

# 딥러닝 알고리즘을 이용한 매설 배관 피복 결함의 간접 검사 신호 진단에 관한 연구

조상진\* · 오영진† · 신수용††

## Indirect Inspection Signal Diagnosis of Buried Pipe Coating Flaws Using Deep Learning Algorithm

Sang Jin Cho\*, Young-Jin Oh†, and Soo Young Shin††

(Received 7 November 2023, Revised 20 December 2023, Accepted 21 December 2023)

### ABSTRACT

In this study, a deep learning algorithm was used to diagnose electric potential signals obtained through CIPS and DCVG, used indirect inspection methods to confirm the soundness of buried pipes. The deep learning algorithm consisted of CNN(Convolutional Neural Network) model for diagnosing the electric potential signal and Grad CAM(Gradient-weighted Class Activation Mapping) for showing the flaw prediction point. The CNN model for diagnosing electric potential signals classifies input data as normal/abnormal according to the presence or absence of flaw in the buried pipe, and for abnormal data, Grad CAM generates a heat map that visualizes the flaw prediction part of the buried pipe. The CIPS/DCVG signal and piping layout obtained from the 3D finite element model were used as input data for learning the CNN. The trained CNN classified the normal/abnormal data with 93% accuracy, and the Grad-CAM predicted flaws point with an average error of 2m. As a result, it confirmed that the electric potential signal of buried pipe can be diagnosed using a CNN-based deep learning algorithm.

**Key Words** : Buried Pipe(매설 배관), Close Interval Potential Survey(근간격전위측정법), Direct Current Voltage Gradient(직류전압기울기측정법), Deep learning algorithm(딥러닝 알고리즘), Convolutional Neural Network(합성곱 신경망), Grad-CAM

## 1. 서 론

토중 매설 배관은 음극방식 및 방식전위 모니터링 등의 방법으로 부식을 방지 및 관리하고 있으나, 사용기간의 증가에 따라 매설 배관의 외면 피복 열화 및 손상 등으로 인해 예상하지 못한 배관 부식이 발생할 수 있다. 이에 배관의 건전성을 확보하기 위해

서는 배관의 부식 및 파손 여부를 조기에 진단하는 것이 중요하다.<sup>1</sup>

매설 배관은 설치 특성상 전통적인 접촉 방식의 비파괴 검사(Radiography Testing, Ultrasonic Testing, Magnetic Testing, Penetration Testing)를 적용하기 어려워 굴착을 하지 않고 매설 배관의 건전성에 대해 검사할 수 있는 음극방식의 비굴착 간접검사가 많이 활용되고 있다. 이러한 검사로는 근간격전위측정법(CIPS, Close Interval Potential Survey)과 직류전압기울기측정법(DCVG, Direct Current Voltage Gradient) 등이 있으며 각각의 검사가 개별적으로 진행되어 왔다.<sup>2</sup>

CIPS 검사는 긴 거리의 매설 배관에 대하여 Fig.

† 교신저자, 회원, 한국전력기술 스마트융합연구소

E-mail: yjoh2@kepeco-enc.com

TEL: (054)421-6463, FAX: (054)421-4323

†† 교신저자, 금오공과대학교 IT융복합공학과

E-mail: wdragon@kumoh.ac.kr

TEL: (054)478-7473

\* 한국전력기술 스마트융합연구소

1(a)와 같이 배관의 직상부에서 배관에 대한 관대지 전위 분포 상황을 상세히 측정하여 전기방식 상태 및 추후 전기 방식 설계를 위한 기초정보를 획득하게 된다. Fig. 2와 같이 매설 배관에 결함이 있는 지점에서는 전위 값이 주변부에 비해 높게 측정된다. DCVG 검사는 배관에 공급되는 방식 전류를 주기적으로 ON/OFF하며 Fig. 1(b)와 같이 두 기준 전극을 사용하여 지표면에서 두 지점의 전위 구배를 측정하게 된다. 토중 매설 배관의 피복 결함 위치를 탐측하기 위한 검사방식으로는 DCVG 검사 방식이 많이 이용되며 Fig. 2과 같이 측정된 전위구배가 음(-)에서 양(+로 바뀌는 지점은 매설 배관의 피복 결함부가 있는 지점으로 판단하게 된다.

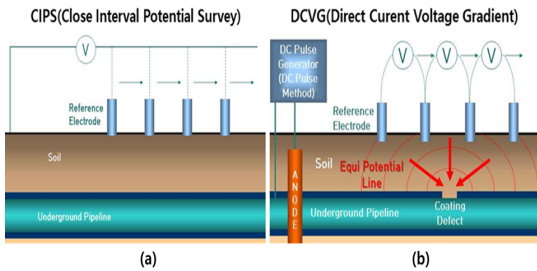


Fig. 1 CIPS(a) & DCVG(b) measurement method

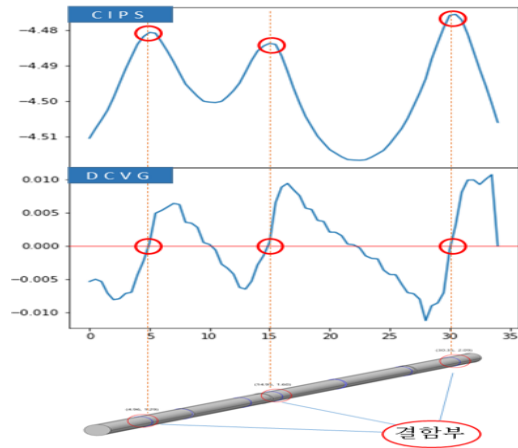


Fig. 2 Examples of CIPS and DCVG signals in buried pipe with coating flaws

토양에 전류를 방식시켜 지전위 신호를 측정하는 CIPS, DCVG 검사는 토중에 단일 배관만 설치되어 있는게 아닌 여러 배관들이 적층 및 교차하여 설치되어 있거나 주변에 금속 구조물들이 많은 설치 조

건에서는 주변부의 영향으로 측정 데이터에 상당한 노이즈가 발생하게 된다. 노이즈가 있는 측정 신호에 대하여 검사원이 매설 배관 피복 결함의 유무를 판별함에 있어 판별의 정확성과 객관성이 낮아지는 한계가 있다.

따라서 이러한 한계를 극복하기 위해 본 연구에서는 측정 신호의 판별을 보다 객관적이고 자동화된 방법으로 개발하기 위하여 딥러닝 알고리즘의 하나인 CNN(Convolutional Neural Network, 합성곱신경망)을 이용하였다. 또한 현행의 CIPS와 DCVG의 탐상 신호를 개별로 판독하는 방식에서 피복 결함부 판별 정확도를 높이기 위하여 CIPS, DCVG\_x(배관 수평 방향), DCVG\_Y(배관 수직 방향) 3개의 신호를 동시에 고려하였다. 3개의 탐상 신호를 통합적으로 분석/판별하기 위해 CIPS/DCVG 신호를 하나의 3차원의 데이터로 통합하였고, 매설 배관의 위치 정보를 함께 학습시키기 위해 매설 배관의 배치(Piping Layout) 정보를 함께 CNN에 입력하였다. CNN에 CIPS/DCVG 신호 특성과 매설 배관의 위치 특성을 학습시키고 학습된 CNN을 이용해 매설 배관의 간접검사 전위 탐상 신호를 진단하여 피복 결함의 유무를 판별하고, Grad-CAM(Gradient Class Activation Map)<sup>3</sup> 기술로 피복 결함부 예측 위치를 시각화하는 알고리즘을 개발하였다.

## 2. 탐상신호 진단을 위한 딥러닝 알고리즘 개발

### 2.1 탐상 신호 진단을 위한 딥러닝 알고리즘 구성

CNN 알고리즘을 이용한 탐상 신호 진단 알고리즘 개발 방안은 Fig. 3과 같다. 입력 데이터로는 매설 배관 부근의 부지에 대한 CIPS 및 DCVG 신호 복합 데이터와 매설 배관 배치 데이터를 사용하였다. 합성곱 신경망(CNN)을 결함부가 없는 정상 데이터와 결함부가 있는 비정상 데이터 class로 이진 분류하도록 지도 학습을 수행하였다. 학습된 신경망을 이용하여 비정상 데이터를 분류하고, 분류된 비정상 데이터(Abnormal data)에 대해 매설 배관의 결함이 있을 것 같은 영역을 시각화하여 보여주기 위한 기술로 Grad CAM을 적용하여 결함부 예측 위치에 대한 히트맵(Heat Map)을 생성하여 시각화하도록 전체 알고리즘을 구축하였다.




Fig. 3 Schematic diagram of CNN algorithm diagnosis of electric potential signal

2.2 입력 데이터

Fig. 4는 COMSOL을 이용한 지전위 유한요소해석 시뮬레이션을 위한 3D 모델과 시뮬레이션 결과 생성된 신호 데이터의 예를 보여주는 그림이며 인공 결함은 매설 배관의 코팅부만 손상된 것으로 하여 모델을 구성하였다. Fig. 4(a)는 임의의 인공결함들이 존재하는 단일 직관의 모델, Fig. 4(b)는 여러 배관이 적층 및 교차되어 있는 복잡한 매설 배관 배치 모델 그림이다. COMSOL 기반 전위 유한요소해석 시뮬레이션 결과 지전위 분포를 CIPS 신호, 지전위 구배 특성을 DCVG 신호로 간주하였다.

Fig. 4(a)의 단일 직관 모델에서 매설 배관의 인공 결함의 개수와 위치를 변화시킨 5가지의 단일 직관 인공결함 모델과 Fig. 4(b) 3D 모델에서 인공결함의 개수와 위치를 변화시켜 3가지의 복잡한 배치의 매설 배관 인공결함 모델의 시뮬레이션 해석 결과에 대한 지전위 신호 데이터를 얻었다. X, Y 방향별 0.5m 간격으로 얻은 전위 데이터를 CIPS 신호 데이터로 이용하였고, X, Y 방향별 전위 차이는 DCVG X 방향 & DCVG Y 방향 신호데이터로 이용하여, 8가지

인공결함 모델에 대한 2차원의 CIPS, DCVG\_X, DCVG\_Y 신호 데이터를 얻었다.

생성된 8가지 인공결함 모델의 CIPS, DCVG\_X, DCVG\_Y 데이터에 실제 현장 측정시 발생 가능한 노이즈를 고려하여 가우시안 노이즈(Gaussian Noise)를 삽입하고, 정규화(Normalization) 처리를 하였다. CIPS, DCVG\_X, DCVG\_Y 데이터에 노이즈의 크기 별로 총 4가지 Case를 만들었으며, 노이즈 크기는 Case 1 (CIPS : 0.1%, DCVG : 0.5%), Case 2 (CIPS : 1%, DCVG : 5%), Case 3 (CIPS : 5%, DCVG : 10%), Case 4 (CIPS : 10%, DCVG : 20%)로 하여 가우시안 노이즈를 삽입하였다.

노이즈 삽입 후 정규화 처리된 2차원의 CIPS, DCVG\_X, DCVG\_Y 3개의 신호 데이터들을 3차원의 채널(Channel) 방향으로 쌓아 너비, 높이, 채널(W, H, C)의 3차원의 복합 신호 데이터로 만들었다. CNN 알고리즘은 일정한 크기의 데이터를 입력 데이터로 가져야 하므로 16x16x3(WxHxC)를 복합 신호 데이터의 입력 크기로 하여, 각 인공결함 모델별 3차원 데이터를 만들고 윈도우 슬라이딩 방식으로 잘라 3D 신호 데이터를 생성하였다.

유한요소해석 데이터를 생성하기 위해 만든 3D 모델 매설 배관의 평면도를 배관 배치(PIPING LAYOUT) 데이터로 이용하였다. 배치 데이터를 윈도우 슬라이딩 방식으로 잘라 16X16의 1차원의 배관 배치 데이터를 생성하였으며 합성곱 신경망에 입력될 때 신호 복합 데이터의 위치와 배관 배치 데이터의 위치가 매칭되어 입력되도록 구성하였다.

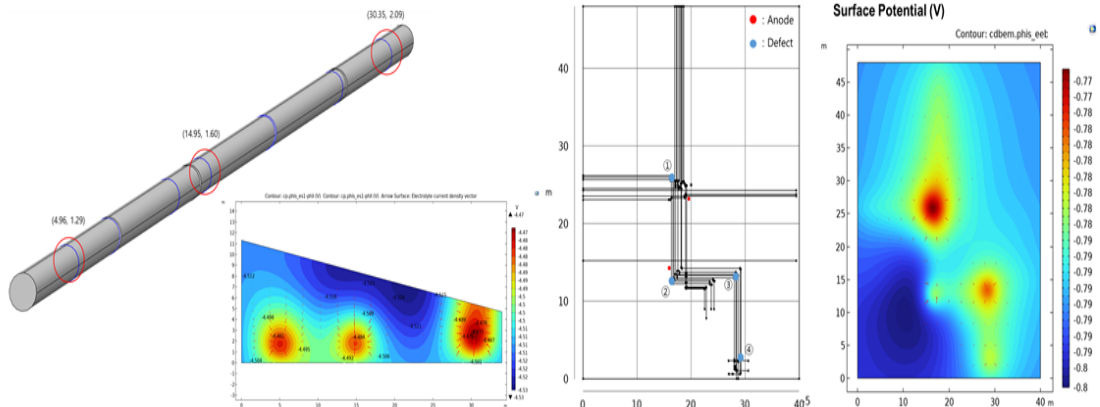


Fig. 4 3D model & Electric potential FEA for buried pipe

2.3 CNN 모델

신호 판별을 위해 구성한 CNN 모델 구조의 특징은 앞서 생성된 3D 신호 데이터와 2차원의 배관 배치 데이터를 Fig. 5와 같이 각각 입력받게 된다. CNN 모델은 아래 그림과 같이 입력층과 합성곱층으로만 이루어진 Layer1, Layer2, Layer3, 합성곱층과 풀링층이 연결된 Layer4, 완전연결층, 출력층으로 구성하였다.

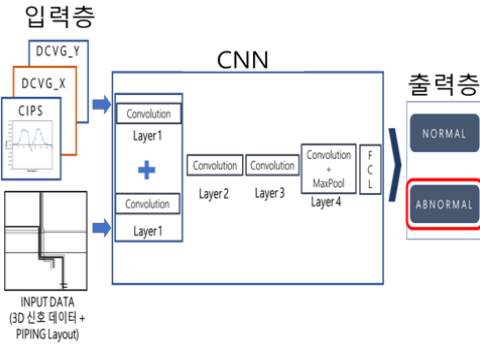


Fig. 5 CNN model configuration

2.3.1 입력층

입력층은 (16x16x3)의 3차원 CIPS/DCVG 복합 신호 데이터와 (16X16)의 배관 배치(PIPING LAYOUT) 데이터로 이루어졌다.

2.3.2 합성곱층

합성곱층에서는 합성곱 연산을 수행하게 되는데, 합성곱 연산은 입력데이터에 대하여 필터(Filter)가 일정한 간격(Stride)으로 이동하며 Dot Product 연산을 수행하고 그 결과로 입력된 데이터의 특성을 갖는 특성맵(Feature Map)을 생성한다. 이때 필터들을 구성하는 각각의 값들이 가중치(Weight) 파라미터가 되며, 신경망이 학습한다는 것은 이 가중치들이 최적값을 갖도록 찾아 나감을 의미한다.

전위 신호 진단을 위한 CNN 모델에 적용된 모든 합성곱층에는 3X3 필터, Stride는 1, padding은 1을 적용하여 합성곱 연산 과정에서 위치 정보에 대한 손실이 발생하지 않게 출력되는 특성맵의 크기와 입력의 크기와 같도록 구성하였다.

첫 번째 층(Layer 1)에서는 입력층에서 전달된 두 데이터를 각각 합성곱 연산을 통해 신호 특성과 배관 위치 특성을 각각 학습시킨 후 신호 특성과 배관

위치 특성을 가진 특성맵을 채널 방향으로 연결(concatenate)해 두 번째 층(Layer 2)부터는 연결된 두 특성을 동시에 학습하도록 구성하였다.

2.3.3 풀링층

풀링(Pooling)은 너비와 높이 방향의 공간을 축소시키는 연산으로, 필터의 크기와 이동 간격(Stride)의 크기를 같게 설정하여 입력된 데이터의 가로와 세로의 크기를 반으로 줄여주며 학습하는 매개변수가 없고 데이터 크기를 축소시켜 연산량을 감소시켜주는 역할을 한다.

이 CNN 내 특성맵의 크기는 16x16으로 크지 않고, 추후 Grad Cam을 이용한 결함 위치 예측 정확도를 높이기 위해 Layer 4에만 필터 영역의 최대값을 출력하는 최대 풀링(Max Pooling)을 적용하였다.

2.3.4 완전연결층

완전연결층(Fully Connected Layer)에서는 Layer 4의 출력값으로 나온 특성맵의 모든 노드(Node)들을 1열로 나열하며 이때 다차원의 특성맵이 1차원으로 변하며 각 노드들이 가진 위치 정보와 다차원 상 밀접하게 위치한 값들과의 연관성이 손실된다. Flatten 된 노드들은 출력층과 연결하여 학습시켜 최종적인 분류 연산을 수행한다.

2.3.5 출력층

완전 연결층과 연결된 출력층은 결함부가 없는 정상 데이터와 결함부가 존재하는 비정상 데이터로 이진 분류를 수행한다. 출력층에서는 각 레이블에 속할 확률을 계산하고, 이 중 더 큰 값이 출력된다.

2.4 Grad CAM

합성곱 신경망은 마지막 완전연결층을 통과하며 다차원 데이터들이 위치 정보를 손실하게 되기 때문에 신경망이 어떠한 영역을 보고 특정 class로 분류했는지 알 수 없는데 이를 시각화하여 보여주는 알고리즘의 하나가 Grad CAM이다.

Grad CAM은 출력 대상 특성맵 뒤에 연결된 네트워크의 gradient 정보를 이용하여 각 뉴런의 중요도를 파악한다. Grad CAM은 특성맵 위의 네트워크를 추적해 gradient를 얻어 특성맵에 곱한 후 최종적으로 ReLU 함수를 통과하여 히트맵을 만든다. ReLU 함수를 적용한 이유는 출력값에 positive한 영향을

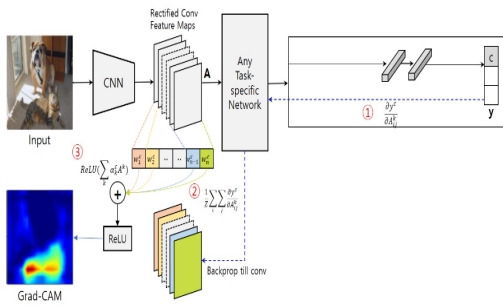


Fig. 6 Grad CAM concept map

주는 노드에만 관심이 있기에 negative한 영향을 주는 노드들은 제거함으로써 성능을 향상시킨다.

CNN이 정상/비정상 데이터를 분류하였다면, Grad CAM은 비정상 데이터에 대하여 ‘비정상 데이터’라는 결과를 얻는데 positive한 영향을 주는 노드를 찾아 이상 신호가 있는 매설 배관의 결함부 영역에 대해 히트맵을 생성하여 시각화한다.

### 2.5 학습 결과

다양한 크기의 노이즈 데이터로 CNN을 학습시켰고 Fig. 7은 학습이 진행되는 동안의 학습 정확도와 학습 손실(Loss) 그래프이다.




Fig. 7 CNN model's learning accuracy(a) and loss(b)

학습 정확도는 학습이 진행되는 과정에서 신경망의 분류 성능을 보여주는 지표이며, 학습 손실은 신

경망이 학습시 가중치(Weight) 매개변수의 최적값을 찾는 과정에서 손실함수(Loss Function)를 이용하여 신경망이 얼마나 잘못 예측하고 있는지에 대한 정도를 확인하게 되는데 이 정도를 학습 손실이라 부르며 학습 손실이 0으로 수렴함은 학습이 잘 되고 있음을 의미한다. Fig. 7을 보면 학습 정확도는 95% 이상, 학습 손실은 0으로 수렴하며 학습이 잘 된 것을 확인할 수 있다.

비정상 데이터로 분류한 데이터에 대해 Grad CAM을 이용해 예측 결함 위치를 보여주는 히트맵을 얻고 이를 결함부가 있는 실제 결함 위치와 비교해 보았다. Fig. 8을 보면 좌측이 비정상 데이터에 대한 히트맵이며, 히트맵 상 노란색 영역이 결함 추정부로 우측의 실제 결함이 위치한 영역과 비교해 봤을 때 Grad CAM이 결함부를 추적하여 보여주는 것을 확인할 수 있다.




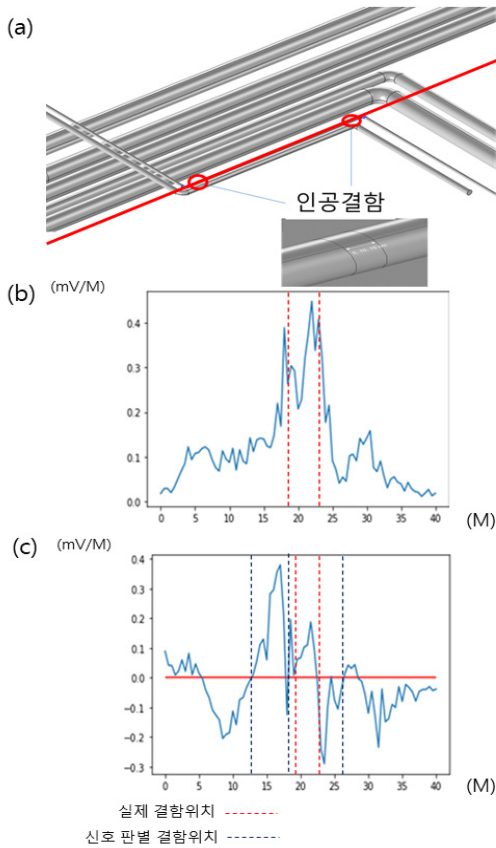
Fig. 8 The heat map of the Grad CAM for abnormal data and the location for abnormal data

## 3. 성능분석

### 3.1 전위 신호 진단 CNN

매설 배관 전위 탐상 신호 진단을 위한 CNN 알고리즘이 기존 CIPS/DCVG의 검사방식과 비교하여 성능 개선 여부를 확인하기 위해 기존의 측정방식으로 판별이 어려운 Fig. 9(a)과 같이 복잡한 매설 배관 배치 모델의 유한요소해석 데이터를 이용하여 검증하였다. 적색 직선상 19m와 23m 두 지점에 결함부가 존재하는 해석 데이터에 노이즈를 삽입하여 Fig. 9(b)의 CIPS신호, Fig. 9(c)의 DCVG 신호를 생성하였다.


적색 직선상의 CIPS 신호 Fig. 9(b)를 통해 15~25m 지점의 지전위 값이 주변부에 비해 높으며, 30m 지점이 그래프상 주변부에 비해 높음을 알 수 있다. CIPS 검사는 매설 배관의 전기방식 상태 및 추후 전



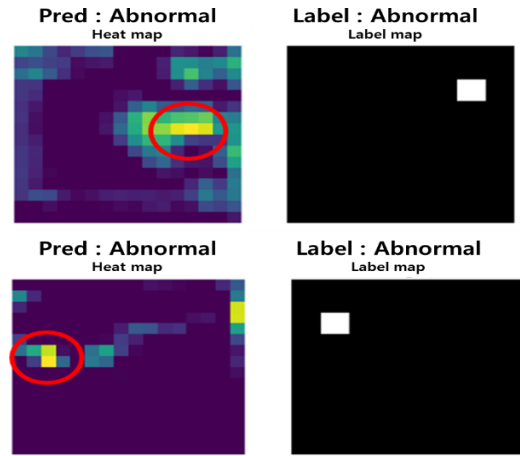
**Fig. 9** Buried pipe layout(a) and CIPS(b) & DCVG (c) signal on the red line

기방식 설계를 위한 기초정보를 획득하는 검사로 매설 배관의 피복 결함을 탐측하는 검사방식은 아니다. 매설 배관의 피복 결함부 탐측을 위한 검사인 DCVG 신호 Fig. 9(c)를 통해 신호 그래프상 전위 구배가 음(-)에서 양(+)로 바뀌는 지점이 결함부가 있는 지점으로 판단하며 13m, 18m, 26m 지점에서 음(-)에서 양(+)로 전위 구배 크기가 변환 부근에 결함부가 존재할 것으로 판단할 수 있다. DCVG 신호를 실제 결함부가 19m, 23m 위치함과 비교한다면 19m 지점의 결함부는 근처를 탐지하였으나 23m 지점의 결함은 탐지하지 못하였고, 결함이 없는 13m, 26m 두 지점에 결함부가 있을 것으로 판별하여 현재의 측정 방식으로 해당 데이터에 대해 매설 배관 피복 결함 유무와 위치를 정확히 판별할 수 없음을 확인할 수 있다.

탐상 신호 진단 CNN 알고리즘을 이용하여 동일



**Fig. 10** Input data area for CNN



**Fig. 11** CNN's classification results for abnormal data and comparison of actual flaw location with heat maps

한 신호 데이터에 대하여 Fig. 10과 같이 4개의 면에 대한 3D 복합 데이터를 입력하여 결함부 판정 및 결함부 예측부를 시각화하였다. Fig. 11과 같이 결함이 있는 2개의 데이터에 대해 정확히 분류하였고, 히트맵 상 결함 예측 지점과 실제 결함부의 위치가 1.5m 정도의 오차로 기존 검사방식과 비교했을 때 성능이 개선되었음을 확인할 수 있다.

### 3.2 측정오차 별 결함 판정 성능 분석

실제 발전소에서 측정 시 발생할 신호의 노이즈에 대하여 신호 진단 알고리즘의 강건성을 확인하기 위해 CIPS/DCVG 신호에 노이즈 크기를 변경하며 결함 신호 판별과 결함 위치 예측에 대한 성능을 분석하였다.

학습된 CNN 모델에 대하여 노이즈 크기에 강건함을 확인하기 위해 CIPS/DCVG 신호의 노이즈 크기별 5가지 케이스에 대한 테스트 데이터를 생성하여 CNN의 분류 성능을 측정하였다. 테스트 데이터의 각 케이스별 노이즈 크기는 Case1 (CIPS :

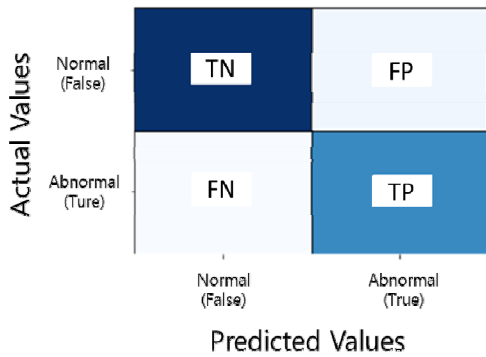


Fig. 12 Confusion Matrix

0.1%, DCVG : 0.5%), Case2 (CIPS : 1%, DCVG : 5%), Case3 (CIPS : 5%, DCVG : 10%), Case4 (CIPS : 10%, DCVG : 20%), Case5 (CIPS : 20%, DCVG : 40%)로 하여 CIPS/DCVG 신호에 노이즈를 삽입하여 각 Case 별 617개(Normal : 466개, Abnormal : 151개)의 데이터를 생성하였다.

Fig. 12과 같이 Normal(정상) 데이터를 False로 Abnormal(비정상) 데이터를 True로 하여 각 Case 별 Confusion Matrix를 생성하여 정확도(Accuracy), 재현율(Recall), 정밀도(Precision), F1 score 4개의 분류 성능 평가지표를 평가했으며 각 평가지표의 수식은 Fig. 13과 같다.

$$\begin{aligned}
 \text{Accuracy} &= \frac{TP+TN}{TP+FP+FN+TN} & \text{Recall} &= \frac{TP}{TP+FN} \\
 \text{Precision} &= \frac{TP}{TP+FP} & \text{F1-score} &= 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}
 \end{aligned}$$

(a) (b) (c) (d)

Fig. 13 Formula of the classification performance evaluation index

노이즈 크기(Case)별 테스트 데이터에 대한 CNN의 분류 성능은 Table 1과 같다. 먼저 모든 데이터에 대한 분류 성능인 정확도를 살펴보면 5가지 Case에서 92~95%의 높은 수준으로 노이즈 크기와 상관없이 높은 정확도의 성능을 보임을 확인할 수 있다. 매설 배관의 안정성 확보를 위하여 결함부 데이터를 얼마나 정확히 분류하였는지 대한 수치인 재현율은 전체 평균 93.1%의 높은 검출률을 보였으나, 노이즈 Case5 (CIPS : 20%, DCVG : 40%)에서 재현율이

84.4%로 성능이 저하되며 노이즈가 큰 영역에서는 결함부에 대한 검출률이 저하됨을 확인하였다. 정상/비정상 데이터의 불균형으로 정밀도가 정확도나 재현율에 비해 낮은 평균 81.6%의 수치를 보이며, 재현율과 정밀도의 조화 평균인 F1 score는 전체적으로 0.84-0.9로 높은 성능이 유지됨을 확인할 수 있다.

Table 1 Performance evaluation metrics for CNN model with 5 signal noise cases

Noise Case	Accuracy	Recall	Precision	F1 Score
Case1	0.929	0.939	0.798	0.863
Case2	0.932	0.939	0.807	0.868
Case3	0.921	0.925	0.782	0.847
Case4	0.948	0.946	0.853	0.897
Case5	0.924	0.844	0.838	0.841
Overall	0.931	0.919	0.816	0.863

CNN 분류 성능지표를 통해 전위 탐상 신호 진단 CNN이 노이즈가 큰 영역에서는 결함부에 대한 검출 성능이 저하되긴 하나 노이즈에 강건함을 확인할 수 있다.

### 3.3 측정오차 별 결함 위치 예측 성능 분석

노이즈 Case 별로 비정상 데이터로 분류한 데이터에 대하여 Grad CAM으로 생성한 히트맵의 결함부 위치와 실제 결함부 위치의 오차로 예측 결함 위치 성능을 측정했다.

노이즈 Case 별 위치 오차의 평균값은 Table. 2와 같으며, 평균 위치 오차는 노이즈 크기에 비례하지 않으며 오차 거리가 평균적으로 2~2.3m 내외의 임을 알 수 있다. Fig. 14의 히스토그램과 박스 플롯을 보면 모든 케이스에서 오차 거리 0~2m 범위에 많은 데이터가 밀집해 있으며 크기와 관계없이 모든 노이즈 Case에서 오차 거리가 4m 이상인 이상치(outlier)가 많은 것을 확인하였다.

Table 2 Average error distance at flaw location prediction point

Case1	Case2	Case3	Case4	Case5
2.23m	2.05m	2.21m	2.18m	2.37m

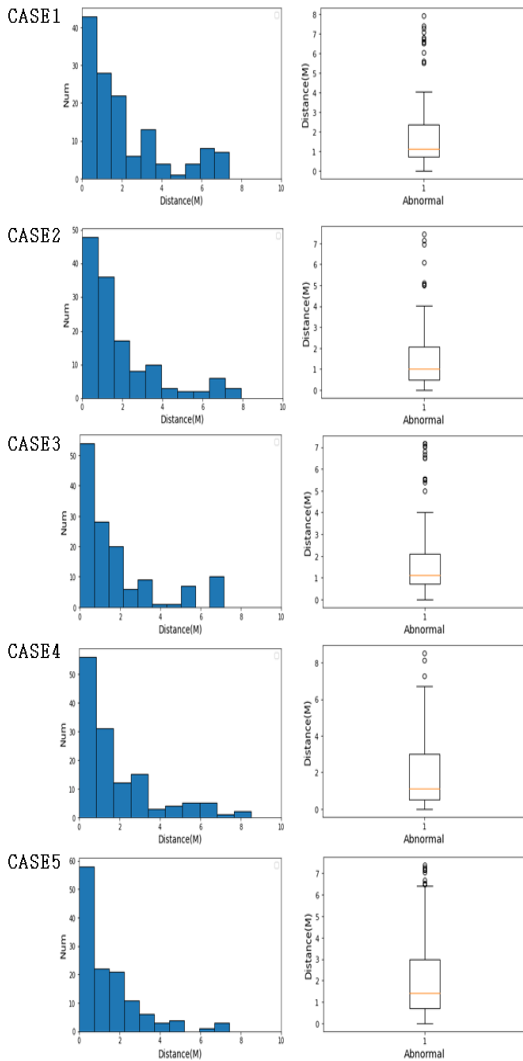


Fig. 14 Histogram & Box Plot for Predictive Flaw Position Errors by Noise

#### 4. 결 론

본 연구에서는 매설 배관의 건전성 확인을 위해 적용되는 음극방식의 간접 검사인 CIPS 및 DCVG의 전위 탐상 신호 진단의 정확성을 높이고, 보다 객관적이고 자동화된 방법으로 판별하고자 딥러닝 알고리즘을 적용하였다. 기존 진단 방법 대비 정확성을 높이고자 CIPS, DCVG\_x, DCVG\_Y 방향 3가지의 신호를 복합적으로 진단하도록 데이터를 구성하였으며, 매설 배관의 결함을 판정하고 결함부를 예측하여 보여주기 위해 CNN과 Grad CAM을 적용한

딥러닝 알고리즘 개발하였다.

지전위 유한요소해석 데이터에 실제 환경에서 발생 가능한 측정 오차를 고려하여 다양한 크기의 노이즈를 삽입한 데이터를 이용하여 CNN을 학습시켰고, 학습된 CNN과 Grad CAM을 이용한 결함 판정 및 결함부 위치 예측은 기존의 CIPS/DCVG 검사방식을 이용한 판별 방법으로 판정이 어려운 신호에 대해서도 판정과 결함부를 비교적 정확히 예측할 수 있음을 확인하였다. CNN 모델의 결함부 데이터 분류 성능은 여러 노이즈 크기에서도 재현율과 F1 Score에서 높은 성능 수치를 보여주며 신뢰성을 보였으나, 결함 신호의 간섭으로 인하여 전압 기울기 극성 역전이 발생하지 않는 데이터에 대한 분류 정확도가 낮으며, 학습데이터의 다양성이 낮아 많은 데이터로 추가 학습을 통해 성능 향상이 필요할 것으로 보인다. Grad CAM을 이용한 결함부 위치 추적은 전반적으로 오차 거리 2m 이내로 비교적 잘 예측하나 전혀 다른 위치를 예측하는 이상치(outlier)가 많다는 한계를 확인하였다. 매설 배관 결함부의 보수 작업은 결함부 부근을 굴착하여 진행하게 되는데, 예측한 결함부의 위치가 부정확한 경우 불필요한 작업으로 인한 비용 손실과 시간적 손실이 발생하게 되므로 결함부의 위치를 추적하는 알고리즘의 보완 한다면 전위 탐상 신호 진단에 활용성이 높을 것으로 판단된다.

연구에 사용한 데이터는 지전위 유한요소해석 데이터에 임의의 노이즈를 삽입한 데이터로 실제 현장 측정 데이터와는 다소 차이가 있을 것으로 판단되며 추후 실측 데이터를 이용하여 CNN에 대해 추가 학습을 진행하고, 성능검증을 통하여 실제 측정 신호 데이터에 대한 알고리즘의 적용 가능성을 확인할 예정이다.

#### 후 기

본 연구는 산업통상자원부(MOTIE)와 한국에너지기술평가원(KETEP)의 지원을 받아 수행한 연구 과제입니다(No. 20217910100010).

#### 참고문헌

- (1) KOGAS-TECH, A good world to live in without underground accident, Safety Management of



- Underground facility.
- (2) M. G. Kim, B. T. Lim, K. T. Kim, H. Y. Chang, H.B. Park, and Y.S Kim, 2020, "Enhancing the Reliability of Coating Flaw Detection for Pipes Buried in Soil Using a Multi-Electrode Detector", *CORROSION SCIENCE AND TECHNOLOGY*, Vol.19, No.5, pp.265-280.
  - (3) Ramprasaath R. Selvaraju, Michael Cogswell, Abhishek Das, Ramakrishna Vedantam, Devi Parikh, and Dhruv Batra, 2017, "Grad-CAM: Visual Explanations from Deep Networks via Gradient-based Localization", *ICCV*.
  - (4) KISTEK, 1999, Development of corrosion environment survey and analysis method for buried pipe II.
  - (5) KOGAS, Protection technique handbook, pp.18, 2003.
  - (6) Jae-Won Kim, Bu-Taek Lim, Heung-Bae Park, and Hyun-Young Chang, 2018, "Technology for the Detection of Corrosion Defects in Buried Pipes of Nuclear Power Plants with 3D FEM", *CORROSION SCIENCE AND TECHNOLOGY*, Vol.17, No.6, pp.292-300.
  - (7) H. Y. Chang, K. T. Kim, B. T. Lim, K. S. Kim, J. W. Kim, H. B. Park, and Y. S. Kim, 2017, "Protection Performance Simulation of Coal Tar-Coated Pipes Buried in a Domestic Nuclear Power Plant Using Cathodic Protection and FEM Method", *CORROSION SCIENCE AND TECHNOLOGY*, Vol.16, No.3, pp.115-127.
  - (8) S. H. Choi, S. Y. Won, Y. R. Yoo, and Y. S. Kim, 2022, "Relationship between the Cathodic Protection of Pipe Buried in Soil and Environmental Factors", *CORROSION SCIENCE AND TECHNOLOGY*, Vol.21, No.5, pp.372-380.
  - (9) J. J. Kim, M. S. Seo, and D. K. Kim, 2014, "The Study on Development of Cathodic Protection on Underground Pipeline Measuring System", *KIGAS*, Vol.18, No.5, pp. 66-71.
  - (10) M. E. Orazem, 2014, *Underground Pipeline Corrosion*, 1st ed., p. 227, Woodhead Publishing, Cambridge.  
<https://doi.org/10.1533/9780857099266.2.227>
  - (11) COMSOLTM, 2014, *Guidebook of COMSOLTM Multiphysics (Chemistry-Electrochemistry)*, ALTSOFT, pp. 174.
  - (12) M. G. Kim, B. T. Lim, K. T. Kim, H. Y. Chang, H. B. Park, and Y. S. Kim, 2020, "Effects of Rectifier and Copper Grid Interference on the Detection Reliability of Coating Flaws on Buried Pipes", *CORROSION SCIENCE AND TECHNOLOGY*, Vol.19, No.4, pp.211-223.
  - (13) J B. Park, H. M. Kim, and G. S. Park, 2016, "A study on the Signal Correction for Multiple Defects in MFL Type Nondestructive Testing System", *J. Korean Magn. Soc.*, Vol.26, No.1, pp.24-30.
  - (14) Y. D. Ryou, J. H. Lee, Y. K. Yoon, and H. S. Lim, 2014, "The Development and Introduction of External Corrosion Direct Assessment Measures for Urban Gas Pipelines", *KIGAS*, Vol.18, No.5, pp.12-19.
  - (15) H. Y. Chang, H. B. Park, K. T. Kim, Y. S. Kim, and Y. Y. Jang, 2014, "Evaluation of Corrosion Protection Efficiency and Analysis of Damage Detectability in Buried Pipes of a Nuclear Power Plant with 3D FEM", *Trans. of the KPVP*, Vol.11, No.2, pp.61-67.
  - (16) WIKIPEDIA, 2023, Confusion matrix, [https://en.wikipedia.org/wiki/Confusion\\_matrix](https://en.wikipedia.org/wiki/Confusion_matrix).