

Development of a Deep-Learning- Based Flaw Detection Algorithm for Analysis of Pulsed Eddy Current Nondestructive Test Data

2022. 10. 20

Hyoung Tae Kim*

Duck-Gun Park

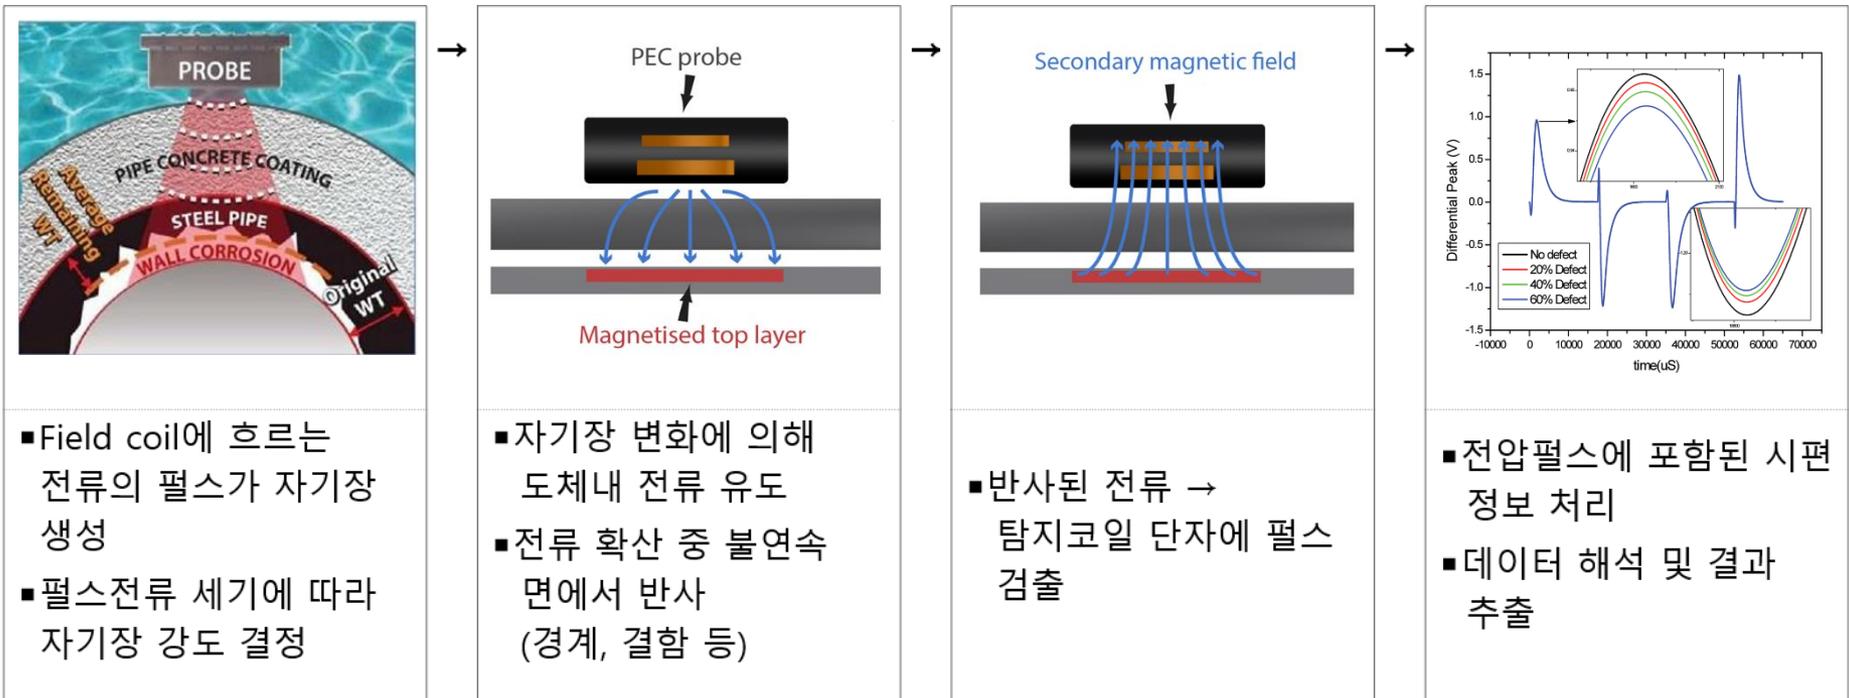
Intelligent Accident Mitigation Research Division



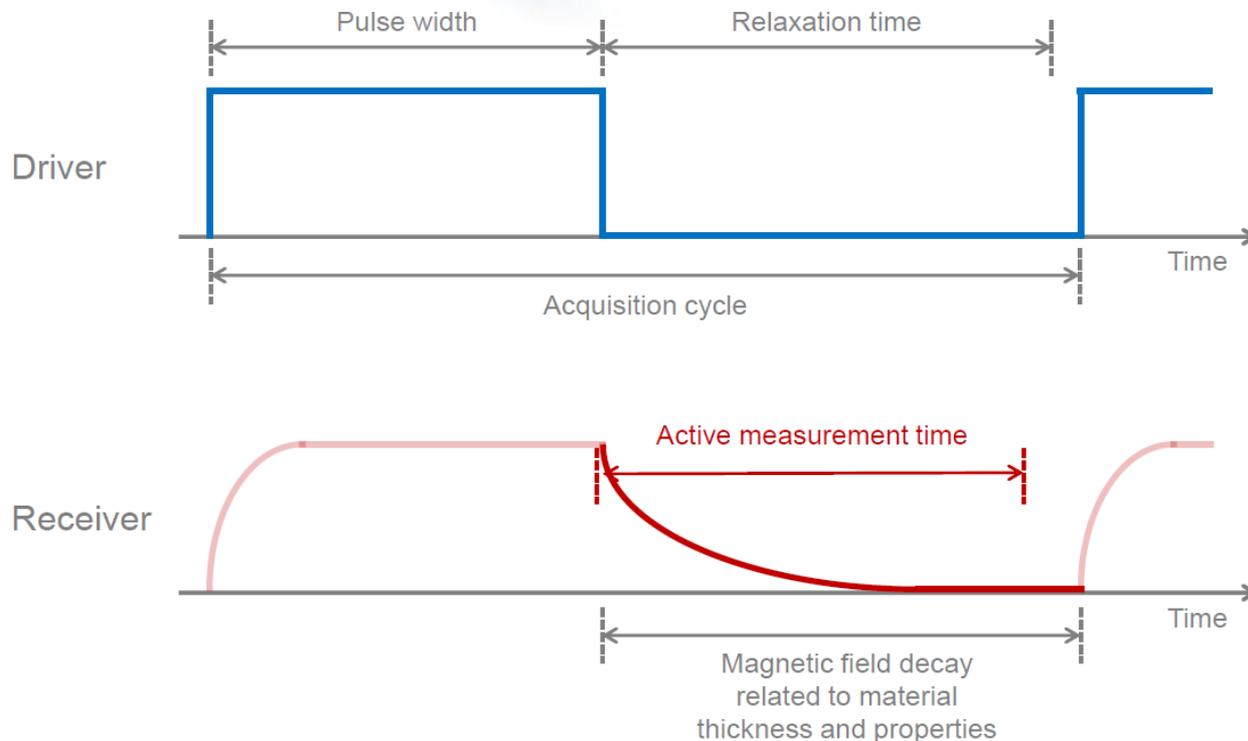
한국원자력연구원
Korea Atomic Energy Research Institute

1. 펄스와전류(PEC: Pulsed Eddy Current) 검사

- 와전류검사(ECT: Eddy Current Testing) 기술은 펄스전류를 시험편에 인가하여 유도되는 와전류를 검출, 분석해 배관 내의 결함을 검출하는 기술
 - 구동 코일에 흐르는 펄스 전류가 자기장을 생성하면, 자기장 변화에 의해 배관을 이루고 있는 도체에 전류가 유도되고, 결함 부위에서 반사된 전류를 탐지코일 단자에서 검출을 한 후, 이 데이터를 해석하여 결함 부위를 탐색



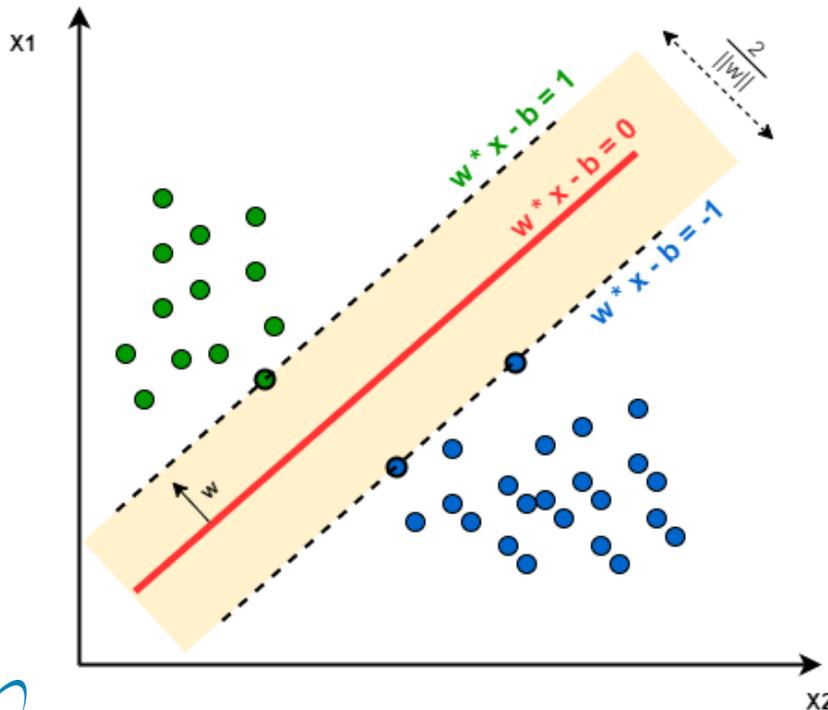
- 피검체의 두께가 두꺼울수록 와전류가 0으로 감소하기까지 걸리는 시간이 길어지며, 이러한 시간차를 부식이 없는 건전부와 비교함으로써 간단하게 배관 검사 가능
- 측정 데이터의 스캐틀링이 심하기 때문에, 애매한 부분을 구분해 내기 위해서 기계학습 및 인공지능 알고리즘 도입



2. 기계학습 및 인공지능 알고리즘 도입

□ SVM (Support Vector Machine)

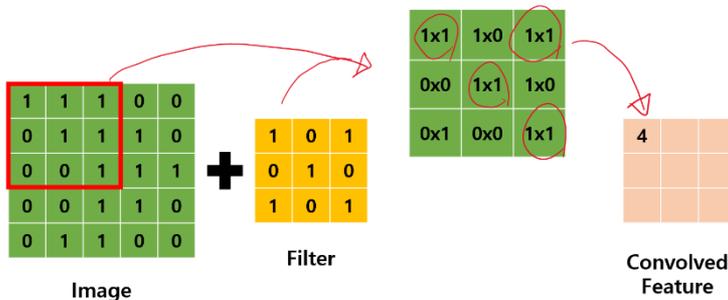
- 결정 경계(Decision Boundary), 분류 기준 선을 정의하는 모델
- 분류되지 않은 새로운 점이 나타나면 경계의 어느 쪽에 속하는지 확인해서 분류가 가능
- 서포트 벡터와 결정 경계 사이의 거리를 마진(margin)이라고 하고, SVM은 허용 가능한 오류 범위 내에서 가능한 최대 마진을 만드는 알고리즘



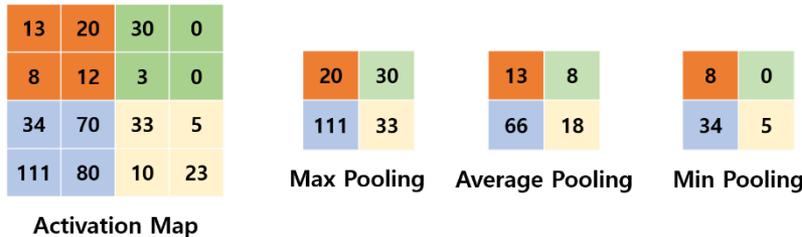
- SVM은 분류에 사용되는 지도학습 머신 러닝 모델
- 서포트 벡터(support vectors)는 결정 경계에 가장 가까운 각 클래스의 점들임
- 서포트 벡터와 결정 경계 사이의 거리를 마진(margin)이라고 함
- SVM은 허용 가능한 오류 범위 내에서 가능한 최대 마진을 만들려고 함

□ CNN(Convolutional Neural Networks)

- 합성곱(Convolution) 연산을 사용하는 인공 신경망
- 다층의 컨볼루션 계층들을 통해서 데이터의 특징을 추출하게 되고, 추출된 특징을 기반으로 기존의 신경망을 이용하여 분류



- 다층의 Convolution 계층을 통해서 데이터의 feature map을 만들어 데이터의 특징을 추출
- 합성곱 과정을 거친 데이터의 크기를 줄이고, 특정 feature를 강조하기 위해 Pooling 작업을 수행



3. 실험 및 데이터 신호 특성 분석

□ 데이터 취득 조건

○ 5단계 계단형 배관:

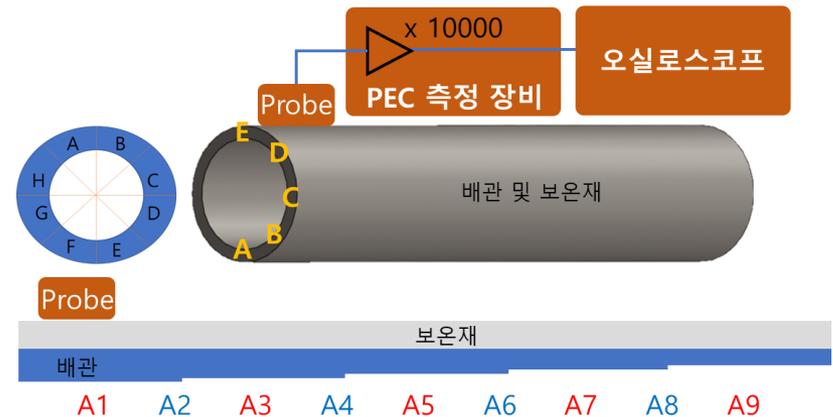
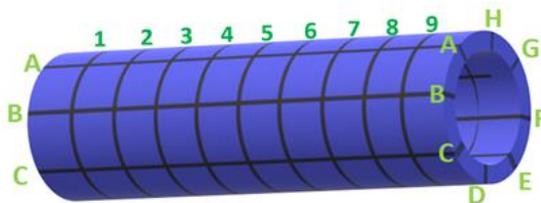
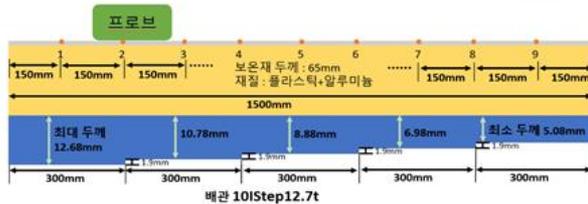
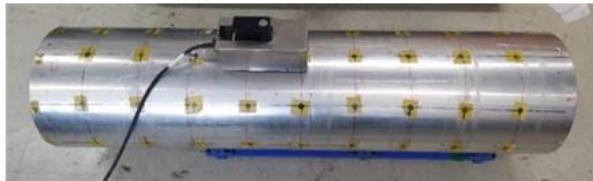
- ▶ 제일 두꺼운 부위가 약 9.5mm이며, 약 1.5mm씩 줄어드는 5단계의 1500mm 길이의 계단형 배관

○ 50mm 플라스틱 및 0.5mm 스테인레스 Cladding으로 보온재 모사

○ 기본 수신 신호를 10000배 증폭 후, 저장

○ 취득 데이터 총 720개 (동일 지점 10번씩 측정)

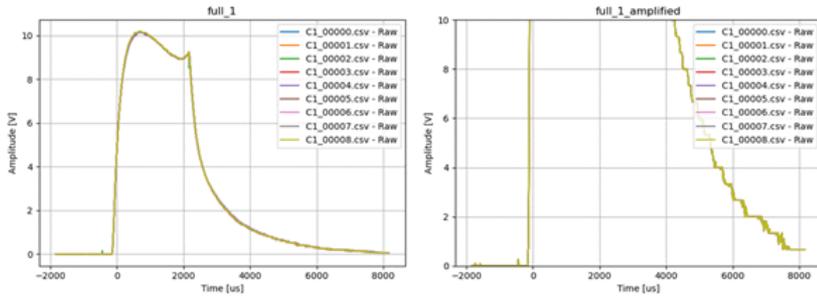
- ▶ 단차 9 지점과 동경 방향 8 지점 = 72 지점
- ▶ 9 지점 중, Flat 5 지점, Edge 4 지점



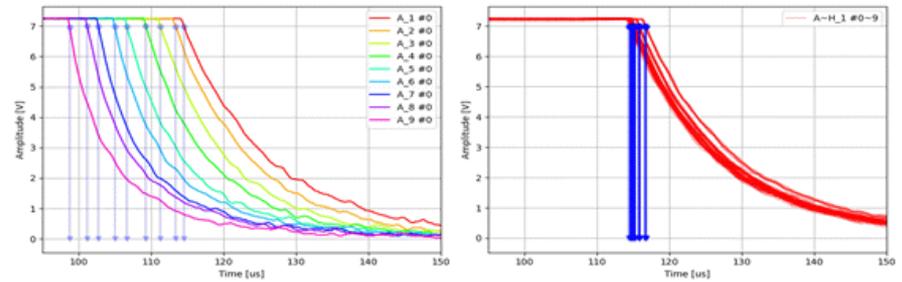
□ 실험 전 처리 및 특성 분석

○ Raw 신호 증폭 특성 및 Moving Averaging 적용

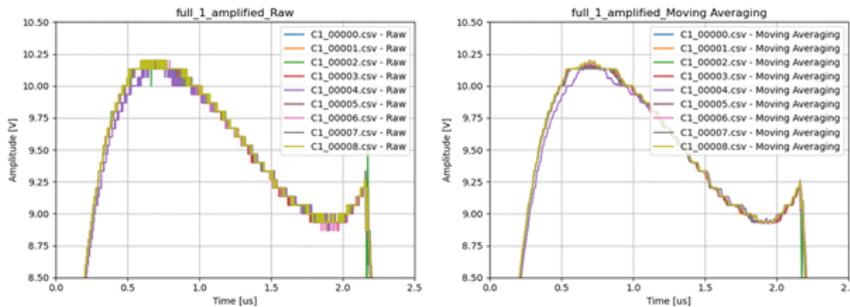
○ Raw 신호에 대해 종래의 신호처리 기법을 통한 배관 감육 상태 추정



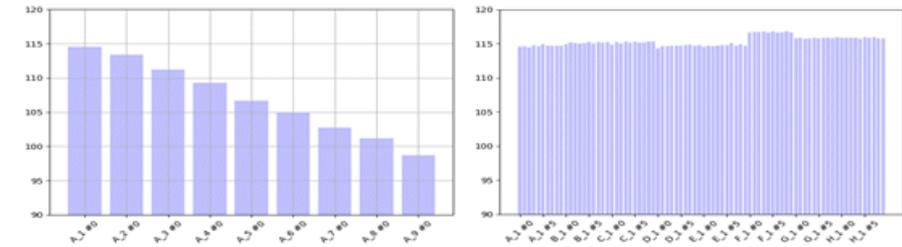
Raw 신호 예시 (좌: 신호 증폭 전, 우: 신호 증폭 후)



종래의 특정 전압의 시간 추출법(Voltage Cut Time)



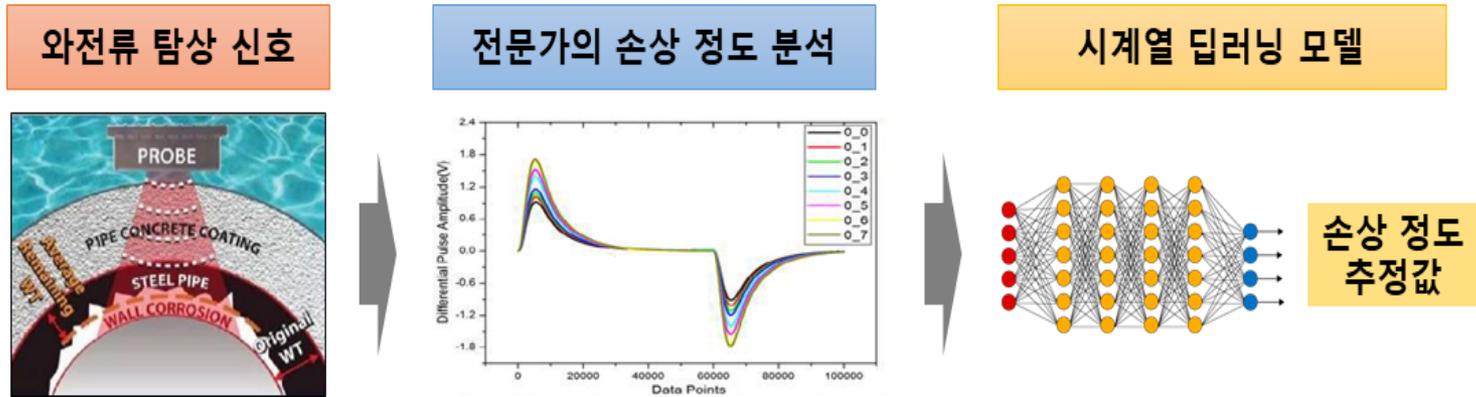
Moving Averaging 적용 예시 (좌: 적용 전, 우: 적용 후)



감육 두께가 서로 다르거나 같은 지점에서의 시간 지연 특성,
 (a) 두께가 서로 다른 지점에서의 시간 지연
 (b) (두께가 동일한 지점에서의 시간 지연)

4. 딥러닝 모델 개발

- 펄스와전류 신호를 분석해 판단한 손상 정도를 딥러닝을 통해 학습 후, 미지의 펄스와전류 신호로부터 손상 정도의 추정하는 비파괴평가 AI 개발
- 딥러닝 학습에 용이하도록 신호 데이터의 전처리(정규화 및 디노이징)를 수행, 추정 정확도를 향상할 수 있는 전처리 조건 선정

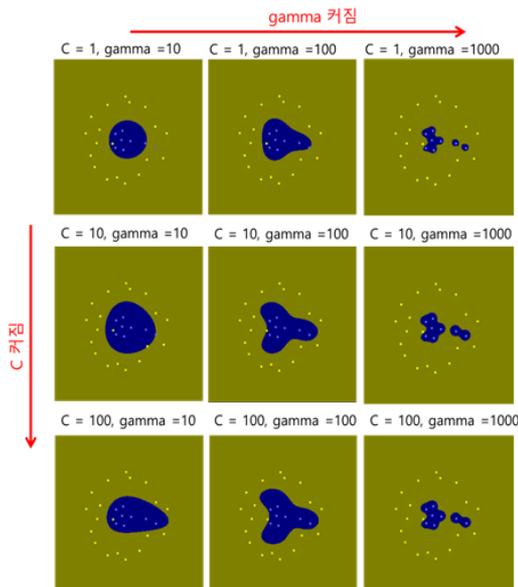


- Desktop 환경에서 호환 가능한 Open Source를 활용하여 신호 전처리 및 딥러닝 알고리즘 개발

운영체제	프로그래밍 언어	딥러닝 라이브러리	입력 데이터	출력데이터
Windows 10 (64 bit)	Python 3	Tensor Flow 2	*.csv	*.csv

□ SVM(Support Vector Machine) 모델을 이용한 알고리즘 개발

- 두 카테고리 중 어느 하나에 속한 데이터의 집합이 주어졌을 때, SVM은 주어진 데이터 집합을 바탕으로 새로운 데이터가 어느 카테고리에 속할지를 판단하는 비확률적 이진 선형 분류모델을 만들
- 데이터가 사상 공간에서 경계로 표현되는데 SVM은 그중 가장 큰 폭을 가진 경계를 찾는 알고리즘



□ CNN(Convolutional Neural Network) 모델을 이용한 알고리즘 개발

- 와전류 탐상 전문가가 와전류 신호를 분석해 판단한 손상 정도를 딥러닝을 통해 학습 후, 미지의 와전류 신호로부터 손상 정도의 추정하는 비파괴평가 AI 모델
- 딥러닝 모델은 단일 채널 시계열 데이터 전처리 조건별 특성 분석, 단일 채널 시계열 데이터 딥러닝 모델 선정, 딥러닝 모델의 하이퍼 파라미터 조정을 통한 성능 최적화의 순서로 수행



와전류 탐상 시계열 데이터 딥러닝 모델 개발 과정

5. 딥러닝 적용 결과

□ Deep Learning 모델을 활용한 데이터 학습 및 진단

- 3가지 SVM 알고리즘(Polynomial, Rbf) 및 2가지 딥러닝 모델(VGG19, Xception, Inception)을 학습 및 진단에 활용하고자, 시계열 데이터에 적합하도록 2차원 연산을 모두 1차원 연산으로 변환함
- 신호처리 기법에서 사용된 Fitting:New = 9:1 (72:8) 데이터 셋을 Train:Test 데이터셋으로 활용하였고, 진단 성능은 MSE로 비교하되 학습과정에서 특이 값에 민감도를 낮추기 위해 학습 중지 시점은 Test 데이터 셋의 MAE(Mean Absolute Error)이 10회 이상의 학습 과정(Epoch)도 감소하지 않은 경우로 선정함
- 네 모델 모두 최초 Learning Rate (LR)을 0.0001을 설정하고, 5회 이상의 학습 과정(Epoch)에서도 MAE가 감소하지 않을 경우, LR을 0.5배 감소시킴

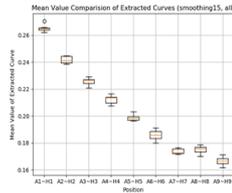
□ 진단결과

- Test 데이터에 대해 Batch Size (8, 16, 32)와 샘플링(500, 1000, 1500, 2000)에 따른 성능 차이가 나타남
- Inception (Batch Size: 8)을 활용하는 경우 Sequence Length = 2000에서 MSE가 0.00082로 가장 낮게 나타났음

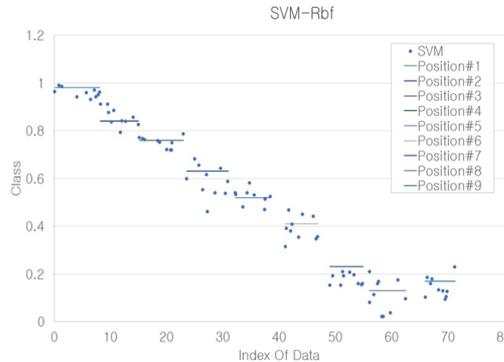
Model	VGG19			Xception			Inception		
	Number of Parameters								
	88,479,297			20,657,657			16,913,121		
Sequence Length	8	16	32	8	16	32	8	16	32
500	0.00151	0.00151	0.00173	0.00160	0.00131	0.00190	0.00224	0.00411	0.07957
1000	0.00211	0.00178	0.00205	0.00134	0.34174	0.00182	0.00098	0.00173	0.00163
1500	0.00225	0.00207	0.00231	0.00123	0.34642	0.00152	0.00106	0.00102	0.20376
2000	0.00217	0.00172	0.00416	0.00149	0.34915	0.34437	0.00082	0.00114	0.00269

□ 임의의 데이터에 대한 진단 성능 비교

- 전체 720개 데이터 중 감육 상태가 다른 데이터는 9종 각 80개씩 존재하여, 이를 임의로 Fitting:New = 9:1 (72:8)로 분리하여, 648개의 데이터로 Fitting 후 72개의 데이터에 대해 MSE (Mean Squared Error)를 산출하는 방식으로 임의의 데이터에 대한 진단 성능을 비교

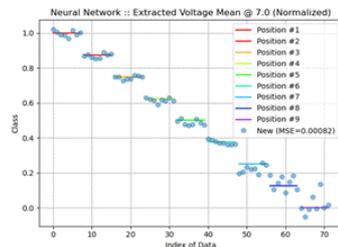
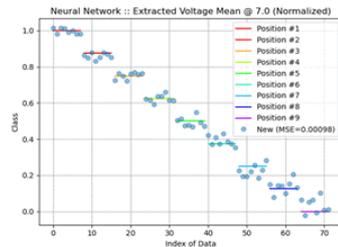
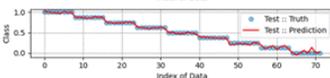
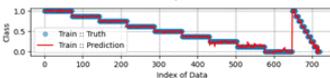
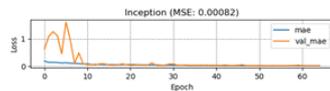
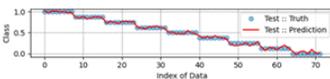
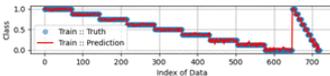
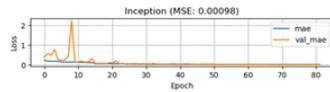


Model	SVM-Poly	SVM-RBF
Number of Parameters	14,400	14,400
Sequence Length	16	16
500	0.11058	0.10210
2000	0.12094	0.05842



○ SVM

- ▶ Position 1 ~ 6 의 배관 두께가 두꺼운 구간에서 변별력이 있음
- ▶ Position 7 ~9 에서 배관 간의 차이점을 구분하기 어려움



○ CNN

- ▶ Inception (Batch=8) 모델의 경우, 전 구간에서 시편의 두께와 일치하는 경향성을 보임
- ▶ 말단 효과가 발생하는 Edge 부분의 분류에서 SVM보다 우수한 성능을 발휘함

6. 결론



- 와전류 신호 수집이 주로 수행되는 데스크톱 PC 환경에서 PEC 신호 수집 환경의 효과와 실용성을 고려하여 호환되는 오픈 소스를 사용하여 신호 사전 처리 및 딥 러닝 알고리즘을 개발
 - ▶ 시간 지연은 두께가 다른 지점에서는 다르게 보이지만, 동일한 두께의 영역에서도 시간 지연 값이 차이가 나는 것을 확인
- 본 연구에서는 배관내측 단차 구성으로 가공된 시험편 벽두께가 감소함에 따라 진폭이 감소되고 지연이 감소함을 확인하였으나, 마지막 2개의 얇은 단차영역에서는 차이가 명확하지 않았음
 - ▶ 벽 두께로 신호를 효과적으로 분리하기 위해 SVM과 CNN 알고리즘이 적용
 - ▶ CNN은 얇은 두께 영역에서 SVM보다 더 효과적으로 두께 차이를 분리
- 종래의 특정 전압의 시간 추출 방법에 비하여
 - ▶ 동일한 Sequence Length = 1000에서 MSE를 Inception(배치 크기: 8)에서 0.00235에서 0.00098로 58.3% 감소
 - ▶ Inception(Batch Size:8)을 사용하였을 때 MSE는 Sequence Length = 2000으로 가장 낮았으며, 이는 기존의 특정 전압의 시간 추출 방법에 비해 65.1% 감소