

CNN 기반의 준지도학습을 활용한 GPR 이미지 분류*

A Study on GPR Image Classification by Semi-supervised Learning with CNN

김혜미 · 배혜림[†]

부산대학교 산업공학과 산업데이터공학융합전공

요약

GPR(Ground Penetrating Radar)에서 수집된 데이터는 지하 탐사를 위해 사용된다. 이 때, 지반 아래의 시설물들이 GPR을 반사하는 경우가 종종 발생하여 수집된 데이터는 전문가에 경험에 의존하여 해석된다. 또한, GPR 데이터는 수집 장비, 환경 등에 따라 데이터의 노이즈, 특성 등이 다르게 나타난다. 이로 인해 정확한 레이블을 가지는 데이터가 충분히 확보되지 못하는 경우가 많다. 일반적으로 이미지 분류 문제에서 높은 성능을 보이는 인공신경망 모델을 적용하기 위해서는 많은 양의 학습 데이터가 확보되어야 한다. 그러나 GPR 데이터의 특성 상 데이터에 정확한 레이블을 붙이는 것은 많은 비용을 필요로 하여 충분한 데이터를 확보하기가 어렵다. 이는 결국 일반적으로 활용되는 지도학습 방법을 기반으로 인공신경망을 적절히 학습시킬 수 없게 한다.

본 논문에서는 각 레이블의 정확도가 유사한 수준을 갖도록 하는 것을 목표로 데이터 특성을 바탕으로 하는 이미지 분류 방법을 제안한다. 제안 방법은 준지도학습을 기반으로 하고 있으며, 인공신경망으로부터 이미지의 특징값을 추출한 후 클러스터링 기법을 활용하여 이미지를 분류한다. 이 방법은 라벨링 된 데이터가 충분하지 않은 경우 라벨링할 때 뿐 만 아니라 데이터에 달린 레이블의 신뢰도가 높지 않은 경우에도 활용할 수 있다.

■ 중심어 : GPR, 이미지 분류, CNN, 준지도학습, 이미지 클러스터링

Abstract

GPR data is used for underground exploration. The data gathered are interpreted by experts based on experience as the underground facilities often reflect GPR. In addition, GPR data are different in the noise and characteristics of the data depending on the equipment, environment, etc. This often results in insufficient data with accurate labels. Generally, a large amount of training data have to be obtained to apply CNN models that exhibit high performance in image classification problems. However, due to the characteristics of GPR data, it makes difficult to obtain sufficient data. Finally, this makes neural networks unable to learn based on general supervised learning methods.

This paper proposes an image classification method considering data characteristics to ensure that the accuracy of each label is similar. The proposed method is based on semi-supervised learning, and the image is classified using clustering techniques after extracting the feature values of the image from the neural network. This method can be utilized not only when the amount of the labeled data is insufficient, but also when labels that depend on the data are not highly reliable.

■ Keyword : GPR, Image classification, CNN, Semi-supervised learning, Image clustering

2021년 07월 23일 접수; 2021년 08월 18일 수정본 접수; 2021년 08월 23일 게재 확정.

* 이 논문은 2020년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (No. 2020R1A2C110229411).

[†] 교신저자 (hrbae@pusan.ac.kr)

I. 서론

GPR(Ground Penetrating Radar)은 지반 아래의 상태 및 시설을 확인할 수 있는 비파괴검사 장치이다. 일반적으로 건설현장에서 가스관, 상수관, 하수관 등 지하매설물을 파악할 때 뿐만 아니라 싱크홀을 찾을 때 역시 사용된다. GPR에서 수집되는 데이터는 A-scan, B-scan, C-scan이 있으며, 본 연구에서 활용한 데이터는 이미지로 변환된 B-scan 데이터이다.

수집된 GPR 데이터는 설비의 사양과 데이터 수집 환경에 따라 노이즈 등 데이터의 상태가 크게 차이 난다.[1] 본 연구에서 고려한 데이터는 데이터 수집 구간에 따라 노이즈의 포함 수준이 다르다. 또한, 해당 설비에서 수집된 데이터 중 레이블이 붙은 이미지의 수는 인공신경망을 학습하기에 현저히 부족한 양이다. 때문에 기존 CNN(Convolution Neural Network) 기반의 모델은 이 이미지를 정확하게 분류하지 못할 뿐만 아니라[2], 모든 레이블에 대해 균일한 정확도를 보이지 못한다.

본 연구는 각 레이블의 정확도 간 편차를 줄이는데 초점을 두고 수행되었다. 즉, 이미지 분류의 전체 정확도보다는 주어진 다수의 레이블 각각의 정확도가 비슷하게 학습할 수 있는 방법론을 제안한다.

본 논문의 순서는 다음과 같다. 2장에서 GPR 데이터 중 B-scan 데이터의 분류 모델에 대한 기존 연구에 대해 살펴보고, 3장에서는 제안 방법론에 활용된 개념들을 소개한다. 4장에서는 제안 방법론을 구체적으로 설명하고, 5장에서 제안 방법론을 활용하여 GPR 이미지를 분류하고, 인공신경망 기반의 이미지 분류 모델인 ResNet과 성능을 비교하고, 6장에서는 실험 결과를 바탕으로 제안 방법론의 활용 기대효과를 서술한다.

II. 관련 연구

GPR을 사용하는 환경의 특성 상 수집된 데이터는 전문가의 경험에 크게 의존하여, 분석 수준이 달라진다. [1] 전문가의 경험 수준에 의존하지 않고 자동으로 빠르게 GPR을 분석하기 위해 알고리즘을 통한 분류 방법이 현재까지도 계속 연구되고 있다.

수행된 대부분의 연구는 기계학습을 바탕으로 GPR 이미지를 분류하는 방법론을 연구하였다. 기계학습이 적용된 초기에는 SVM(Support Vector Machine)을 중심으로 연구가 진행되었다.[3, 4, 5, 6] 이후 인공신경망을 활용한 방법론이 주로 연구되었으며[7], 특히 최근에는 CNN[8, 9, 10, 11, 12]을 중심으로 많은 연구가 이루어지고 있다.

인공신경망은 GPR 이미지 분류를 위해 2006년에도 활용되었으며, 이 때 활용된 인공신경망은 단순히 입력레이어, 히든레이어, 출력레이어 각각 1개씩으로 구성된 인공신경망이 활용되었다.[13] 이미지로 구성된 데이터를 처리하기 위해 이후 주로 사용되는 신경망은 CNN 기반의 더 깊은 모델들이다. 2017년에 수행된 연구는 특정한 형태를 가지고 있는지 여부를 분류하는 모델을 학습하고, 이를 활용한 객체 탐지 시스템을 제안하였다.[8] 또 다른 연구로는 CNN 모델의 성능을 높이기 위해 Fashion-MNIST 데이터 셋으로 사전 학습된 모델을 전이하여 모델 학습에 활용한 연구가 수행되었다.[9]

III. 배경

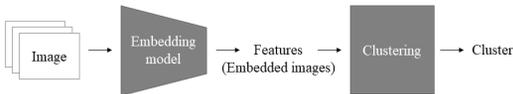
본 논문에서 제안된 방법론은 이미지 클러스터링을 활용한 준지도학습(Semi-supervised Learning)을 기반으로 한다. 분류 모델은 CNN 기반의 인공신경망을 활용하였으며, Attention을 포함하고 있는 구조이다. 이 때, 인공신경망이

적절한 방향으로 학습될 수 있도록 모델 초기화를 수행하며, 제안 모델이 초기화 값을 활용할 수 있도록 전이학습(Transfer Learning)을 수행한다.

3.1 준지도학습

이미지 분류 문제를 위한 지도학습은 많은 양의 라벨링된 이미지 데이터가 확보되어야 제대로 수행될 수 있다. 하지만, 실제로 라벨링된 이미지 데이터를 충분히 확보하는 것은 많은 비용을 요구하며, 이와 같은 환경에서 합리적인 비용으로 학습을 수행하는 방법들이 다양하게 연구되어 왔다. 그 중에서도 적은 양의 라벨링된 데이터와 많은 양의 라벨링 되지 않은 데이터로 구성된 데이터 셋에서 수행되는 학습 방법을 준지도학습이라 한다.[14]

3.2 이미지 클러스터링[15]



<그림 1> 이미지 클러스터링 과정

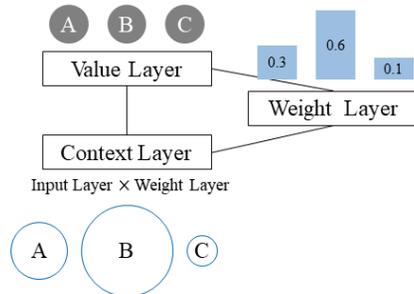
클러스터링은 유사한 특징을 갖는 데이터 셋을 그룹화하는 방법이다. 이미지 클러스터링은 사람의 입장에서 보면 어려운 문제가 아니지만, 기계의 입장에서는 단순히 이미지만을 활용하여 수행되어야한다. 때문에 이미지 클러스터링은 지도학습 기반의 이미지 분류 문제보다 어려운 문제로 알려져 있다.

이미지 클러스터링은 두 단계를 거쳐 수행된다. 먼저 모델만을 활용하여 이미지에서 적절한 특징을 추출한다.[16] 추출된 특징은 이미지를 보다 낮은 차원으로 줄이며, 일종의 주성분분석(PCA, Principle Component Analysis)이 수행되는 것으로 볼 수 있다. 다음으로 추출된 특징을

활용하여 클러스터링을 수행한다. 이 문제의 핵심은 어떻게 이미지로부터 주요한 특징을 뽑아내는 모델을 구현할 것인지와 다수의 변수로부터 정확하게 클러스터링을 수행하는 방법을 찾는 것이다.

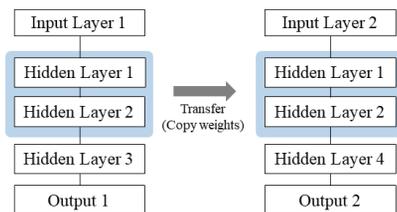
3.3 Attention[17]

여러 개의 변수가 있을 때, 각 변수 값의 조합에 따라 모델에 미치는 영향력이 다른 경우가 있다. Attention은 여러 개의 값 중 각각의 값이 갖는 중요도이다. 인공신경망에서는 간단히 그림 2와 같은 구조에서 Attention을 학습할 수 있으며, 이 때 attention을 의미하는 레이어는 가중치 레이어(Weight Layer)다. 밸류 레이어(Value Layer)로부터 입력된 값을 활용하여 각 값에 대한 Attention을 얻고, 밸류 레이어 값에 Attention을 곱하여 가중치가 반영된 밸류 레이어인 컨텍스트 레이어(Context Layer)를 얻게 한다.



<그림 2> Attention 레이어의 개념[18]

3.4 전이학습



<그림 3> 인공신경망의 전이학습

전이학습은 어떤 도메인에서 학습되었던 모델을 유사한 도메인의 새로운 모델에 전이하는 학습 방법이다. [19] 이 방법은 기존에 학습된 모델을 활용하여 적은 데이터를 활용하여 새로운 모델을 학습시킨다.[20] 이는 기존 학습된 모델의 가중치를 새로운 모델로 이전하여 활용한다. 이와 같은 학습 방법은 학습 시간이 부족할 때, 데이터가 부족할 때 유용한 방법이다.

CNN 기반의 이미지 분류 모델은 크게 특징 추출기와 분류기로 구분된다.[21] 전이학습은 상황에 맞추어 특징 추출기를 구성하는 레이어 중 어떤 레이어를 학습할 것인지 결정해야 된다. 이 전략은 학습을 수행하는 장비의 연산능력과 학습에 활용할 수 있는 데이터의 양에 따라 결정된다. 분류기는 항상 학습이 수행된다. 하지만 특징 추출기는 데이터의 양과 장비의 연산능력이 충분할 때 더 많은 레이어를 업데이트하고, 연산능력과 데이터의 양이 부족할수록 더 적은 레이어를 학습한다.

IV. 방법론

논문에서 제안한 방법은 크게 두 단계로 수행된다. 첫 번째 단계는 사용할 모델의 가중치를 적당히 사전에 학습시키는 초기화(Initialization) 단계이다. 다음으로 모델의 출력부 구조를 수정하고 클러스터링 기법을 적용하여, 분류가 잘 되도록 모델을 학습시키는 메인

모델 학습 단계가 진행된다.

그림4에서 (a)는 초기화 모델, (b)는 메인 모델의 구조이다. 각 모델은 인공신경망으로 구성되어 있으며, 초기화 모델에서 학습된 입력 레이어와 히든 레이어는 메인모델로 전이된다. 이 때, 전이된 레이어는 동결(Freeze)되어, 메인 모델 학습 시 전이된 레이어의 가중치는 학습되지 않는다.

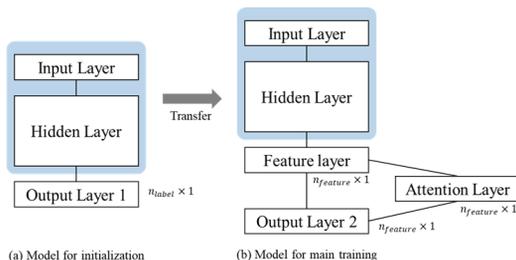
4.1 초기화 모델 학습

초기화를 위해 사용되는 데이터는 정확한 레이블이 붙여진 소량의 데이터이다. 분석에 활용되는 모델은 일반적으로 지도학습인 CNN 기반의 이미지 분류 모델에서 활용되는 모델과 동일한 구조이다. 이 때 모델의 입력 레이어는 입력 이미지와 같은 차원을 갖고, 출력 레이어는 레이블의 개수 n_{label} 로 구성된 벡터와 같은 차원을 갖는다. 이 연구에서는 단순하게 구성된 CNN 모델을 활용하였으나, CNN 기반의 다른 인공신경망 모델로 교체할 수 있다.

CNN은 이미지를 X 로, 원-핫 인코딩(One-hot encoding)된 값을 Y 로 두고 학습을 진행한다. 모델에 X 가 입력되었을 때 \hat{Y} 가 출력되는데, 이는 각 레이블을 답으로 가질 확률값이 나타나게 된다. 출력된 값 \hat{Y} 과 실제값 Y 간의 오차인 $loss$ 를 계산하고, 이 값을 최소화하는 방향으로 CNN의 가중치를 학습한다. 이 과정은 일반적인 지도학습과 동일하다.[22]

4.2 메인 모델 학습

메인 모델 학습 단계에서는 초기화 학습과 동일하게 라벨링된 학습 데이터가 활용된다. 초기화 학습 단계와 차이는 레이블이 특징값의 형태로 변환되어 활용된다는 점이다. 메인 모델은 초기화 단계에서 학습된 모델의 입력 레이어부터 히든 레이어까지 전이되며, 앞서 학습된 모



〈그림 4〉 제안 방법론에서 활용된 인공신경망 구조

텔과 차이점은 출력부이다. 메인 모델의 출력부의 모든 레이어의 사이즈는 특징값의 수 $n_{features}$ 와 같으며, Attention 레이어를 포함한다. Attention 레이어는 히든 레이어에서 출력된 값으로 만들어진 $n_{features}$ 개의 특징값(Feature)에 중요도를 반영한다. 이 때 중요도가 반영된 특징값은 출력 레이어에 나타나며, 출력값의 조합이 분류를 위한 임시 레이블에 잘 도달할 수 있도록 돕는다.

Algorithm 1 Main model training algorithm

Input: labeled training data set of GPR image x , data x 's label set y
 $ft \leftarrow mainModel(x)$ # Get data x 's feature value set
 $C_{train} \leftarrow average(ft|y = i)$ # Calculate centroids of each labels
Fit MinMaxScaler by ft
 $C_{train} \leftarrow MinMaxScaler(C_{train})$ # Scaling the centroids
 $mainModel \leftarrow mainModel.fit(x, C_{train})$
 # Train the model by training data and new label as centroids
Output: trained *mainModel*

<그림 5> 메인 모델 학습 알고리즘

메인 모델이 학습되는 과정은 그림5와 같다. 라벨링 된 학습 데이터 x 를 메인 모델에 입력하여 특징값 ft 를 얻는다. x 로부터 얻어진 ft 를 각각의 레이블 y 별로 계산하여 중심값 C_{train} 을 산출한다. 산출된 C_{train} 간의 간격을 충분히 확보하기 위해 ft 를 0부터 1사이 값으로 변환하는 정규화함수 *MinMaxScaler*를 학습하고, 학습된 정규화함수에 C_{train} 를 입력하여 정규화된 C_{train} 를 얻는다. 마지막으로 학습 데이터 x 를 입력값으로 정규화된 C_{train} 를 출력값으로 두고 메인모델을 학습시킨다.

4.3 GPR 이미지 분류

이미지 분류 과정에서는 K-means[23] 클러스터링이 추가적으로 활용된다. K-means 클러스터링은 복잡도가 낮아 수치형 데이터를 간단하

고 빠르게 분석할 수 있어 본 연구에서 활용되었다. 이 때, K-means 클러스터링은 다변량의 수치형 데이터를 다룰 수 있는 다른 클러스터링 방법으로 대체될 수 있다. 이 과정의 구체적인 흐름은 그림6과 같다.

Algorithm 2 Algorithm of classification by unlabeled data

Input: labeled training data set of GPR image x , data x 's label set y , unlabeled training data set of GPR image x' , classification target image set *IMG*, the number of cluster for k-means clustering n
 $ft' \leftarrow mainModel(x')$ # Get data x' 's feature value set
 $y' \leftarrow Kmeans(n|ft')$ # Set arbitrary label y' from cluster of k-means clustering by ft'
 $C'_{train} \leftarrow average(ft'|y' = i)$
 #Calculate centroids of each arbitrary label
 $ft \leftarrow mainModel(x)$ # Get data x 's feature value set
 $y_{arb} \leftarrow argmin_{C'_{train}} ((ft - C'_{train})^2)$
 # Get arbitrary label of data x
 $L(y) \leftarrow argmax_y (the\ number\ of\ y|y' = i)$
 # Match the clusters with class

 $ft_{IMG} \leftarrow mainModel(IMG)$
 # Get data *IMG*'s feature value set
 $y_{IMG} \leftarrow argmin_{C'_{train}} ((ft_{IMG} - C'_{train})^2)$
 # Get arbitrary label of data *IMG*
 $L_{IMG} \leftarrow L(y_{IMG})$ # Convert clustering results to class
Output: images *IMG*'s class L_{IMG}

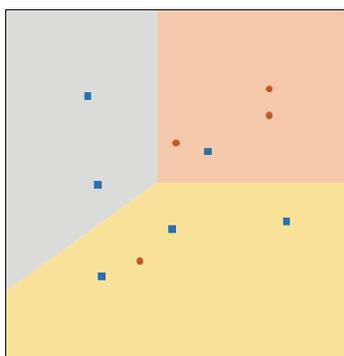
<그림 6> 라벨링되지 않은 데이터를 활용한 이미지 분류 알고리즘

먼저, 레이블 여부와 관계없이 학습 데이터를 활용하여 분류의 기반을 마련한다. 라벨링되지 않은 데이터 x' 를 메인 모델에 입력하여 특징값 ft' 를 얻는다. K-means 클러스터링으로 ft' 를 n 개의 클러스터로 분류하고, 이를 y' 로 두며 K-means 클러스터링 결과의 중심값을 C'_{train} 으로 정의한다. 다음으로 라벨링 된 데이터 x 를 메인 모델에 입력하여 특징값 ft 를 얻는다. C'_{train} 을 기준으로 ft 가 포함되는 클러스터를 찾으며, 이 결과를 y_{arb} 에 저장한다. 마지막으로 클러스터를 이미지에 주어진 레이블에 매칭한다. 매칭되는 레이블은 각 클러스터 내 가장 많은 비중을 차지하는 레이블로 결정된다.

앞의 과정을 통해 분류에 필요한 모델이 결정되었다면, 새로운 이미지(*IMG*)를 분류하는 과

정은 다음과 같다. 먼저 IMG 를 메인 모델에 입력하여 특징값 ft_{IMG} 를 얻는다. 다음으로 추출된 ft_{IMG} 이 포함되는 클러스터를 찾아 y_{IMG} 로 두고 y_{IMG} 를 레이블로 변환하여, IMG 가 레이블로 분류되도록 한다.

클러스터가 레이블에 매칭되는 과정의 예시는 그림7과 같다. 각 점의 위치는 특징값으로 결정된다. 두 종류의 점은 레이블이며, 이들은 3개의 클러스터로 나뉘었다. 왼쪽 상단의 클러스터는 사각형 레이블로 결정되며, 오른쪽 상단의 클러스터는 원 레이블이 75%를 차지하므로, 원 레이블로 본다. 하단의 클러스터는 사각형 레이블이 75%를 차지하므로 사각형 레이블로 매칭된다.



〈그림 7〉 특징값 클러스터링 결과의 레이블 매칭 예

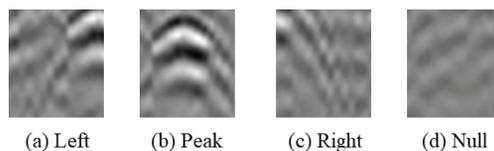
V. 실험

4장에서 설명된 방법론을 활용하여 GPR 데이터를 분류하였다. 해당 장은 주어진 데이터와 모델의 기초적인 설정에 대해 설명한다. 이후 구현된 모델을 구체적으로 제시하며, 기존 방법론과 비교를 진행한다.

5.1 데이터 및 모델 설정

본 논문에서는 GPR 데이터를 이상치와 정상

으로 분류하는 것을 목표로 한다. 이상치는 상승(Left), 꼭짓점(Peak), 하강(Right)으로 구분된다. 정상은 이상치로 분류할 수 없는 이미지를 의미하며, 기타(Null)로 표현된다. 각 레이블 별 이미지 예시는 그림8과 같다. 상승으로 분류되는 경우는 왼쪽에서 오른쪽으로 갈수록 위로 올라가는 형태를 띤다. 꼭짓점은 상승하다가 하강하는 형태를 갖는 경우이다. 하강은 왼쪽에서 오른쪽으로 갈 때 아래로 내려가는 꼴이다. 기타는 상승, 꼭짓점, 하강으로 분류할 수 없는 형태를 경우이다. 이 때, 이미지 데이터의 사이즈는 $20 \times 20 \times 3$ 으로, 가로와 세로 각각 20픽셀이며, 3개의 채널로 구성된다.



〈그림 8〉 활용 GPR 이미지 및 레이블 예시

학습에 활용되는 데이터는 크게 라벨링된 학습 데이터, 라벨링되지 않은 학습 데이터, 검증 데이터로 나뉜다. 라벨링된 학습 데이터는 총 408장으로 상승 90장, 꼭짓점 81장, 하강 111장, 기타 126장의 이미지로 구성되어 있으며, 라벨링되지 않은 학습 데이터는 840장이다. 이 때, CNN, ResNet과 같이 전통적인 지도학습을 기반으로 학습되는 모델은 라벨링된 학습 데이터만 학습에 사용할 수 있다. 검증 데이터는 총 194장으로 상승 49장, 꼭짓점 41장, 하강 42장, 기타 62장으로 구성되며, 이 데이터 셋은 모델의 성능을 검증하기 위해 활용된다.

5.2 제안 방법론 설정

본 논문에서 제안하는 분류 방법론은 인공지능 경망과 K-means 클러스터링으로 구성된다. 이

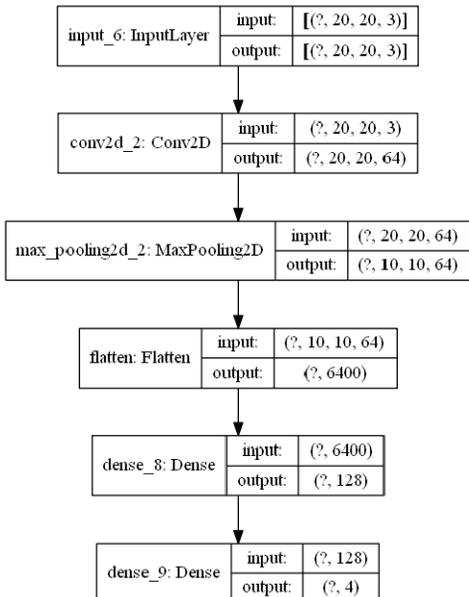
때, 인공신경망은 4개의 히든 레이어로 구성된 CNN을 활용하였다.

인공신경망 중 메인 모델의 손실 함수는 평균 제곱오차(MSE, Mean Squared Error)로 설정하였으며, 출력부의 활성화 함수로 Relu가 활용되었다.

인공신경망을 학습하기 위해 활용된 최적화 함수는 Adam이다. 초기화 모델과 메인 모델 모두 학습률(Learning rate)을 0.001로 설정하였다. 이 때, 모델들이 과적합(Overfitting)되지 않도록 조기종료(Early Stopping)를 도입하여 목적함수인 손실값의 변화가 미비하면 학습이 종료되도록 하였다.

5.3 실험 결과

제안 분류 방법론으로 GPR 이미지를 상층, 꼭지점, 하강, 기타 4가지 레이블로 분류하는 실험을 진행하였다. 제안 방법론은 단순하게 구성된 simple CNN, 보다 깊은 형태로 구성된 신경망 구조인 ResNet50, ResNet101, ResNet152와

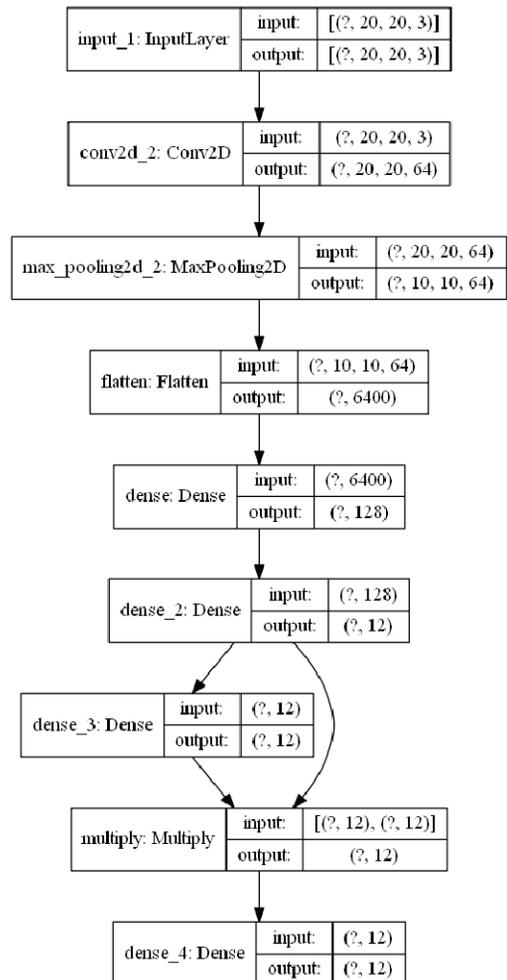


<그림 9> simple CNN의 구조

비교하였다. 특히, simple CNN은 제안 방법론의 초기화 모델로 활용되었으며, Keras에서 제공 [24]하고 있는 예시 모델과 동일한 구조로 이는 그림9와 같다.

위의 simple CNN로 만들어진 초기화 모델을 전이하여 메인 모델은 그림10과 같이 만들어진 다. 메인 모델은 초기화 모델의 출력부를 특징값의 사이즈로 변환하며 Attention 레이어로 구현된다. 실험에서는 간단히 Attention 가중치를 줄 수 있는 구조로 설계되었다.

먼저, 제안 방법론의 하이퍼 파라미터인 특징값의 수 $n_{features}$ 와 클러스터의 수 $n_{clusters}$ 에 따른



<그림 10> 메인 모델의 구조

실험결과는 다음과 같다. 이 때, $n_{features}$ 은 4, 6, 8, 10, 12 중 하나의 값을 갖고, $n_{clusters}$ 는 4, 8, 12, 16, 20 중 하나의 값을 갖는 상황에 대해 실험이 진행되었다.

방법론 간 비교를 위한 성능지표는 크게 2가지로 구분된다. 첫 번째 성능지표는 실제 이미지에 라벨링된 4개의 레이블 각각에 대한 정확도이다. 이 성능지표는 Accuracy로 표현된다. 두 번째 성능지표는 이상치와 정상에 대한 정확도로 Null Sensitivity로 표현된다. 상승, 꼭짓점, 하강 레이블을 갖는 데이터가 기타로 분류되지 않을 확률을 이상치에 대한 정확도로 본다. 정상에 대한 정확도는 기타로 레이블을 갖는 데이터가 레이블로 분류될 확률이다. 두 번째 성능지표 Null Sensitivity는 최종 분류목표에 대한 지표로, 전체 정확도 뿐 만 아니라 각 레이블에 대한 정확도의 차가 적을수록 높은 성능을 보인다고 판단할 수 있다. 때문에 해당 지표는 각 레이블에 대한 평균 정확도(Avg.)와 정확도 간 차(Diff.)를 확인하였다.

메인 모델은 하이퍼 파라미터인 $n_{features}$, $n_{clusters}$ 에 의해 다른 성능을 보인다. 주어진 데이터에 적합한 모델을 찾기 위해 두 번째 성능지표인 Null Sensitivity 중 평균값을 기준으로 메인 모델 비교를 진행하였으며, 결과는 표1과 같다.

메인 모델은 $n_{features}$ 이 10, $n_{clusters}$ 이 12일 때

〈표 1〉 제안 방법론의 검증 데이터 셋에 대한 정확도: Null Sensitivity(Avg.)

단위: %	$n_{features}$					
	4	6	8	10	12	
$n_{clusters}$	4	73.35	67.80	62.80	69.25	70.90
	8	63.35	62.85	70.85	73.05	73.85
	12	65.30	73.10	69.55	76.50	67.90
	16	75.05	72.45	67.50	76.40	68.55
	20	66.75	71.90	73.35	73.40	68.85

가장 높은 성능을 보인다. 해당 하이퍼 파라미터로 구성된 모델을 기존 방법론과 비교한 결과는 표2와 같다.

〈표 2〉 기존 방법론과의 비교

Method	Acc. (%)	Time (sec)	Null Sensitivity(%)			
			Normal	Outlier	Avg.	Diff.
CNN	68.0	0.02	63.8	84.4	74.10	20.6
ResNet50	49.5	0.08	24.1	90.5	57.30	66.4
ResNet101	62.4	0.09	65.5	77.0	71.25	11.5
ResNet152	56.7	0.12	27.1	97.5	62.30	70.4
Proposed	63.9	0.19	74.2	78.8	76.50	4.6

기존 방법론과 제안 방법론을 비교했을 때, 첫 번째 성능지표인 Accuracy는 단순한 CNN 모델이 가장 높은 값을 갖는다. 그러나 본 연구에서 최종 목표는 이상치를 탐지하는 것으로 두 번째 성능지표인 Null Sensitivity로 모델 성능을 판단하는 것이 적합하다. 비교 결과 각 레이블 별 평균 정확도는 제안 방법론이 가장 높게 나타났다으며, 정확도 간 차 역시 제안 모델이 가장 작게 나타났다. 즉, Null Sensitivity의 측면에서는 제안 방법론이 기존 방법론보다 더 높은 성능을 보인다.

VI. 결 론

본 논문에서는 CNN과 K-means 클러스터링을 결합하여 GPR 이미지 데이터를 분류하는 방법론을 제안하였다. 이 방법론은 레이블이 붙어 있는 데이터의 양이 적고, 이미지 내 관찰되는 노이즈의 형상이 매우 다양하여 같은 레이블을 갖더라도 유사한 특징이 많이 않은 경우를 고려하였다. 제안 방법론은 라벨링 여부와 관계없이 모든 데이터를 활용하여 새로운 레이블을 생성하여, CNN 모델을 학습하고 GPR 이미지를 분류하였다. 이는 모델이 라벨링되지 않은 이미지

에 대한 특성 또한 학습할 수 있게 하여, 라벨링 결과에 대한 신뢰도가 충분하지 않은 경우에도 활용 가능하다.

그러나, 제안 방법론은 초기화를 통해 좁혀진 상황에 대해서만 학습이 진행된다. 때문에 탐색의 범위를 보다 확장할 수 있는 방법을 대입한다면 모델 성능을 향상시킬 수 있을 것이다. 또한, 본 논문에서 진행된 실험은 이미지의 전처리 없이 진행된 것으로 이미지 전처리를 통해 일부 노이즈를 제거하고, 라벨링된 데이터를 생성했을 때 더 높은 성능을 보일 것으로 기대된다.

참 고 문 헌

- [1] B. Park, 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, 2018.
- [2] C. Tan, et al. "A survey on deep transfer learning." *International conference on artificial neural networks*. Springer, Cham, 2018.
- [3] E. Pasolli, M. Farid, and D. Massimo, "Automatic analysis of GPR images: A pattern-recognition approach." *IEEE Transactions on Geoscience and Remote Sensing* Vol.47, No.7, pp.2206-2217, 2009.
- [4] El-Mahallawy, S. Mohamed, and H. Mazlan. "Material classification of underground utilities from GPR images using DCT-based SVM approach." *IEEE Geoscience and Remote Sensing Letters* Vol.10, No.6, pp.1542-1546, 2013.
- [5] E. Pasolli, et al. "Automatic detection and classification of buried objects in GPR images using genetic algorithms and support vector machines." *IGARSS 2008-2008 IEEE International Geoscience and Remote Sensing Symposium*. Vol. 2, 2008.
- [6] R. N. Nagashree, et al. "Detection and classification of ground penetrating radar image using textural features." *2014 International Conference on Advances in Electronics Computers and Communications*. IEEE, 2014.
- [7] Ozkaya, Umut, and Levent Seyfi. "Deep dictionary learning application in GPR B-scan images." *Signal, Image and Video Processing* Vol.12, No.8, pp.1567-1575, 2018.
- [8] Lameri, Silvia, et al. "Landmine detection from GPR data using convolutional neural networks." *2017 25th European Signal Processing Conference (EUSIPCO)*. IEEE, 2017.
- [9] Elsaadouny, Mostafa, J. Barowski, and I. Rolfes. "ConvNet transfer learning for GPR images classification." *2020 German Microwave Conference (GeMiC)*. IEEE, 2020.
- [10] Z. Gong, Zhimin, and H. Zhang. "Research on GPR image recognition based on deep learning." *MATEC Web of Conferences*. Vol. 309. EDP Sciences, 2020.
- [11] H. Harkat, et al. "GPR target detection using a neural network classifier designed by a multi-objective genetic algorithm." *Applied Soft Computing* Vol.79, pp.310-325, 2019.
- [12] U. Ozkaya, et al. "GPR B scan image analysis with deep learning methods." *Measurement* Vol.165, pp.107770, 2020.
- [13] A. Bhuiyan, and B. Nath. "Anti-personnel mine detection and classification using GPR image." *18th International Conference on Pattern Recognition (ICPR'06)*. Vol. 2. IEEE, 2006.
- [14] X. Zhu, and A. B. Goldberg. "Introduction to semi-supervised learning." *Synthesis lectures on artificial intelligence and machine learning* Vol.3,

No.1 pp.1-130, 2009.

- [15] Chang, Jianlong, et al. "Deep adaptive image clustering." Proceedings of the IEEE international conference on computer vision. 2017.
- [16] Coleman, Guy Barrett, and Harry C. Andrews. "Image segmentation by clustering." Proceedings of the IEEE Vol.67, No.5, pp.773-785, 1979.
- [17] Vaswani, Ashish, et al. "Attention is all you need." Advances in neural information processing systems. 2017.
- [18] C. Tian, et al. "Attention-guided CNN for image denoising." Neural Networks Vol.124, pp.117-129, 2020.
- [19] Perkins, N. David, and G. Salomon. "Transfer of learning." International encyclopedia of education 2, pp.6452-6457, 1992.
- [20] F. Zhuang, et al. "A comprehensive survey on transfer learning." Proceedings of the IEEE Vol.109, No.1, pp.43-76, 2020.
- [21] Hussain, Mahbub, Jordan J. Bird, and R. Faria. "A study on cnn transfer learning for image classification." UK Workshop on computational Intelligence. Springer, Cham, 2018.
- [22] I. Goodfellow, Y. Bengio, and A. Courville. Deep learning. MIT press, 2016.
- [23] Hartigan, A. John, A. and W. A. Manchek, "Algorithm AS 136: A k-means clustering algorithm." Journal of the royal statistical society. series c (applied statistics) Vol.28, No.1, pp.100-108, 1979.
- [24] <https://www.tensorflow.org/tutorials/images/classification?hl=ko>

저 자 소 개



김혜미(Hye-Mee Kim)

- 2019년 : 부산대학교 산업공학과 (공학사)
- 2019년~현재 : 부산대학교 산업공학과 (박사과정)
- 관심분야 : 딥러닝, HPO (Hyper Parameter Optimization) 등



배혜림(Hye-Rim Bae)

- 1996년 : 서울대학교 산업공학과 (공학사)
- 1998년 : 서울대학교 산업공학과 (석사)
- 2002년 : 서울대학교 산업공학과 (박사)
- 2004년~현재 : 부산대학교 산업공학과 (교수)
- 관심분야 : 프로세스 마이닝, 빅데이터, BPM (Business Process Mining), 인공지능 등