

Performance Evaluation of Image-Based Algorithm in Pulsed Eddy Current Defect Classification Using Convolutionary Neural Network

Hyoung Tae Kim

Intelligent Accident Mitigation Research Division, KAERI, Daejeon 34057, Korea

Seong-Jin Han and Duck-Gun Park*

ALPIT Inc., Daejeon 34057, Korea

(Received 7 April 2025, Received in final form 29 April 2025, Accepted 29 April 2025)

The classification of experimental data using artificial intelligence requires the transformation of time series data into images before applying AI algorithms. This study explores defect classification in pulsed eddy current (PEC) experiments through a convolutional neural network-based AI imaging algorithm, which processes defect information presented in serial format. Time series data obtained from PEC experiments were analyzed to compare the performance of various imaging algorithms. PEC is widely employed to detect defects caused by corrosion under insulation (CUI). To simulate CUI conditions, a 10-inch-thick pipe was machined into a five-step configuration and covered with 50 mm of insulation. Five imaging algorithms—Continuous Wavelet Transform (CWT), Gramian Angular Summation Field (GASF), Gramian Angular Difference Field (GADF), Markov Transition Field (MTF), and Recurrence Plot (RP)—were evaluated. The ResNet50 neural network model was utilized to assess the performance of these algorithms using Validation Loss and Test Loss as learning indicators. Among the five imaging methods, the CWT algorithm demonstrated superior performance in defect classification. This study contributes to enhancing AI-driven defect detection techniques by evaluating different imaging transformation approaches and identifying the optimal algorithm for improved classification accuracy.

Keywords : Magnetic sensor, Pulsed eddy current, Artificial Intelligence, Convolutionary neural network, Image algorithm, Time series data

합성곱 신경망을 이용한 펄스와전류 결함분류 실험에서의 이미지화 알고리즘 성능 검증

김형태

한국원자력연구원 지능형 사고대응연구부, 대전광역시 대덕대로989번길 111, 34057

한성진 · 박덕근*

(주)아이피트, 대전광역시 대덕대로989번길 111, 34057

(2025년 4월 7일 받음, 2025년 4월 29일 최종수정본 받음, 2025년 4월 29일 게재확정)

실험 데이터를 인공지능을 활용하여 분류하는 과정에서 시계열 데이터를 이미지로 변환한 후 AI 알고리즘을 적용하는 것이 필수적이다. 본 연구에서는 펄스 와전류(PEC) 실험에서 결함을 효과적으로 분류하기 위해 컨볼루션 신경망 기반 AI 이미지 알고리즘을 사용하였다. PEC 실험을 통해 획득한 시계열 데이터를 활용하여 다양한 이미지 변환 알고리즘의 성능을 비교하였다. PEC 기술은 절연체 하의 부식(CUI)으로 인해 발생하는 결함을 감지하는 데 사용되며, 이를 모사하기 위해 10인치 두께의 배관을 5단계 계단 형상으로 가공한 후 50 mm 두께의 단열재를 적용하였다. 본 연구에서는 연속 웨이블릿 변환(CWT), 그래미안 각도 합산 필드(GASF), 그래미안 각도 차이 필드(GADF), 마르코프 전이 필드(MTF), 순환 플롯(RP) 등 다섯 가지 이미지 변환 알고리즘

즘을 평가하였다. ResNet50 신경망 모델을 활용하여 Validation Loss 및 Test Loss를 학습 지표로 삼아 각 알고리즘의 성능을 분석하였다. 분석 결과, CWT 알고리즘이 결합 분류에서 가장 우수한 성능을 보임을 확인하였다. 본 연구는 AI 기반 결합 검출 기술의 정확도를 향상시키기 위한 다양한 이미지 변환 접근법을 비교하고 최적의 알고리즘을 도출하는 데 기여할 것으로 기대된다.

주제어 : 자기센서, 펄스와전류, 인공지능, 합성곱 신경망, 이미지화 알고리즘, 시계열 데이터

I. 서 론

코일의 전류를 변화시키면 부근에 존재하는 도전체에 자계 변화를 방해하는 방향으로 와전류(eddy current)가 발생한다. 와전류의 크기와 발생 시간은 도전체의 전자기적 성질(전기 저항율, 투자율)과 형상에 의존한다. 이 와전류가 만드는 자계를 측정하여 전자기적 성질이 일정한 경우에 대상 물체의 형상이나 두께를 추정할 수 있다. 이러한 원리를 이용하여 펄스와전류(Pulsed Eddy Current, PEC)[1,2]를 비롯한 와전류 시험이 사용되고 있다. 특히, 펄스와전류 시험에서는 자기화에 수십 mA와 수십~1,000 kHz의 연속파를 이용하며 펄스상의 자기화전류를 이용하는 자기센서에 의해 와전류의 감쇠를 관측하여 주파수 성분 또는 시간 축을 평가한다. 따라서, 펄스와전류 시험은 보존재 배관이나 이면 결합 등 기존의 와전류가 접근하기 힘든 곳을 측정하는데 널리 사용된다. 그러나 펄스와전류는 기존의 와전류에 비하여 낮은 해상도가 문제가 되며, 최근 인공지능의 발달은 이러한 문제를 해결하는 데 많은 도움이 된다. 센서융합 및 분류 문제 등에 널리 사용되는 인공지능 기법은 합성곱 신경망(Convolutional Neural Networks, CNN)[3] 기반으로, 이는 이미지 데이터를 해석하는데 특화되어 있다. 따라서, 펄스와전류 신호는 시계열 데이터(time series data)로서 이미지 기반의 CNN 기법을 사용하기 위해서 시계열 데이터를 2차원 이미지 데이터로 변환하는 것이 필요하다. 시계열을 이미지로 표현할 수 있다면 CNN 뿐만 아니라 이미지 인식에 사용되는 다양한 알고리즘들을 시계열 데이터에도 적용할 수 있기 때문에 유용하다. 그러나 시계열 데이터의 정보를 손실하지 않으면서 이미지로 표현하는 일은 쉽지 않다. 시계열 데이터를 이미지 데이터로 변환하는 방법은 CWT(Continuous Wavelet Transform)[4], GAF(Gramian Angular Field)[5,6], MTF(Markov Transition Field)[7], RP(Recurrence Plot)[8,9] 등 여러 가지가 나와 있으나 원신호의 특성에 따라 적용성에는 차이가 있다.

시계열 데이터란 일정 시간 간격으로 배치된 데이터들의 수열 형태를 의미하며, 예로 특정 센서에서 일정한 시간 간격으로 수집되는 RF 신호나 혹은 생체 신호 등 시간적 순서에 따른 데이터를 의미한다. 이러한 시계열 데이터는 송신되는 신호의 종류, 수신 환경 및 조건에 따라 신호의 세기 혹은 신호 파형 등 다양한 시각적 형태로 나타날 수 있다. 이러한

시계열 데이터의 특징 분석 및 시간적 변화를 기계학습에 적용한 데이터의 검출 및 분류 그리고 예측 알고리즘에 관한 많은 연구가 진행되고 있다[10,11]. 특히 시계열 데이터를 이용한 딥러닝 연구가 많이 연구되고 있으며, 그중 시계열 데이터 변환 알고리즘을 이용해 데이터 전처리 및 변환을 진행한 후, 딥러닝을 적용한 방식이 주목받고 있다. 대표적으로 시계열 데이터 간의 상대적인 위치를 계산하여 1차원 시계열 데이터를 2차원 데이터로 변환하는 상대 위치 행렬(Relative Position Matrix) 알고리즘을 CNN과 연계하는 방식이 있으며[11], 또 다른 방법으로는 다변량 시계열 데이터를 차원 축소하여 2차원의 RGB 이미지로 인코딩하여 CNN 학습에 이용하는 방식이 연구되었다.

본 연구에서는 펄스와전류 실험에서 획득한 신호를 CWT(연속 웨이블릿 변환), GAF, MTF, RP 등의 알고리즘을 사용하여 이미지 데이터로 변환하여 각 알고리즘의 특성을 비교하여 보았다. 본 논문에서 제안하는 방식은 시계열 이미지화 알고리즘을 통해 변조 신호의 특징을 효과적으로 시각화하였으며, 변환된 데이터를 입력 데이터로 이용하여 ResNet50[12] 기반의 CNN 모델의 학습을 진행하였다. 펄스와전류 신호는 기존 연구[13]에서 획득된 펄스와전류 신호 중 적분 신호와 플럭스게이트 신호를 이용하였다.

II. 이미지화 알고리즘

1. 웨이블릿 변환(Wavelet Transform)

푸리에 변환이 시간에 대한 변화를 주파수에 대한 변화로 확장하는 반면, 시간 축에 대한 정보가 사라지는 단점을 보완하기 위하여 단시간 푸리에 변환(Short Term Fourier Transform, STFT)을 거쳐 웨이블릿 변환(Wavelet Transform, WT)이 나왔으나, 이는 신호를 윈도우 길이에 따라서 분리시키기 때문에 푸리에 변환에 사용되는 신호의 길이를 감소시키고 이에 따라 주파수 분해능이 악화된다. 그렇다고 윈도우 길이를 증가시켜 주파수 분해능을 향상시켜도 시간 분해능은 반대로 악화된다[14]. 이러한 주파수와 시간의 상충 관계(trade-off)로 인한 분해능의 한계를 극복하기 위해 웨이블릿 변환이 등장했다. 웨이블릿 변환은 시간-주파수 관계를 동시에 볼 수 있기 때문에 시계열 데이터를 2차원 이미지 형식으로 변환하는 인공지능 기법에도 널리 사용된다.

$$T(a, b) = \frac{a}{\sqrt{a}} \int_{-\infty}^{\infty} x(t) \Psi^* \left(\frac{t-b}{a} \right) dt \quad (1)$$

으로 주어진다. 여기서 Ψ^* 는 창 함수이며, 원래의 파형 모양에 따라 Daubechies, Haar, Coiflets 등 여러 함수들이 사용된다[15].

2. Gramian Angular Field (GAF) 알고리즘

그라미안 각도 필드(GAF)는 각 시점 간의 시간적 상관 관계를 극좌표를 기반으로 표현하는 알고리즘이다[7]. 극좌표 기반 행렬은 시계열 데이터를 이미지로 변경할 때 시간 상관관계를 보존할 수 있다는 장점이 있다. GAF는 먼저 주어진 시계열 데이터 값이 너무 크거나 작을 수 있으므로 $[-1, 1]$ 혹은 $[0, 1]$ 구간으로 정규화시킨다. 정규화된 신호 $\tilde{x}_i$ 의 시간 인덱스 t_i 를 반지름 r_i 로 표현하며, 각도와 함께 다음과 같이 극좌표로 변환한다.

$$\begin{cases} \phi_i = \arccos(\tilde{x}_i), -1 \leq \tilde{x}_i \leq 1, \text{ and } \tilde{x}_i \in X \\ r_i = \frac{t_i}{N}, t_i \in N \end{cases} \quad (2)$$

여기서 N 은 극좌표계의 범위에 대한 정규화 상수이다. GAF는 각도의 합과 차에 따라 두 가지 방식으로 나뉜다. 그라미안 각도 합산 필드(Gramian Angular Summation Field, GASF)[16]는 i 와 j 의 시간 쌍으로 이루어진 극좌표계 시계열 데이터의 각도의 합으로 나타내며, 다음 식(3)과 같이 정의한다.

$$GASF = [\cos(\theta_i + \theta_j)] = \tilde{x}' \bullet \tilde{x} - \sqrt{I - \tilde{x}'^2} \bullet \sqrt{I - \tilde{x}^2} \quad (3)$$

그라미안 각도 차이 필드(Gramian Angular Difference Field, GADF)[15]는 GASF와 반대로 극좌표계의 각도의 차이로 다음 식(4)와 같이 정의한다.

$$GADF = [\sin(\theta_i + \theta_j)] = \sqrt{I - \tilde{x}'^2} \bullet \tilde{x} - \tilde{x}' \bullet \sqrt{I - \tilde{x}^2} \quad (4)$$

GAF는 왼쪽 상단에서 오른쪽 하단으로 이동함에 따라 시간이 증가하기 때문에 시간 종속성을 보존한다. 주 대각선은 원시 데이터의 값과 각도 정보를 포함하기 때문에 이를 이용하여 원시 데이터를 복구할 수 있다.

3. Markov Transition Field (MTF) 알고리즘

마르코프 전이 필드(MTF) 알고리즘은 이산화한 시계열 데이터의 전이 확률을 나타내는 알고리즘이다[17]. MTF를 구성하기 위해 주어진 시계열 데이터 집합 X 를 값에 따라 여러 개의 Q 구간으로 나눈 뒤, 시간 인덱스 t_i 의 시계열 데이터 값 x_i 에 맞는 구간 $q_i (i \in [1, Q])$ 에 배정한다. 시간 축을 따

라 1차 마르코프 체인 방식으로 $Q \times Q$ 크기의 가중치 인접 행렬 W 를 구성한다.

$$W = \begin{bmatrix} w_{11} | P(x_i \in q_1 | x_{i-1} \in q_1) \cdots w_{1Q} | P(x_i \in q_1 | x_{i-1} \in q_Q) \\ w_{21} | P(x_i \in q_2 | x_{i-1} \in q_1) \cdots w_{2Q} | P(x_i \in q_2 | x_{i-1} \in q_Q) \\ \vdots \\ w_{Q1} | P(x_i \in q_Q | x_{i-1} \in q_1) \cdots w_{QQ} | P(x_i \in q_Q | x_{i-1} \in q_Q) \end{bmatrix} \quad (5)$$

$w_{i,j}$ 는 q_i 구간에서 q_j 구간으로 전이하는 빈도를 나타낸다. W 의 각 열의 합을 1로 정규화함으로써 마르코프 전이 매트릭스를 구성할 수 있다. 이 과정에서 W 는 X 의 분포와 시간 인덱스 t_i 에 대한 시간 종속성이 제거된다. 이러한 W 의 정보 손실을 극복하기 위해, 시간 순서를 따라 각 확률을 정렬하여 MTF를 다음과 같이 정의한다.

$$M = \begin{bmatrix} M_{11} M_{12} \cdots M_{1n} \\ M_{21} M_{22} \cdots M_{2n} \\ \vdots \\ M_{n1} M_{n2} \cdots M_{nn} \end{bmatrix} = \begin{bmatrix} w_{ij} | x_1 \in q_i, x_1 \in q_j \cdots w_{ij} | x_1 \in q_i, x_n \in q_j \\ w_{ij} | x_2 \in q_i, x_1 \in q_j \cdots w_{ij} | x_2 \in q_i, x_n \in q_j \\ \vdots \\ w_{ij} | x_n \in q_i, x_1 \in q_j \cdots w_{ij} | x_n \in q_i, x_n \in q_j \end{bmatrix} \quad (6)$$

MTF의 i 행 j 열 값인 $M_{ij} | |i-j| = k$ 는 시간 인덱스 t_i 일 때의 데이터 값이 속한 구간 q_i 에서 시간 인덱스 t_j 의 데이터 값이 속한 구간인 q_j 로 전이할 확률, 즉 두 시간의 차이가 k 인 지점 간의 전이 확률을 나타낸다. 구간의 너비가 크면 대부분의 값을 평균에 가장 가까운 구간으로 집계하고, 구간의 너비가 작으면 극한 구간에서 값이 작아진다.

4. Recurrence Plot (RP) 알고리즘

순환플롯(RP) 알고리즘은 2차원에 데이터 값의 회귀를 표현함으로써 m 차원 위상 공간 궤도를 탐색하는 것을 목표로 하는 시각화 알고리즘이다[9,18]. 시계열 데이터의 m 차원 공간 궤적을 구한 후, m 차원 궤적과 시간에 따른 거리의 차를 이용해서 거리 행렬을 구한다. 모든 조합의 거리 행렬을 기록한 것을 RP 행렬이라고 부른다. 본 논문에서 고려하는 시계열 데이터는 n 개의 시간 인덱스에 따른 값으로 이루어진 집합으로 정의하며, 이때 주어진 시계열 데이터의 공간 궤적을 다음 식(7)과 같이 나타낼 수 있다.

$$\vec{x}_i = [x_i, x_{i+\tau}, \dots, x_{i+(m-1)\tau}] \quad (7)$$

이때, m 은 궤적의 차원, τ 는 지연시간, 그리고 i 는 1부터 $n - (m-1)\tau$ 까지의 인덱스 값이다. RP 행렬 $R_{i,j}$ 는 i 와 j 의 시간 쌍으로 이루어진 벡터이며, 식(8)과 같이 정의할 수 있다.

$$R_{i,j} = \theta\{\varepsilon - \|\vec{x}_i - \vec{x}_j\|\} \quad (8)$$

이때, θ 는 단위 계단 함수이며, ε 은 임계값을 의미한다. RP는 궤적의 회귀를 이용하기 때문에 시계열 데이터의 주기성 혹은 순환적으로 값이 크게 변하는 데이터에 대해서도 특

정 정보를 잘 추출한다. 또한, 궤적의 유사도에 따라 데이터 값 간의 연관성을 알 수 있고, 데이터의 종류에 따라 적절한 임계값을 설정함으로써 딥러닝의 학습 성능을 향상시킬 수 있다[19].

III. 펄스와전류 신호에 이미지화 알고리즘 적용

1. 보온재 배관에서 펄스와전류 시험

딥러닝 알고리즘을 이용하여 펄스와전류 신호를 해석하기 위하여 원통형 시험편에서 측정된 펄스와전류 신호를 이용하여 각각의 이미지화 알고리즘의 효율을 비교하였다.

펄스와전류 실험은 Fig. 1에 나타난 바와 같이 내부에 계단식 단차를 가공한 직경 10인치의 배관에 50 mm 두께의 보온재를 둘러싸고 보온재 위에서 측정하였으며, 실험의 상세한 내용은 이전 연구가 수록된 참고문헌[13]에 소개하였다. 이 실험에서는 90도 간격으로 4곳의 위치에서 각각 50회씩 측정하여 총 2,000개의 신호를 획득하였다. 보온재에 둘러싸인 배관 두께 측정을 위해, 5 단계의 두께를 가진 탄소강 배관을 Fig. 1과 같이 준비하였다. 0.5 mm 두께의 스테인레스 크래딩 안에는 50 mm 두께의 플라스틱 보온재가 ASTM A106 Grade B 소재의 직경 10 인치 배관을 둘러싸고 있다. 배관의 총 길이는 1500 mm이며, 300 mm의 등간격으로 두




Fig. 1. (Color online) Test section of the insulated pipe (diameter of 10 inch) in the PEC experiment. (Specimen was machined as step configuration to simulate the corrosion under insulation in the pipe).




Fig. 2. (Color online) Typical PEC signal (a) integrated coil sensor signal (b) flux gate sensor signal. (PEC signal were measured with coil and flux gate sensor which is represented as an integrated and differential form).




Fig. 3. (Color online) Time series feature representation by (a) CWT, (b) GASF, (c) GADF, (d) MTF, and (e) RP.

께가 14.4 mm, 12.24 mm, 10.08 mm, 7.92 mm, 5.76 mm으로 단계적으로 줄어들도록 가공하였다. 펄스와전류 신호는 Fig. 2의 (a) 코일에서 나온 적분 신호(integrated signal)와 (b) 플럭스 게이트 센서 신호(flux gate signal)를 이용하였다.

Fig. 3의 (a)와 (b)는 각각 이미지 신호로 변환하기 전의 적분 신호와 플럭스 게이트 시계열 신호에 대하여 위에서 설명한 서로 다른 5가지의 이미지화 알고리즘을 적용하여 얻은 결과들이다. 이미지화 결과 MTF를 제외하고 나머지 알고리즘에 의한 결과는 신호의 세기가 이미지의 색으로 반영된 것을 볼 수 있다. 또한 CWT의 결과를 제외하고 플럭스 게이트 센서 신호의 노이즈가 상대적으로 심한 100 ms 이후부터의 신호가 이미지에 나타났다. 배관 감육의 정도가 달라짐에 따라 적분 신호는 플럭스 게이트 센서 신호의 세기에 영향을 받으며, 이 플럭스 게이트 센서 신호는 특정 구간 신호

의 기울기에 영향을 받기 때문에[3] 주파수 성분과 그 세기를 나타내는 CWT에서 감육에 의한 차이가 두드러지게 나타났다.

본 연구에서는 펄스와전류를 이용한 보온재 배관 결함탐지에 적용하기 위해 서로 다른 이미지화 알고리즘들로부터 얻은 이차원 이미지 변환 결과들(Fig. 3)을 이용하여 인공지능 학습에 적용하였다.

2. 데이터셋 생성

10,000개의 시계열 데이터를 5가지 이미지화 알고리즘을 통해 총 10,000개의 이미지로 변환하였다. 인공지능 학습에 들어가기 전에 2,000개의 이미지에서 학습:검증:시험의 비율이 7:2:1이 되도록 무작위로 분류하여 데이터셋을 생성했다. 한 가지 알고리즘당 총 5번의 학습을 수행했으며, 특정 데이터가 어느 쪽으로도 편중되지 않게 매 학습마다 무작위 데이터셋을 새로 만드는 단계부터 시작했다. 이미지화 알고리즘의 효율을 검증하기 위하여 정확도의 척도로서 모델이 훈련 데이터에 대해 올바르게 예측한 비율을 의미를 표시하는 Train Accuracy(훈련 정확도), 훈련 과정에서 모델이 검증 데이터에 대해 올바르게 예측한 비율을 나타내는 Validation Accuracy(검증 정확도), 그리고 모델이 학습 후 테스트 데이터에서 올바르게 예측한 비율을 나타내는 Test Accuracy(테스트 정확도)를 측정 하였으며, 모델이 검증 데이터에 대해 출력한 예측값과 실제 정답 사이의 차이를 나타내기 위하여 Train Loss(훈련 손실), 모델이 검증 데이터에 대해 출력한 예측값과 실제 정답 사이의 차이를 나타내는 Validation Loss(검증 손실)과, 테스트 데이터에서 출력한 예측값과 실제 정답 사이의 차이를 나타내기 위하여 Test Loss(테스트 손실)을 사용하였다.

3. 인공지능 모델

이미지넷(ImageNet)[20]과 같이 아주 큰 데이터 셋을 이용해서 직접 이미지 분류기를 훈련시키는 것은 상당히 많은 시간이 소요되며 쉽지 않다. 따라서 이미지넷 데이터베이스의 1백만 개가 넘는 영상에 대해 훈련된 신경망의 사전 훈련된 버전을 불러와서, 그것을 각자의 목적에 맞게 업그레이드시켜서 사용하게 된다. 즉 훈련된 가중치들을 가지고 와서 그 가중치들을 목적에 맞게 새롭게 미세 조정(fine-tuning)을 한다.

본 연구에서는 거대한 데이터셋인 이미지넷에서 미리 훈련된 ResNet50[12]을 이용해서 펄스와전류 측정 신호로부터 얻은 결함 이미지들을 분류하였다. ResNet(Residual Network)은 신경망이 깊어질수록 발생하는 기울기 소실 문제(vanishing gradient problem)를 해결한 것으로 매우 깊은 신경망을 효과적으로 학습시킬 수 있다. 따라서 기존의 심층 네




Fig. 4. (Color online) Structure of ResNET50.

트위크에서 발생하는 과적합(over-fitting)이나 학습 실패 문제를 줄일 수 있다. 이중에서 ResNet50은 50개 계층으로 구성된 합성곱 신경망이다(Fig. 4).

4. 인공지능 학습 결과

주어진 PEC 시험 결과를 인공지능으로 학습시에 CWT, GASF, GADF, MTF, 및 RP 등 알고리즘 등을 사용하여 이

미지 데이터로 변환하여 시험한 결과를 Table I에 표시하였다. 이 표에서 검증 손실은 모델을 학습하는 동안, 학습 데이터가 아닌 검증 데이터를 사용하여 계산을 수행하며, 모델이 새로운 데이터에 대해 얼마나 잘 일반화되는지를 평가하는 데 사용된다. 테스트 손실은 모델 학습이 완료된 후, 테스트 데이터를 사용하여 계산한 것이다. 이 값은 모델의 최종 성능을 평가하는 데 사용되며, 실제 환경에서 모델이 얼마나 잘

Table I. Performance evaluation results of different image-based algorithms for PEC defect classification using CNN.

Test No.	Train accuracy	Validation accuracy	Test accuracy	Train loss	Validation loss	Test loss
CWT_01	1.000000	0.990000	1.000000	0.003978	0.039869	0.004603
CWT_02	1.000000	0.985000	1.000000	0.000185	0.041449	0.001375
CWT_03	1.000000	0.970000	0.990000	0.000235	0.077668	0.011448
CWT_04	1.000000	0.980000	1.000000	0.001670	0.033858	0.003305
CWT_05	1.000000	0.965000	0.990000	0.000236	0.111799	0.033451
GASF_01	1.000000	0.945000	0.970000	0.003930	0.172700	0.073221
GASF_02	1.000000	0.950000	0.950000	0.003258	0.188329	0.068447
GASF_03	0.995714	0.945000	0.980000	0.025817	0.174351	0.083185
GASF_04	0.997143	0.0940000	0.950000	0.023620	0.233243	0.100961
GASF_05	1.000000	0.965000	0.950000	0.001414	0.164556	0.103915
GADF_01	1.000000	0.975000	0.970000	0.000689	0.098340	0.051185
GADF_02	1.000000	0.960000	0.970000	0.000370	0.099628	0.051903
GADF_03	1.000000	0.970000	0.980000	0.003935	0.093364	0.070134
GADF_04	1.000000	0.965000	0.970000	0.011957	0.118128	0.067945
GADF_05	0.998571	0.955000	0.950000	0.015272	0.131853	0.110124
MTF_01	0.802857	0.450000	0.460000	0.468434	1.406624	1.571996
MTF_02	0.915714	0.540000	0.500000	0.268936	1.270835	1.430008
MTF_03	0.888571	0.575000	0.480000	0.308199	1.272887	1.396800
MTF_04	0.645714	0.505000	0.510000	0.910787	1.396989	1.365370
MTF_05	0.857143	0.540000	0.520000	0.388421	1.212362	1.407177
RP_01	1.000000	0.980000	0.980000	0.001855	0.085707	0.049096
RP_02	0.995714	0.990000	0.980000	0.019505	0.058012	0.032622
RP_03	1.000000	0.995000	0.990000	0.001055	0.046751	0.011192
RP_04	0.994286	0.980000	0.990000	0.026327	0.066593	0.039558
RP_05	0.995714	0.980000	1.000000	0.030838	0.067115	0.029619

작동할지를 나타낸다. 따라서 검증 손실은 학습 중간에 모델의 성능을 모니터링하기 위해 사용되며, 테스트 손실은 최종 평가를 위해 사용된다. 검증 손실이 낮아지면 모델이 잘 학습되고 있음을 의미하지만, 테스트 손실이 높다면 모델이 과적합되었을 가능성이 있음을 나타낸다. Table I에서 보듯이 웨이블릿 변환(CWT)이 검증 손실과 테스트 손실이 가장 작았으며, MTF가 가장 큰 값을 보여준다. 웨이블릿 변환은 인공지능 학습이 나타나기 전에 신호처리 분야에서 오랫동안 사용되어 왔으며, 신호의 시간적 분포와 공간적 분포를 동시에 나타낼 수 있으며, 일정 시간에서 신호의 에너지를 동시에 표현할 수 있기 때문에 신호의 물리적 의미를 가장 잘 표현할 수 있었다.

IV. 맺음말

실험에서 얻어진 시계열 데이터를 인공지능으로 학습하여 결합 및 오류 등을 탐지할 경우, 1차원 시계열 데이터를 2차원 이미지 데이터로 변환하여 이미지 기반의 학습알고리즘을 사용한다. 본 연구에서는 펄스와전류 실험에서 얻어진 결합 신호의 시계열 데이터를, CWT, GASF, GADF, MTF, 및 RP 등의 5종류 이미지화 알고리즘을 사용하여 결합분류 효율을 구하였다. 결합 분류 효율을 나타내는 파라미터로서 검증 손실과 테스트 손실을 이용하여 평가한 결과, CWT 알고리즘이 최상의 결합분류 효율을 보여준다는 것을 확인하였다.

감사의 글

본 연구는 중소벤처기업부의 “자기영상 기술을 이용한 원자로 제어봉 집합체 손상평가 장비 개발(RS-2025-02305452)” 및 “원전 종사자의 안전환경 모니터링용 IoT 기반 휴대용 방사선 측정기 개발(RS-2023-00270278)”, 그리고 “경수형 SMR철제 격납용기 건전성 규제기반기술개발(RS-2025-02314096)” 과제의 연구비 지원으로 수행되었습니다.

References

- [1] D.-G. Park, M. K. Babu, and D. H. Lee, Trans. KPVP **10**, 90 (2014).
- [2] D.-G. Park, S. Kim, and M. K. Babu, Development of pulsed eddy current technology for the manufacture of wall thinning evaluation equipment, KAERI Research Report, KAERI/RR-3863/2014, Korea (2014).
- [3] <https://ko.wikipedia.org/wiki/%ED%95%A9%EC%84%B1%EA%B3%B1>
- [4] A. Benyahia, M. Zergoug, M. Amir, and M. Fodil, J. IJCIT **12**, 116 (2018).
- [5] J. Fan, J. Wen, and Z. Lai, J. Sens. **23**, 2715 (2023).
- [6] A. C. Buz, M. U. Demirezen, and U. Yavanoglu, J. GJES **7**, 1 (2021).
- [7] Z. Wang and T. Oates, Encoding time series as images for visual inspection and classification using tiled convolutional neural networks, Workshop at AAAI-15, Austin Texas, USA (2015).
- [8] B. Medghalchi and A. Vogel, J. Eng. Appl. Artif. Intell. **133**, Part F (2024).
- [9] J. P. Eckmann, S. O. Kamphorst, and D. Ruelle, J. EPL **4**, 973 (1987).
- [10] B. W. Lee, W. C. Lee, S. W. Chae, D. H. Kim, and C. K. Lee, J. Korean Inst. Smart Media **9**, 162 (2020).
- [11] J.-H. Seon, J. JIIBC **21**, 183 (2021).
- [12] K. He, X. Zhang, S. Ren, and J. Sun, Deep Residual Learning for Image Recognition, Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit., Las Vegas, NV, (2016) pp. 770~778.
- [13] H. T. Kim, S. J. Han, J. W. Shin, and D.-G. Park, J. KSNT **43**, 468 (2023).
- [14] <https://m.blog.naver.com/dusrnwk/221799478508>
- [15] H. Lee, S. Song, Z.J. Hua, M. Lee, and C. Yoo, J. Korea Water Resour. Assoc. **20**, 575 (2019).
- [16] I. Mitiche, G. Morison, A. Nesbitt, M. Hughes-Narborough, B. G. Stewart, and P. Boreham, J. Sens. **18**, 3098 (2018).
- [17] W. Sun, J. Zhou, B. Sun, Y. Zhou, and Y. Jiang, J. Micromachines **13**, 873 (2022).
- [18] H. Lee, J. Lee, and M. Shin, J. Electron. **8**, 192 (2019).
- [19] J.-Y. Park, D.-H. Seo, and H.-W. Nam, J. Korea Inst. Electromagn. Eng. Sci. **32**, 328 (2021).
- [20] A. Krizhevsky, I. Sutskever, and G. E. Hinton, J. CACM **60**, 84 (2017).