

# 초해상화 기반 CNN을 이용한 GPR 영상에서의 지뢰 분류

이현기, 마정목\*  
국방대학교 국방과학학과

## Mine Classification in GPR images Using Super-Resolution based Convolutional Neural Network

Hyungi Lee, Jungmok Ma\*  
Department of Defense Science, Korea National Defense University

**요약** 현재 우리나라의 지뢰 매설량은 최소 82만여개에 달하며 지뢰 및 불발탄에 의하여 사망하거나 치명적인 부상을 입는 사고가 매년 발생하고 있다. 이에 군에서는 새롭게 개발된 지뢰탐지기-II(PRS-20k)를 2022년부터 전 군에 보급하고 있다. 지뢰탐지기-II에 탑재된 지표투과레이다(GPR : Ground Penetrating Radar, 이하 GPR)는 비금속 지뢰 또한 탐지가 가능하고, 탐지된 지뢰를 이미지로 확인 가능하여 오경보율을 감소시킬 수 있었다. 그러나 GPR 이미지의 경우 비용과 시간적인 문제로 인해 고해상도의 이미지를 얻는 데 한계가 있으며 이에 따라 객체를 좀 더 정확하게 탐지하고 분류하는 데도 한계가 있었다. 따라서 본 논문에서는 저해상도 영상에서 고해상도의 영상을 획득하는 기술인 초해상화 기법을 적용하여 분류하는 연구를 실시하였다. 지뢰탐지기-II의 GPR 이미지 데이터를 기반으로 CNN(Convolutional Neural Network) 모델을 활용하여 구별하는 모델과, 초해상화를 거친 2배, 4배의 고해상도 영상을 학습하여 구별하는 모델을 비교하였을 때 초해상화를 거친 모델의 분류 정확도가 3~6% 향상되는 것을 확인할 수 있었다. 향후 간결하고 가벼운 알고리즘을 통해 소요 시간을 줄여나가는 연구를 수행할 예정이다.

**Abstract** The number of landmines buried in Korea is estimated to be at least 820,000, and deadly accidents or fatal injuries by landmines and unexploded ordnance occur every year. Accordingly, the military has supplied a newly developed mine detector-II (PRS-20k) to the entire force since 2022. The surface transmission radar mounted on the mine detector II can detect non-metallic mines and reduce the false alarm rate because it can check the detected mines through an image. On the other hand, due to cost and temporal problems, there is a limit to obtaining high-resolution GPR(Ground Penetrating Radar) images, reducing the detection and classification accuracy. Therefore, this study combined super-resolution techniques with a CNN(Convolutional Neural Network) model, which are techniques for acquiring high-resolution images from low-resolution images. Based on the surface transmission radar image data of mine detector-II, the classification accuracy of the super-resolution model improved by approximately 3-6% by learning the  $\times 2$  and  $\times 4$  high-resolution images through super-resolution. Future research will be conducted to reduce time through simpler and lighter algorithms.

**Keywords** : Mine Classification, Ground Penetrating Radar, Deep Learning, CNN, Super-Resolution

\*Corresponding Author : Jungmok Ma(Korea National Defense Univ.)

email: jxm@gmail.co.kr

Received December 27, 2022

Accepted March 3, 2023

Revised January 16, 2023

Published March 31, 2023

## 1. 서론

한국전쟁 이후 70여년이 지났지만 우리나라의 지뢰 매설량은 최소 82만여개에 달하며 지뢰 및 불발탄에 의하여 사망하거나 치명적인 부상을 입는 사고가 매년 발생하고 있다[1]. 국내 지뢰지대에 설치된 지뢰의 종류는 아래의 Table 1과 같이 M14, M16, M15, M19, 목함지뢰와 수지반보병지뢰가 있다. 그중에서도 중량이 가볍고 플라스틱으로 만들어져 탐지가 어려운 M14 발목지뢰와 외관상 식별이 어려운 목함지뢰는 국민의 안전과 생명에 큰 위협이 되고 있다. 이러한 지뢰의 위험 요소로 인해 지뢰 제거의 필요성이 제기되어, 2022년부터 새롭게 개발된 지뢰탐지기-II(PRS-20k)가 전 군에 보급되고 있다. 지뢰탐지기-II는 금속탐지기뿐만 아니라 지표투과레이다(GPR: Ground Penetrating Radar, 이하 GPR)를 운용하여 금속뿐만 아니라 비금속 지뢰까지도 식별이 가능하며 영상으로도 확인이 가능한 장비이다.

Table 1. Types of Landmines Installed in Korea[1]

Name	Weight	Size	Picture
M14	100g (plastic)	Diameter : 56mm Height : 40mm	
M16	4kg (metal)	Diameter : 103mm Height : 110mm	
M15	13.6kg (metal)	Diameter : 320mm Height : 110mm	
M19	12.56kg (plastic)	Diameter : 332mm Height : 94mm	
PMD-57	400g (wood)	Length : 190mm Width: 90mm Height : 94mm	
PMN	550g (plastic)	Diameter : 112mm Height : 56mm	

최근에는 GPR 신호에 영상처리 분야에 많이 활용되고 있는 딥러닝을 접목한 연구사례가 증가하여 매설된 물체를 인식하고 분류하는 연구가 진행되고 있다[2]. 그러나 GPR 영상의 경우 비용과 시간적인 문제로 인해 고해상도의 이미지를 얻는 데 어려움이 있기 때문에 객체

를 정확하게 탐지하고 분류하는 데도 한계가 있다. 이를 극복하기 위해 저해상도 영상에서 고해상도의 영상을 획득하는 기술인 초해상화(SR: Super-Resolution) 기법을 적용하려는 연구가 이루어지고 있다. 예를 들어 류제민[2]은 SAR 영상에서 군사용 SAR 자동표적인식 모델에 대해 연구하였고 두 배로 초해상화하였을 때 가장 좋은 성능을 얻었다. 그러나 지금까지 실제 지뢰의 GPR 영상을 초해상화하여 적용한 연구는 없었다. 따라서 본 연구에서는 실제 지뢰의 GPR 영상을 초해상화하여 지뢰를 분류하는 데 배율에 따른 성능 효과를 확인하고자 한다.

본 연구는 2장에서 GPR 데이터를 활용한 이미지 식별 및 분류 모형과 GPR 이미지에 초해상화를 적용한 관련연구에 대해 확인하고, 이론적 배경에 대해 설명하며 3장에서는 여러 가지 초해상화 기법 중에서도 잔여 밀집 네트워크(RDN: Residual Dense Block, 이하 RDN) 방식을 사용한 지뢰 식별 네트워크를 제시하고 실험 및 평가하였다. 4장에서는 연구 결론 및 제한사항과 후속 연구방안에 대해 제시하였다.

## 2. 이론적 배경

### 2.1 관련 연구

국내·외에서 지하공동이나 배관, 지뢰의 지표투과레이다 영상을 초해상화를 통해 탐지하고 분류하기 위한 연구가 발표되었다. 이현기[3]는 딥러닝을 사용하여 다양한 토양에서 실제 지뢰의 GPR 영상으로 지뢰가 있는 부분과 없는 부분을 구별하는 연구를 하였다. Kang et al.[4]은 초해상화를 통한 분류를 위해 Alexnet 모델을 바탕으로 UcNet이라는 알고리즘을 제안한다. 이 알고리즘을 통해 GPR 영상을 고해상화 시킨 뒤 지하의 공동, 맨홀, 지층 등을 구별하였다. 강만성[5]은 3D GPR 영상의 이미지 해상도를 증가시키기 위해 주파수-파수 분석 기법을 이용하였고 실제 GPR 이미지를 이용하여 신호대잡음 분석 결과 29dB에서 50dB으로 75% 개선된 이미지를 얻을 수 있었다. Zhao et al.[6]는 다중 신호 분류 알고리즘을 사용하여 3D GPR 영상의 해상도를 증가시켜 얇은 아스팔트의 두께를 정확하게 측정하고자 하였다.

많은 연구들이 GPR 데이터를 초해상화하여 더 정확하게 분류하고 분석하기 위해 노력하였다. 그러나 실제 지뢰의 GPR 영상을 초해상화하여 분류하고자 하는 연구는 없었다. 본 연구와 관련 연구들의 차이점을 정리하여 비교하면 위의 Table 2과 같다.

Table 2. Related research

	Objective	Method	Data
Lee[3]	Mine detection	Convolutional Neural Network	Real data (Mine)
Kang et al.[4]	Underground Cavity Classification	Convolutional Neural Network, Super resolution	Real data (Cavity)
Kang[5]	Underground object Estimation	Convolutional Neural Network, Super resolution	Real data (Cavity)
Zhao et al.[6]	Asphalt Thickness Estimation	Multiple signal Classification Algorithm	Real data (Asphalt)
This paper	Mine Classification	Convolutional Neural Network, Super resolution	Real data (Mine)

## 2.2 GPR

최근 GPR은 빠른 스캔 속도와 비파괴 검사 및 3D 영상기능 덕분에 지하탐사 용도로 널리 사용되고 있다. GPR은 안테나 송신기를 통해 전자기파를 송신하고, 반사되는 전파를 안테나 수신기로 수신하여 지하영상을 단면화한다. 진행 방향 도중에 한 지점에서 획득한 전파 신호를 A-scan이라고 하며, 진행하면서 축적된 A-scan 데이터들을 누적하여 만든 2차원 신호를 B-scan이라고 말한다[7].




Fig. 1. Example of parabolic shape of a target[7]

진행방향으로 움직이는 안테나의 위치에 따라 송신된 표적에 반사된 신호가 도달하는 시간이 다르기 때문에 위의 Fig. 1와 같이 표적의 위치에서 포물선 모양이 그려지게 된다. 포물선의 크기는 실제 지뢰의 크기에 비례한다. 그러나 매질의 상태나 종류에 따라 포물선 형태의 모양이나 선명도가 제대로 나오지 않거나, 포물선 형태가 보이지 않는 지점도 발생할 수 있어 육안 식별이 쉽지 않다.

## 2.3 CNN(Convolutional Neural Network)

CNN은 합성곱층, 풀링층, 드랍아웃 계층, 완전 연결층 등의 계층들을 여러 번 축적하여 구성된 구조이다. 대부분의 모델들이 여러 합성곱 계층을 거치고 나온 특성맵(feature map)들을 다시 합성곱 계층을 거치도록 하거나 풀링층을 통과하도록 깊게 구성되어 있고 마지막 최저층에는 완전 연결층을 통과하도록 하여 입력된 이미지나 영상의 종류를 최종적으로 판별하게 된다[8].

합성곱층은 필터에 의해 특징을 추출하고 이를 바탕으로 특성맵들을 만든다. 다수의 특징들을 추출하고 싶다면 가중치 값을 갖는 2차원 필터의 개수를 조정한다. 풀링층은 특성맵의 사이즈를 감소시켜서 연산량을 줄이는데 max-pooling 방식을 통해 연산 과정을 수차례 통과하게 되면 입력한 영상을 대표하는 특징들을 획득할 수 있다. CNN에서 네트워크가 깊고 넓어지게 되면 위의 과정을 여러번 반복하여 거치게 되고 이러한 과정을 통해 점점 축소된 특성맵 내부에 입력한 이미지의 특징이 압축된다. 그러나 이처럼 압축되고 네트워크의 구조가 깊어지다 보면 학습한 영상에 대해서만 과적합되어 학습된 영상 이외의 다른 영상에 대해서는 정확하게 예측할 수 없게 된다. 과적합의 예방을 위해 드랍아웃 계층을 사용한다. 이는 서로 연결되어 있는 뉴런들을 정해진 비율로 인식하지 않도록 하는 방식으로 누적된 모든 특징들을 학습에 반영하지 않도록 한다. 네트워크의 마지막 층인 완전 연결층은 연결된 뉴런들을 통해 추출된 특징값들을 softmax 함수를 사용하여 구분하기 위해 사용된다.

## 2.4 초해상화

초해상화 기법은 초해상화를 위해 입력하는 저해상도 이미지의 수에 따라 두 종류로 구분한다. 첫 번째는 동일한 위치에서 시계열 정보를 활용한 다중 영상 초해상화 기법이고, 두 번째는 단일 영상만을 활용한 단일 영상 초해상화 기법이다. 동일한 위치에 대한 여러 개의 저해상도 이미지를 통해 하나의 고해상도 이미지를 복원하는 다중 영상 초해상화 기법[9]은 영상의 해상도 증가를 위하여 예전부터 활용되었던 방법이다. 하지만 GPR 영상의 경우 탐사 환경의 습도와 매질의 특성에 의해 발생하는 경계면에서 반사 또는 회절이 발생하고 다양한 잡음이 복잡하게 나타나기 때문에 동일한 촬영 조건의 이미지를 획득하기가 어렵다. 반면에 단일 영상 초해상화 방법은 단 한 장의 입력 이미지만을 활용하여 초해상화 영상을 생성한다. 이로 인한 높은 효율과 사용자 편리성에 의하여 단일 영상 초해상화 기법에 대한 관심이 점차 증가

하고 있다. 단일 영상 초해상화 기법은 초해상화 방식에 의해 보간법, 복원 기법 및 훈련 기반으로 나뉜다. 보간법에 토대를 둔 방식은 비교적 빠르게 연산이 가능하지만, 목표 픽셀에 인접해 있는 픽셀의 정보만 사용하기 때문에 출력 이미지가 명확하게 나타나지 않는 현상이 발생하거나, 자연스럽지 않은 구조가 만들어지기도 한다 [10]. 복원 기반의 방식은 이미지 내 존재하는 사전 정보를 통해 출력 이미지의 재현 가능성을 제한하면서, 이미지의 세밀한 부분까지 복원한다. 하지만, 이미지의 해상도가 올라갈수록 연산에 시간이 많이 소모되며 이미지 복원 성능이 감소된다는 단점이 있다[11].

훈련 기반의 단일 영상 초해상화 기법은 최근 딥러닝 기술의 발전으로 CNN을 사용한 연구들이 다수 진행되고 있으며, 준수한 성능과 빠른 연산 속도로 인하여 많은 연구에서 사용되고 있다.

### 3. 초해상화 기반 지뢰 식별 모델

#### 3.1 초해상화 기반 CNN 모델 설계

지뢰 식별을 위해 제안하는 초해상화 기반 CNN 모델의 구조는 다음 페이지의 Fig. 3와 같다. 입력 이미지들은 CNN을 통한 분류 전에 RDN 모델을 통해 초해상화가 이루어 진다. RDN[12]은 그전의 모든 계층의 정보를

활용하여 이미지의 특징 맵을 추출하는데 적합하다. 아래 Fig. 2의 잔여 밀집 블록(Residual Dense Block)을 여러개 축적하는 구조로 구성된 RDN의 구조는 다음 페이지의 Fig. 3의 Step 1에 나타난다. 이 방법은 학습된 다양한 특징 정보를 다시 사용함으로써 정보의 흐름을 유연하게 하여 준수한 성능을 보여준다.

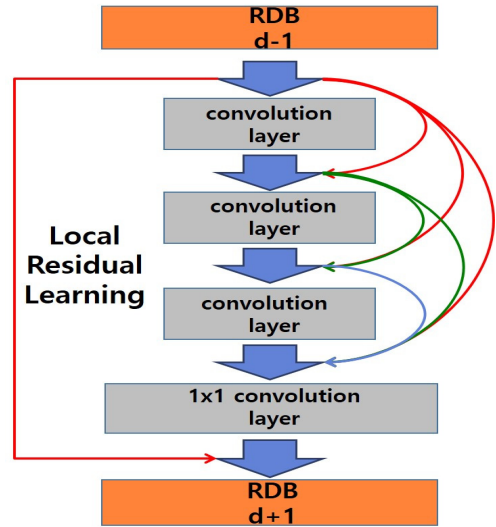


Fig. 2. The architecture of Residual Dense Block[12]

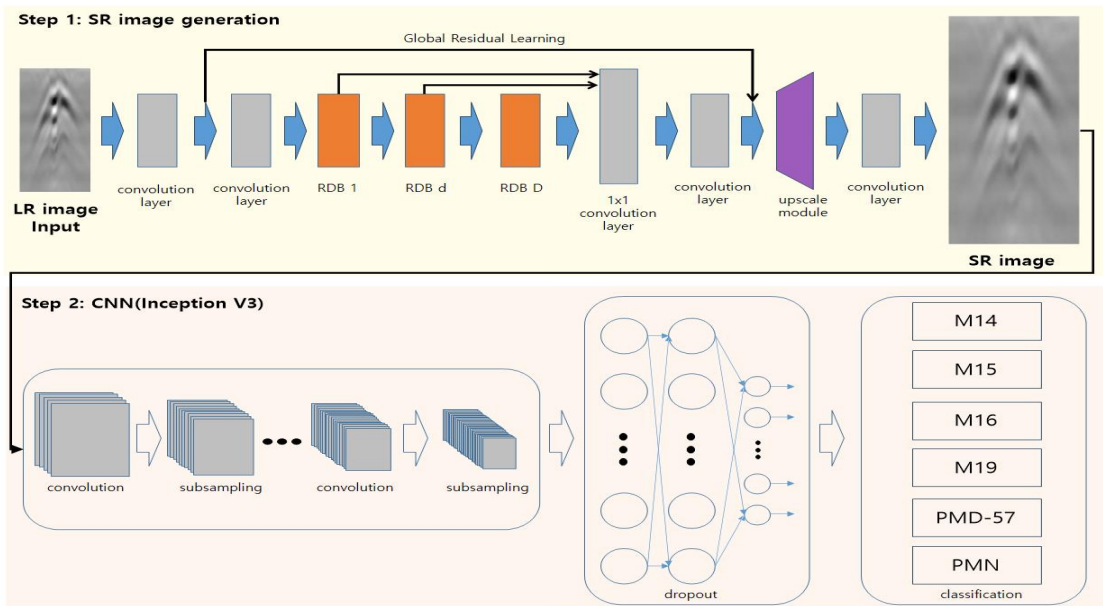


Fig. 3. Overview of mine classification model

지뢰 식별을 위한 모델에서의 초해상화 배수는 2배와 4배를 이용한다. 예를 들어 입력 이미지의 크기가 100×100 픽셀이라면, 초해상화 배수 2배를 통과한 이미지는 200×200 픽셀의 크기로 키우고, 4배를 통과한 이미지는 400×400 픽셀의 크기로 키운다. 이후 GPR 이미지 분류 연구[3]에서 준수한 성능을 보여주었던 Inception V3[13] 모델을 이용하여 지뢰를 종류별로 학습하고 분류한다. Inception V3의 추상적인 구조는 다음 페이지 Fig. 3의 Step 2와 같으며, 42개의 계층으로 구성된다. 이는 합성곱층에서의 필터 크기를 줄이고, 비대칭 합성곱으로 분해하여 연산량과 파라미터의 양을 축소하고 효율적인 연산을 가능하게 만든 모델이다. 모델을 통과한 최종 출력은 대상 지뢰의 개수에 맞춰 6개로 변경하였다.

### 3.2 실험 데이터 및 환경

데이터 세트는 육군교육사령부 AI소요관리과에서 2021년 6월 21일부터 25일까지 공병학교에서 실시한 전투실험을 통해 수집된 M14, M16, 목함지뢰, 수지반 보병지뢰, M15, M19 파형 데이터를 육군 데이터 랩에서 제공받았다. 본 실험에서는 그 중 오경보 물체와 탐지속도가 0.5m/s를 초과하는 데이터를 제외한 318개의 원본 데이터를 사용하였다.




Fig. 4. GPR image pattern

학습에 사용한 데이터는 위의 Fig. 4와 같이 지뢰 6종에 대해 각각 전처리하여 구별하였고 이렇게전처리 작업

을 거친 전체 데이터 3,180개를 80:10:10의 비율로 서로 중복되지 않도록 랜덤하게 훈련, 검증, 평가 데이터로 나누었다. 지뢰 분류를 위한 데이터 구성은 아래의 Table 3과 같다. 모델의 성능 평가에는 정확도(Accuracy)와 원본을 얼마나 유사하게 복원하는지 나타내는 PSNR (Peak Signal Noise Ratio)으로 확인하였다.

본 연구는 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.

Table 3. Data amount configuration for Mine classification

Type	M14	M15	M16	M19	PMD-57	PMN	Total
Train	720	144	144	384	720	432	2,544
Validation	90	18	18	48	90	54	318
Test	90	18	18	48	90	54	318
Total	900	180	180	480	900	540	3,180

### 3.3 실험결과

초해상화 기반 CNN 모델의 분류 정확도 실험 결과는 아래의 Table 4와 같다. 이는 초해상화하지 않은 이미지를 활용한 기본 모델과 GPR 이미지를 2배와 4배 초해상화한 초해상화 기반 CNN 모델로 각각 실험한 결과이다. 실험 결과는 초해상화 기반 CNN 모델 모두 기본 모델보다 정확도가 향상되었다. 특히, 가장 크게 정확도가 향상된 모델은 초해상화를 2배로 적용한 모델이었다.

Table 4. Comparison of related research

	Test accuracy		
	100 epoch	200 epoch	300 epoch
Basic model	79.2	83.5	80.4
Super-resolution based CNN ×2	81.0	<b>86.6</b>	84.3
Super-resolution based CNN ×4	79.8	84.7	82.0

가장 적합한 반복학습 수를 찾기 위해 반복학습 수를 100부터 100씩 증가시키며 실험을 실시하였다. 아래의 Fig. 5는 반복학습을 200번 하였을 때 2배 초해상화 기반 CNN 모델의 정확도 곡선 그래프이다. 0~25회 반복 학습까지 가파르게 정확도 곡선이 상승하고 있으며 손실

함수 또한 감소하는 모습을 보인다. 그러나 100회 반복 학습 이후부터는 정확도, 손실함수 곡선은 각각 원만하게 상승, 감소하는 모습을 보인다.

전체적으로 반복학습의 수가 100일 때보다 200일 때 높은 정확도를 보였으나 300일 때에는 오히려 정확도가 낮아지는 경향을 보였다. 이는 학습시에 동일한 이미지가 지속적으로 누적되어 과적합되기 때문으로 추정할 수 있다. 결과적으로 200번 반복학습을 실시한 2배 초해상화 기반 CNN 모델이 86.6%로 가장 정확도가 높았으며 기본 모델보다 정확도가 약 5.6% 향상되었음을 알 수 있었다. 따라서 초해상화 기반 CNN 모델을 적용한다면 실제 지뢰의 분류 정확도 성능을 향상시킬 수 있음을 확인하였다.




Fig. 5. Accuracy and loss curve of super-resolution based CNN ×2 adapted 200 epochs

반복학습을 200번 실시한 4배 초해상화 기반 CNN 모델은 기본 모델보다 정확도가 약 3.3% 향상되었지만, 2배와 비교하였을 때 정확도가 약 2.3% 낮게 나타났다. 마찬가지로 초해상화의 성능 지표인 PSNR 수치를 비교하면 초해상화 배수 2배에서는 52.63dB이지만 초해상화 배수 4배에서는 43.66dB으로 실험 결과와 동일하게 4배 초해상화 기반 CNN 모델이 더 낮은 수치를 보였다. 이는 초해상화를 적용하면서 초해상화 배수 2배를 적용한 모델에 비하여 원본 이미지의 특징이 더 많이 손실된 결과가 반영된 것으로 보인다. 이러한 실험 결과로 미루어 볼 때 이미지의 픽셀 크기는 초해상화 배수 4배를 통

과한 모델이 크지만, 초해상화의 성능이 낮았기 때문에 2배를 통과한 모델보다 분류의 정확도가 낮은 것을 알 수 있다. 이는 인지적인 측면에서는 만족할만한 이미지를 얻을 수 있지만 텍스처 영역에서 구조적인 왜곡을 일으키는 훈련 기반 초해상화의 단점이다.

#### 4. 결론

본 논문에서는 우리 군에서 실제 운용 예정인 PRS-20k의 GPR 영상에서 지뢰를 식별하기 위한 초해상화 기반 CNN 모델을 제시하고 실험하였다. 실제 지뢰의 GPR 영상 데이터는 군사보안 문제로 민간에서 활용이 어려워 관련된 연구가 진행될 수 없었다. 따라서 본 연구에서는 육군 데이터랩을 통해 획득한 실제 지뢰 데이터를 활용하여 초해상화를 적용한 이미지 분류 모델을 제시한 데 의미가 있다. 초해상화 모델로는 최근 여러 논문에서 좋은 성능을 보여주고 있는 RDN 모델을 활용하였으며 분류 모델로는 GPR 이미지 분류 연구에서 우수한 성능을 보여주었던 Inception v3 모델을 사용하였다. 또한 육군 데이터랩에서 획득한 실제 지뢰 6종에 대한 GPR 이미지 3,180장의 이미지로 모델을 학습하고 검증하였다. 결과적으로 200번 반복학습을 시행한 2배 초해상화 기반 CNN 모델의 정확도가 초해상화 하지않은 기본 모델의 정확도보다 5.6% 향상시킬 수 있었다.

비록 군사보안 상의 이유로 제한적인 양의 데이터로 실험을 실시하였으나 앞으로 실제 야전에서 지뢰탐지기-II를 운용하며 추가적인 데이터를 누적해 나간다면 분류의 정확도는 더욱 높아질 것으로 기대된다. 본 연구에서 학습된 모델을 사용한다면 그동안 인력에 의해 이루어지던 지뢰 탐지 및 구별을 딥러닝을 통해 시스템적으로 가능하게 함으로써 오탐지율을 줄일 수 있을 것이다. 또한 전문 인력이 없더라도 GPR 이미지 데이터만 충분히 확보된다면 지뢰를 탐지하고 구별할 수 있는 효율적인 시스템을 만들어 낼 수 있을 것이다. 그러나 초해상화를 통한 고해상도의 이미지를 학습하고 분류하는 딥러닝 모델은 다수의 파라미터와 높은 연산량으로 실제 모듈에서 알고리즘을 실행하기에는 오랜 시간이 걸린다. 따라서 즉각적인 반응이 필요한 실제 야전에서 운용하기 위해서는 모델 압축 및 최적화를 통해 간결하고 가벼운 알고리즘을 활용한 추가적인 연구가 필요하다.

## References

- [1] Peace Sharing Association, 2019 A Report on the Damage to Landmine Residents in Gyeonggi-do Province, Report, Peace Sharing Association, Republic of Korea, pp.1-205. Available From: <http://psakorea.org/board/index.html?id=report&page=1&no=88>
- [2] J. M. Ryu, J. M. Ma, "Automatic Target Recognition of Military SAR Images Using Super-Resolution based Convolutional Neural Network", *Journal of Institute of Control, Robotics and Systems*, Vol.28, No.1, pp.22-27, Jan. 2022.  
DOI: <https://doi.org/10.5302/I.ICROS.2022.21.0178>
- [3] H. G. Lee, J. M. Ma, "A Study on Mine Detection in GPR Images Using CNN", *Journal of the Korea Academia-Industrial cooperation Society*, Vol.23, No.6, pp.82-88, Jun. 2022.  
DOI: <https://doi.org/10.5762/KAIS.2022.23.6.82>
- [4] M. S. Kang, N. G. Kim, S. B. Im, J. J. Lee, Y. K. An, "3D GPR Image-based UcNet for Enhancing Underground Cavity Detectability", *Remote Sens*, Vol.11, No.21, Oct. 2019.  
DOI: <https://doi.org/10.3390/rs11212545>
- [5] M. S. Kang, Y. K. An, "Frequency-Wavenumber Analysis of Deep Learning-based Super Resolution 3D GPR Images", *Remote Sens*, Vol.12, No.18, Sep. 2020.  
DOI: <https://doi.org/10.3390/rs12183056>
- [6] S. Zhao, I. L. Al-Qadi, "Super-Resolution of 3D GPR Signals to Estimate Thin Asphalt Overlay Thickness Using the XCMP Method", *IEEE Transactions on Geoscience and Remote Sensing*, Vol.57, No.2, pp.893-901, Feb. 2019.  
DOI: <https://doi.org/10.1109/TGRS.2018.2862627>
- [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] 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>
- [9] R. Fernandez-Beltran, P. Latorre-Carmona, F. Pla, "Single-frame super-resolution in remote sensing: a practical overview", *International Journal of Remote Sensing*, Vol.38, No.1, pp.314-354, Dec. 2016.  
DOI: <https://doi.org/10.1080/01431161.2016.1264027>
- [10] R. Keys, "Cubic convolution interpolation for digital image processing", *IEEE Transactions on Acoustics, Speech, and Signal Processing*, Vol.29, No.6, pp. 1153-1160, Dec. 1981.  
DOI: <https://doi.org/10.1109/TASSP.1981.1163711>
- [11] Q. Yan, Y. Xu, X. Yang, T. Q. Nguyen, "Single image super resolution based on gradient profile sharpness", *IEEE Transactions on Image Processing*, Vol.24, No.10, pp.3187-3202, Oct. 2015.  
DOI: <https://doi.org/10.1109/TIP.2015.2414877>
- [12] Y. Zhang, Y. Tian, Y. Kong, B. Zhong, Y. Fu, "Residual dense network for image super-resolution", *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition(CVPR)*, IEEE, UT, USA, pp.2472-2481, June 2018.  
DOI: <https://doi.org/10.48550/arXiv.1802.08797>
- [13] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, Z. Wojna, "Rethinking the Inception Architecture for Computer Vision", *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, IEEE, NV, USA, pp.2818-2826, Dec 2016.  
DOI: <https://doi.org/10.1109/CVPR.2016.308>

## 이 현 기(Hyungi Lee)

[준회원]



- 2013년 2월 : 육군사관학교 무기 시스템 공학과 (무기 시스템 공학 학사)
- 2023년 1월 : 국방대학교 국방과학학과 (국방과학학과 석사)

〈관심분야〉

인공지능, 무기체계 획득, 시스템 엔지니어링

## 마 정 목(Jungmok 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