>

마 정 목(Jung-mok Ma)

[정회원]



- 2002년 2월 : 육군사관학교 운영 분석학과 (운영분석 학사)
- 2008년 8월 : 미국 펜실베이니아 주립대(PSU) (산업공학 석사)
- 2015년 5월 : 미국 일리노이대(UIUC) (산업공학 박사)
- 2015년 9월 ~ 현재 : 국방대학교 국방과학학과

<관심분야>

국방 모델링 및 데이터 분석학, 무기체계 획득관리

이 현 기(Hyun-gi Lee)

[준회원]



- 2013년 2월 : 육군사관학교 무기 시스템 공학과 (무기 시스템 공학 학사)
- 2021년 2월 ~ 현재 : 국방대학교 국방과학학과 (석사과정)

<관심분야>

인공지능, 무기체계 획득, 시스템 엔지니어링