

개선된 특징 추출을 이용한 원전SG 세관 결함 패턴 분류에 관한 연구

A Study on the Classification of Steam Generator Tube Defects Using an Improved Feature Extraction

조남훈*[†], 이향범*

Nam-Hoon Jo*[†] and Hyang-Beom Lee*

초 록 본 논문에서는 개선된 특징추출을 이용한 원자력 발전소 증기발생기 세관의 결함 형태 분류에 대한 연구를 수행한다. 본 논문에서는 4가지 축대칭 결함, 즉 I-In 형태, I-Out 형태, V-In 형태, V-Out 형태 결함을 고려한다. 유한요소법에 기초한 수치해석 프로그램을 이용하여 결함의 폭과 깊이를 변화시켜가면서 400개의 와전류탐상시험(ECT) 신호를 생성하였다. 이와 같이 생성된 ECT 신호로부터 새로운 특징을 제안하였는데, 여기에는 최대 임피던스 값을 갖는 점과 최대 임피던스 값의 1/2의 값을 갖는 점 사이의 위상각과 최대임피던스 값을 갖는 점과 최대 임피던스 값의 10%, 20%, 30%, 40%를 갖는 점사이의 위상각들이 포함된다. 또한, 결함형태를 분류하기 위하여 은닉층이 하나인 다층퍼셉트론을 사용하였다. 컴퓨터 모의실험 연구를 통하여 제안된 방법이 최대오차와 평균제곱오차 측면에서 향상된 결함 분류 성능을 얻는다는 것을 보였다.

주요용어: 와전류탐상시험, 원전SG 세관, 신경회로망, 특징추출

Abstract In this paper, we study the classification of steam generator tube defects using an improved feature extraction. We consider 4 axisymmetric defect patterns of tube: I-In type, I-Out type, V-In type, and V-Out type. Through numerical analysis program based on finite element modeling, 400 ECT signals are generated by varying width and depth of each defect type. From those generated ECT signals, we propose new feature vectors that include an angle between the two points where the Maximum impedance and half the Maximum impedance, and angles between Maximum impedance point and 10%, 20%, 30%, 40% of Maximum impedance points. Also, multi-layer perceptron with one hidden layer is used to classify the defect patterns. Through the computer simulation study, it is shown that the proposed method achieves an improved defect classification performance in terms of Maximum Error and mean square Error.

Keywords: Eddy Current Testing(ECT), Steam Generator(SG) Tube, Neural Network, Feature Extraction

1. 서 론

원자력 발전소 증기발생기 세관은 증기를 발생시켜 터빈 발전기를 돌리는 동시에 방사능 차단벽으로서 중요한 기능을 하고 있다. 증기발생기 세관은

원전 수명관리에 큰 영향을 미치고 있으며, 따라서 세관 결함을 검출하기 위한 신뢰할만한 검사법의 개발이 매우 중요하다. 원자력 발전소 증기발생기 세관 검사에 사용되는 대표적인 비파괴검사법으로 와전류탐상시험(eddy current testing: ECT)방법이

있다. 와전류탐상시험(ECT)은 도체에 와전류를 유도하여 이상 존재시 분포가 변하는 것을 코일의 임피던스를 측정하여 관찰함으로써 검사체의 이상 유무를 판단하는 비파괴검사 방법이다. 와전류탐상시험방법에서는 결함의 유무 및 정도를 파악하기 위하여 검사신호를 정확하게 해석할 수 있어야 한다. 또한, 검사신호의 정확한 해석이 가능하려면, 결함의 종류 및 정도, 주변 상황에 따라 어떤 형태 및 크기의 신호가 발생되는지에 대한 사전 경험이나 지식이 축적되어 있어야 한다. 그러나, 이러한 중요성에도 불구하고, 현재 국내 원전에서 실시되고 있는 비파괴검사 기술은 그 신뢰성이 검사 장비와 작업자에 전적으로 의존하는 실정이다. 이러한 상황에서는 실제 검사시 과연 어떠한 것이 최적 검사 조건인지, 그리고 현재의 탐상 조건에서 예견되는 결함 검출능력이 얼마나 되는지 등 비파괴검사의 신뢰성에 대한 가장 근본적인 의문을 해결하는 데에는 한계를 가지고 있다. 이러한 한계를 극복하기 위해서 전세계적으로 크게 두 가지 방향의 연구가 수행되고 있다. 첫 번째는 비파괴탐상 장비가 출력으로 제공하는 검사 신호를 이론적으로 예측하는 기술, 즉 비파괴탐상시험 모델링 기법의 개발이고 [1-4], 두 번째는 비파괴탐상 장비의 출력신호를 분석하여 결함의 크기, 종류, 크기 등을 자동적으로 결정하는 지능형 신호해석 기술의 개발이다[5-10]. 특히, 지능형 신호해석 기술 개발을 위해서는, 탐상 신호로부터 결함의 종류, 크기 등을 정확하게 구별할 수 있는 특징(feature) 추출도 매우 중요한 연구 분야 중의 하나이다.

최근에 참고문헌[7]에서 2차원 축대칭결함에 대해서 수치해석 기법을 이용하여 생성한 ECT 신호에 대한 결함평가를 수행하였다. 이 연구에서는 4가지 결함형태, 즉 I형 관내벽 결함(I-In type), I형 관외벽 결함(I-Out type), V형 관내벽 결함(V-In type), V형 관외벽 결함(V-Out type)을 고려하였는




Fig. 1 The I-shaped flaw in the outer diameter (IO type) and the V-shaped flaw in the outer diameter (VO type)

데, Fig. 1은 4가지 결함 중 I-Out 결함과 V-Out 결함 형태를 나타낸다.

참고문헌[8]에서는 새로운 특징추출을 제안하여 [7]에서 제시한 결함패턴 분류기의 분류성능을 향상시켰다. 즉, [7]에서는 전술한 4가지 결함패턴을 분류하기 위해서 11개의 특징을 이용하였던 것과 비교하여, [8]에서는 새로운 방식으로 3개의 특징을 추출하여 사용할 것을 제안하였다. 또한, 전술한 4가지 결함에 대해서, [8]에서 제시한 방법은 [7]의 방법보다 향상된 분류 성능을 갖는 것을 컴퓨터 모의실험을 이용하여 입증하였다.

본 논문은 참고문헌[7,8]에서 고려한 4가지 축대칭 결함 분류성능을 보다 향상시키는 것을 목적으로 한다. 참고문헌[8]에서는 일반적으로 세 가지 특징을 사용하여 결함형태를 분류하였는데, 본 논문에서는 보다 향상된 결함 분류를 위해서 [8]에서 제안한 방식을 더욱 일반화한 7개의 특징을 사용하고자 한다. 신경회로망의 학습 및 평가에 사용하는 목표값(target)과 신경회로망 출력값의 차이를 오차라고 하는데, 이러한 오차가 작을수록 분류성능이 더욱 우수한 것으로 간주된다. 본 논문에서는 참고문헌 [8]에서의 분류성능을 보다 개선하여 이러한 오차를 더욱 줄이고자 한다. 이러한 연구를 통하여, 신호회독과정에서 필연적으로 존재하는 잡음 등에 의한 분류성능 저하를 방지할 수 있을 것으로 기대된다.

본 논문의 구성은 다음과 같다. 2장에서는 결함 분류 성능을 향상시키기 위하여 새로운 특징벡터를 제시한다. 3장에서는 결함형태 분류기로 사용되는 신경회로망의 일종인 다층퍼셉트론(multilayer perceptron; MLP)에 대해서 기술한다. 4장에서는 제시한 새로운 특징추출을 이용한 기법이 기존의 방법과 비교하여 우수한 분류 성능을 갖는다는 것을 컴퓨터 모의실험을 통하여 입증하며, 5장에서는 본 논문의 결론을 제시한다.

2. 결함 형태 분류를 위한 개선된 특징 추출

신경회로망을 이용하여 결함 형태를 분류하기 위해서는 분류기를 학습시키는데 충분한 량의 와전류 결함신호 표본들이 필요하다. 이를 위하여 참고문헌[7,8]과 같은 방식으로 I형 결함 100개와 V형 결함 100개에 동일한 수의 와전류 탐상시험 신호를 생성하였다. 즉, 결함의 종류를 형상에 따라 2가지

(I/V-type), 위치에 따라 2가지 (In/Out) 총 4가지로 구분하였다. 그 후, 각 범주에 속한 결함의 크기(폭과 깊이)를 다양하게 변화시킨 후, 각 결함에 대해 와전류탐상 주파수를 2가지(100 kHz/400 kHz)로 변화시켜 가면서 I-type 결함에 대해서 200개, V형 결함에 대해서 200개의 결함신호를 생성하였다. 여기서, 결함의 깊이는 0.1, 0.2, ~, 1.0 mm의 값을 사용하였고, 결함의 폭은 0.2, 0.4, 0.6, 0.8, 1.0 mm의 값을 사용하였다.

결함신호의 패턴 분류 및 결함크기 산정을 위해서 기존의 연구결과 [7]에서는 ECT 결함신호의 특징 11가지(최대 저항값, 최대 저항값을 갖는 점의 위상, 최대 리액턴스 값, 최대 리액턴스 값을 갖는 점의 위상, 최대 임피던스 값, 최대 임피던스 값을 갖는 점의 위상, 결함 신호 시작점의 출발각, 결함 신호 끝점의 도착각 등등)를 추출하였다. 이러한 분류기를 사용할 경우 I-Out, V-Out, V-In 결함에 대해서는 대부분 정확하게 분류할 수 있었지만, I-In 결함에 대해서는 25개의 샘플신호 중 8개를 V-In 결함으로 분류하였다. 즉, I-In 결함에 대해서는 분류 실패율이 $8/25 \times 100 = 32\%$ 로 상대적으로 높은 문제점이 있었다. 최근에 참고문헌 [8]에서 분류 정확도를 개선하기 위하여 새로운 특징 3가지를 제안하였다. 특히, 여기서 제안된 새로운 특징(최대 임피던스 값을 갖는 점과 최대 임피던스 값의 1/2의 값을 갖는 점 사이의 위상각)을 사용하여 결함 패턴을 분류할 경우 [7]에서 고려한 모든 결함에 대해서 완벽한 분류를 할 수 있음을 보였다.

본 논문에서는 참고문헌[8]의 특징을 좀 더 보완하여 신경회로망의 결함 분류성능을 더욱 개선시키고자 한다. 기존의 특징을 사용할 경우, 분류 성공률은 100% 이었지만, 평가데이터에 대한 평균제곱오차(MSE)와 최대오차(Max Error)의 값이 충분히 작은 값을 주지는 않았으며, 신경회로망 학습시 필요한 반복횟수가 다소 크다는 것은 개선이 필요한 부분이었다. 이는, 불완전한 데이터나 잡음이 섞인 신호 등에 대해서는 분류성공률이 100%가 되지 않을 수도 있음을 의미한다. 따라서, MSE나 Max Error의 값을 더욱 줄이는 것은 매우 중요한 연구이다. 이러한 목적을 달성하기 위하여 본 연구에서는 Fig. 2와 같은 특징을 제안한다. Fig. 2는 차동(differential) 프로브로 얻은 ECT 신호를 임피던스 평면에서 나타낸 것으로, x축과 y축은 각각 저항과 리액턴스를 나타낸다.




Fig. 2 An improved feature extraction for the classification of defect types

Fig. 2에서 정의된 특징 F1, F2, F3, F4, F5, F6, F7의 구체적인 의미는 다음과 같다:

- F1: 상반 평면(upper half plane)에서의 최대 임피던스 값
- F2: 상반 평면(upper half plane)에서의 최대 임피던스 값을 갖는 점의 위상
- F3: 최대 임피던스 값을 갖는 점과 최대 임피던스 값의 50%의 값을 갖는 점 사이의 위상각
- F4: 최대 임피던스 값을 갖는 점과 최대 임피던스 값의 40%의 값을 갖는 점 사이의 위상각
- F5: 최대 임피던스 값을 갖는 점과 최대 임피던스 값의 30%의 값을 갖는 점 사이의 위상각
- F6: 최대 임피던스 값을 갖는 점과 최대 임피던스 값의 20%의 값을 갖는 점 사이의 위상각
- F7: 최대 임피던스 값을 갖는 점과 최대 임피던스 값의 10%의 값을 갖는 점 사이의 위상각

기존의 특징추출에 추가된 특징인 F4, F5, F6, F7은 기존의 특징 F3와 어느 정도 비슷한 성질로 볼 수도 있다. 하지만, 4장에서 볼 수 있는 것처럼, 이러한 특징들의 추가로 결함 분류성능을 더욱 향상시킬 수 있다.

3. 다층 퍼셉트론

본 절에서는 이번 연구에서 새로이 개선된 특징 추출의 우수성을 입증하기 위한 결함 패턴 분류에

대한 모의실험을 수행한다. 기존 연구결과에서는 결합 분류를 위해서 3개의 특징을 사용하였지만, 개선된 특징 추출에서는 여기에 4개의 특징을 더하여 7개의 특징을 사용한다. 본 연구에서는 신경회로망 중에서 일반화능성이 우수한 것으로 알려져 있는 다층퍼셉트론(MLP; multi layer perceptron)을 사용하여 분류기를 설계하고자 한다. MLP는 입력층과 출력층 사이에 하나 이상의 은닉층 (hidden layer)이 존재하는 퍼셉트론으로서[11,12] Fig. 3은 두 개의 은닉층을 갖는 MLP의 구조를 나타낸다.

본 연구에서는 MLP의 은닉층(hidden layer)을 하나로 구성하며, 은닉층의 뉴런의 개수는 10개로 설정하였다. 또한, 은닉층의 뉴런의 활성화 함수(activation function)은 log sigmoid 함수를 사용하였다. 또한, 다층퍼셉트론의 학습에는 학습속도가 빠르고, 수렴성이 좋은 것으로 알려져 있는 conjugate gradient 알고리즘을 사용한다. Conjugate gradient 알고리즘 사용시 아래조건을 만족하면 최적해로 수렴한 것으로 간주하여 MLP 학습을 중지한다:

$$\frac{\sqrt{\sum_{k=1}^N [t(k) - a(k)]^T [t(k) - a(k)]}}{N} < \epsilon$$

여기서, N 은 학습데이터의 전체 개수이고, $a(k)$ 는 k 번째 학습데이터에 대한 MLP의 출력값, $t(k)$ 는 k 번째 학습데이터에 대한 목표값을 나타내며, ϵ 은 목표오차(Error goal)라고 부르는데, 보통 충분히 작은 수로 정하는데, 그 구체적인 값은 나중에 기술한다. 한편, MLP 학습시 Weight와 Bias가 지역적 최소점(local minimum)으로 수렴할 수도 있기 때문에 초기조건의 선정이 매우 중요하는데, 본 연구에서는 초기조건을 랜덤함수로 생성하여 결정




Fig. 3 The structure of multi-layer perceptron (MLP) with two hidden layers

하였다. 따라서, 여러 번의 컴퓨터 모의실험이 필요한데, 본 연구에서는 컴퓨터 모의실험을 3회 수행하여 그 결과를 분석하였다.

4. 컴퓨터 모의실험

제안된 기법의 분류성능을 평가하기 위해서는 학습 데이터(train data)와 평가 데이터(test data)를 구별하여야 한다. 이를 위하여, 수치해석 프로그램으로 준비한 400개의 데이터를 아래와 같은 방식으로 학습 데이터 200개, 평가 데이터 200개로 구별하였다:

- 학습 데이터: 깊이(depth)가 0.1, 0.3, 0.5, 0.7, 0.9 mm 인 데이터
- 평가 데이터: 깊이(depth)가 0.2, 0.4, 0.6, 0.8, 1.0 mm인 데이터

이제, 이전의 연구[8]에서 사용한 특징벡터와의 성능 차이를 분석해 보도록 한다. 이전의 특징벡터를 사용한 경우, 최대오차 측면에서 볼 때 V-Out 형태 결합을 분류하는 것이 다른 결합을 분류할 때보다 상대적으로 분류성능이 좋지 않았다. 따라서, 우선 V-Out 형태 결합의 분류성능을 분석하여 이전의 특징벡터와 새로이 개선된 특징벡터 사이의 성능을 비교하도록 하자.

4.1. V-Out 형태 결합 분류기

V-Out 형태 결합을 분류하기 위하여 V-Out의 목표값을 1, I-In, I-Out, V-In의 목표값을 0으로 설정한 후 MLP를 학습시킨 후, 분류성능을 평가하였다. 평가시에는 MLP의 출력값이 0.5 이상인 패턴은 V-Out으로, 0.5 이하인 패턴은 I-In, I-Out, V-In으로 분류하였다. 또한, 목표값에서 MLP의 출력값을 뺀 값의 절대값을 오차로 정의할 때, 분류성능은 평가 데이터에 대한 평균제곱오차(MSE)와 최대오차(Max Error)를 사용하여 측정하였다. 여기서, 최대오차는 각각의 결합 데이터에 대한 오차를 계산한 후, 이 오차들의 최대값으로 정의하였다. 또한, conjugate gradient 알고리즘에서 사용하는 최대 반복 횟수는 10,000번, 목표오차는 $\epsilon = 0.001$ 로 정하였다.

Table 1은 와전류 탐상 주파수가 100 kHz 일 때, 기존의 특징벡터를 사용한 경우의 분류결과이며, Table 2는 와전류 탐상 주파수가 100 kHz 일 때,

새로 개선된 특징벡터를 사용한 경우의 분류결과를 정리한 것이다.

Table에서 epochs은 MLP를 학습시키는 데 필요한 반복 횟수를 의미하고 MSE와 Max Error는 평가데이터에 대한 예측성능이며, 실험 1, 2, 3이 의미하는 것은 첫 번째, 두 번째, 세 번째 실험결과를 의미한다. Table 1과 Table 2로부터 기존 특징벡터를 사용하는 경우 2회는 10,000 epoch 동안 $\epsilon = 0.001$ 으로 수렴하지 못하고, 1회는 8,679 epoch 후 $\epsilon = 0.001$ 로 수렴하는데 비해, 개선된 특징벡터를 사용하는 경우에는 3회 모두 1,300 epoch 이내에 모두 $\epsilon = 0.001$ 로 수렴하여 수렴특성이 훨씬 좋을 수 있다. 또한, MSE와 Max Error도 개선된 특징벡터를 사용하는 것이 훨씬 작은 값을 갖고, 결과적으로 분류 성능이 우수하다는 것을 알 수 있다.

한편, 이해를 돕기 위하여, Fig. 4와 Fig. 5는 실험번호 3번에서 학습된 MLP를 사용할 때의 평가데이터에 대한 MLP 출력 결과를 보여준다. 그림에서 빨간색 점선은 목표값이고 파란색 실선은 MLP의 출력값을 나타내는데, 이 차이가 작을수록 패턴 분류 성능이 우수하다. 또한, x축은 각각의 데이터 식별번호(identification number)를 나타내는데, 1~25는 I-In 데이터, 26~50은 I-Out 데이터, 51~75는 V-In 데이터, 76~100은 V-Out 데이터를 의미한다. 또한, 1~25 사이에서는 x축 값이 1, 2, 3, 4, 5, 6, 7, ... 인 데이터는 각각 (깊이, 폭)=(0.2, 0.2), (0.2, 0.4), (0.2, 0.6), (0.2, 0.8), (0.2, 1.0), (0.4, 0.2), (0.4, 0.4), ... 인 결함을 나타낸다.

Table 1 The classification performance of V-Out defect (100 kHz, the method of [8], $\epsilon = 0.001$)

| 실험 | epochs | MSE | max error |
|----|--------|--------|-----------|
| 1 | 10000 | 0.0050 | 0.39 |
| 2 | 8676 | 0.0076 | 0.36 |
| 3 | 10000 | 0.0064 | 0.39 |

Table 2 The classification performance of V-Out defect (100 kHz, the proposed method, $\epsilon = 0.001$)

| 실험 | epochs | MSE | Max Error |
|----|--------|--------|-----------|
| 1 | 1167 | 0.0016 | 0.076 |
| 2 | 1195 | 0.0018 | 0.10 |
| 3 | 1276 | 0.0017 | 0.090 |

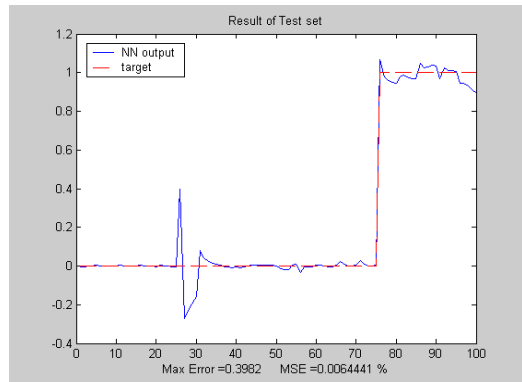


Fig. 4 The classification result of V-Out defect, (100 kHz, the method of [8])

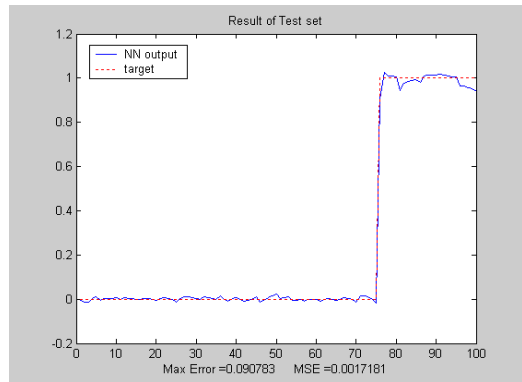


Fig. 5 The classification result of V-Out defect, (100 kHz, the proposed method)

Table 3 The classification performance of V-Out defect (400 kHz, the method of [8], $\epsilon = 0.001$)

| 실험 | epochs | MSE | Max Error |
|----|--------|--------|-----------|
| 1 | 10000 | 0.015 | 0.85 |
| 2 | 10000 | 0.010 | 0.37 |
| 3 | 10000 | 0.0084 | 0.24 |

Table 4 The classification performance of V-Out defect (400 kHz, the proposed method, $\epsilon = 0.001$)

| 실험 | epochs | MSE | Max Error |
|----|--------|--------|-----------|
| 1 | 2369 | 0.0035 | 0.29 |
| 2 | 2811 | 0.0048 | 0.31 |
| 3 | 2115 | 0.0040 | 0.31 |

마찬가지로, 와전류 탐상 주파수가 400 kHz 일 때, 동일한 실험을 수행하였는데, Table 3은 기존의 특징벡터를 사용한 경우의 분류결과이며, Table 4는 새로 개선된 특징벡터를 사용한 경우의 분류결과를 정리한 것이다.

이해를 돕기 위하여, Fig. 6과 Fig. 7은 실험번호 3번에서 학습된 MLP를 사용할 때의 평가데이터에 대한 MLP 출력 결과를 나타낸다.

위 실험 결과로부터 다음과 같은 중요한 사실을 유추할 수 있다.

- 1) 개선된 특징벡터를 사용하는 경우가 기존의 특징벡터를 사용할 때보다 MLP 학습시 필요한 epoch이 훨씬 적다. 이는 개선된 특징벡터가 결함의 특성을 훨씬 효과적으로 표현하고 있음을 의미한다.
- 2) 기존의 특징벡터를 사용하는 경우, 대부분의 경우 10,000 epochs이 지나도 수렴하지 않았다. 이에 ϵ 의 값을 0.001에서 0.003으로 증가시켜서 예

측성능을 알아본 결과, 분류성능이 별 차이가 없음을 알 수 있었다. 특히, 100 kHz ECT신호의 경우, ϵ 의 값이 작을 때 오히려, MSE와 Max Error가 증가하여 성능이 나빠짐을 알 수 있었다. 즉, 기존의 특징벡터를 사용하는 경우 ϵ 의 값을 0.003으로 증가시켜서 신경회로망을 학습시킬 때 오히려 예측성능이 보다 우수하다. 따라서 기존 특징벡터와 개선된 특징벡터의 분류성능 비교시 기존 특징벡터를 이용한 신경회로망 학습은 $\epsilon = 0.003$ 을 사용하고, 개선된 특징벡터를 이용한 MLP 학습은 $\epsilon = 0.001$ 을 사용하는 것이 합리적이다. 따라서 다음절부터는 특별한 언급이 없는 한, 기존 특징벡터의 경우 $\epsilon = 0.003$ 을, 개선된 특징벡터의 경우 $\epsilon = 0.001$ 을 이용한다. 또한, 신경회로망 학습시 반복횟수는 기존 특징벡터 사용시 3000회, 개선된 특징벡터 사용시 5000회로 정하였다.

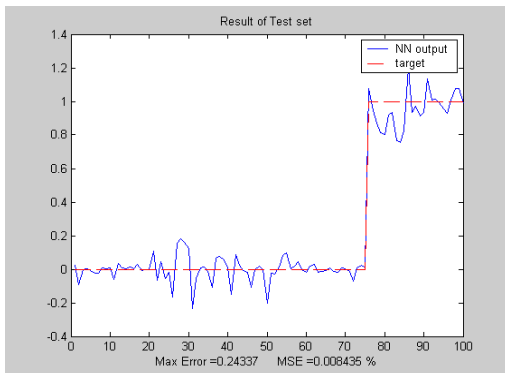


Fig. 6 The classification result of V-Out defect, (400 kHz, the method of [8])




Fig. 7 The classification result of V-Out defect, (400 kHz, the proposed method)

4.2. I-In 형태 결함 분류기

I-In 형태의 결함을 분류하기 위한 목표값 설정, MLP 출력에 따른 패턴 분류 등의 방법은 앞서의 V-Out 결함형태와 비슷한 방법을 사용하였다. Table 5와 Table 6은 와전류 탐상 주파수가 100 kHz 일 때, 기존의 특징벡터를 사용한 경우와 새로 개선된 특징벡터를 사용한 경우의 분류결과를 정리한 것이다. MSE와 Max Error 모두 개선된 특징벡터를 사용하는 것이 우수한 결과를 준다는 것을 알 수 있다.

Table 5 The classification performance of I-In defect (100 kHz, the method of [8], $\epsilon = 0.003$)

| 실험 | epochs | MSE | Max Error |
|----|--------|--------|-----------|
| 1 | 732 | 0.0042 | 0.1 |
| 2 | 657 | 0.0041 | 0.17 |
| 3 | 1005 | 0.0044 | 0.21 |

Table 6 The classification performance of I-In defect (100 kHz, the proposed method, $\epsilon = 0.001$)

| 실험 | epochs | MSE | Max Error |
|----|--------|--------|-----------|
| 1 | 1404 | 0.0024 | 0.08 |
| 2 | 918 | 0.0023 | 0.09 |
| 3 | 1370 | 0.0023 | 0.10 |

Table 7과 Table 8은 와전류 탐상 주파수가 400kHz 일 때의 분류결과 비교이다. MSE와 Max Error 모두 개선된 특징벡터를 사용하는 것이 우수한 결과를 준다는 것을 알 수 있다.

4.3. I-Out 형태 결함 분류기

I-Out 형태의 결함을 분류하기 위한 목표값 설정, MLP 출력에 따른 패턴 분류 등의 방법은 앞서의 V-Out 결함형태와 비슷한 방법을 사용하였다. Table 9와 Table 10은 와전류 탐상 주파수가 100 kHz 일 때, 기존의 특징벡터를 사용한 경우와

Table 7 The classification performance of I-In defect (400 kHz, the method of [8], $\epsilon = 0.003$)

| 실험 | epochs | MSE | Max Error |
|----|--------|--------|-----------|
| 1 | 2300 | 0.0036 | 0.13 |
| 2 | 2264 | 0.0087 | 0.44 |
| 3 | 1546 | 0.0074 | 0.39 |

Table 8 The classification performance of I-In defect (400 kHz, the proposed method, $\epsilon = 0.001$)

| 실험 | epochs | MSE | Max Error |
|----|--------|--------|-----------|
| 1 | 2917 | 0.0029 | 0.10 |
| 2 | 3626 | 0.0041 | 0.14 |
| 3 | 2275 | 0.0074 | 0.33 |

Table 9 The classification performance of I-Out defect (100 kHz, the method of [8], $\epsilon = 0.003$)

| 실험 | epochs | MSE | Max Error |
|----|--------|--------|-----------|
| 1 | 1400 | 0.0051 | 0.29 |
| 2 | 1199 | 0.0043 | 0.25 |
| 3 | 1018 | 0.0060 | 0.32 |

Table 10 The classification performance of I-Out defect (100 kHz, the proposed method, $\epsilon = 0.001$)

| 실험 | epochs | MSE | Max Error |
|----|--------|--------|-----------|
| 1 | 736 | 0.0036 | 0.21 |
| 2 | 908 | 0.0036 | 0.24 |
| 3 | 1048 | 0.0034 | 0.19 |

새로 개선된 특징벡터를 사용한 경우의 분류결과를 정리한 것이다. MSE와 Max Error 모두 개선된 특징벡터를 사용하는 것이 우수한 결과를 준다는 것을 알 수 있다.

와전류 탐상 주파수가 400 kHz인 경우, 기존의 특징벡터를 사용하면 세 번의 실험 모두에서 3000 epoch 까지 학습데이터의 MSE가 0.003보다 작아지지 않았다. 이는 탐상주파수가 400 kHz인 경우에는 I-Out 형태 결함을 분류하기 위한 MLP 학습이 기존의 특징벡터를 사용하는 경우 쉽지 않다는 것을 의미한다. 특징벡터의 차이에 의한 성능 비교를 위해서, 개선된 특징벡터를 사용할 때의 MLP 학습도 $\epsilon = 0.003$ 로 정하였다. Table 11과 Table 12는 와전류 탐상 주파수가 400 kHz 일 때, 기존의 특징벡터를 사용한 경우와 새로 개선된 특징벡터를 사용한 경우의 분류결과를 정리한 것이다. 표로부터 MLP 학습에 필요한 epochs 회수가 개선된 특징벡터를 사용하면 약 400, 기존의 특징벡터를 사용하면 3000 이상인 것을 확인할 수 있다. 이것은 개선된 특징벡터를 사용할 경우, MLP 학습이 훨씬 효과적으로 빨리 가능함을 의미한다. 또한, MSE와 Max Error 모두 개선된 특징벡터를 사용하는 것이 우수한 결과를 준다는 것을 알 수 있다.

Fig. 8과 Fig. 9는 실험번호 3번에서 학습된 MLP 를 사용할 때의 평가데이터에 대한 MLP 출력 결과를 나타낸다.

Table 11 The classification performance of I-Out defect (400 kHz, the method of [8], $\epsilon = 0.003$)

| 실험 | epochs | MSE | Max Error |
|----|--------|--------|-----------|
| 1 | 3000 | 0.0101 | 0.31 |
| 2 | 3000 | 0.0092 | 0.25 |
| 3 | 3000 | 0.0116 | 0.37 |

Table 12 The classification performance of I-Out defect (400 kHz, the proposed method, $\epsilon = 0.001$)

| 실험 | epochs | MSE | Max Error |
|----|--------|--------|-----------|
| 1 | 397 | 0.0043 | 0.15 |
| 2 | 470 | 0.0048 | 0.16 |
| 3 | 381 | 0.0039 | 0.15 |




Fig. 8 The classification result of I-Out defect, (400 kHz, the method of [8])




Fig. 9 The classification result of I-Out defect, (400 kHz, the proposed method)

Table 13 The classification performance of V-In defect (100 kHz, the method of [8], $\epsilon = 0.003$)

| 실험 | epochs | MSE | Max Error |
|----|--------|--------|-----------|
| 1 | 420 | 0.0036 | 0.154 |
| 2 | 549 | 0.0035 | 0.162 |
| 3 | 383 | 0.0035 | 0.186 |

Table 14 The classification performance of V-In defect (100 kHz, the proposed method, $\epsilon = 0.001$)

| 실험 | epochs | MSE | Max Error |
|----|--------|---------|-----------|
| 1 | 353 | 0.0013 | 0.077 |
| 2 | 210 | 0.0011 | 0.069 |
| 3 | 226 | 0.00093 | 0.057 |

Table 15 The classification performance of V-In defect (400 kHz, the method of [8], $\epsilon = 0.003$)

| 실험 | epochs | MSE | Max Error |
|----|--------|--------|-----------|
| 1 | 1694 | 0.0030 | 0.140 |
| 2 | 1537 | 0.0028 | 0.128 |
| 3 | 1690 | 0.0029 | 0.136 |

Table 16 The classification performance of V-In defect (400 kHz, the proposed method, $\epsilon = 0.001$)

| 실험 | epochs | MSE | Max Error |
|----|--------|--------|-----------|
| 1 | 1382 | 0.0012 | 0.057 |
| 2 | 815 | 0.0010 | 0.047 |
| 3 | 1050 | 0.0012 | 0.072 |

4.4. V-In 형태 결함 분류기

V-In 형태의 결함을 분류하기 위한 목표값 설정, MLP 출력에 따른 패턴 분류 등의 방법은 앞서의 V-Out 결함형태와 비슷한 방법을 사용하였다. Table 13과 Table 14는 와전류 탐상 주파수가 100 kHz 일 때, 기존의 특징벡터를 사용한 경우와 새로 개선된 특징벡터를 사용한 경우의 분류결과를 정리한 것이다. MSE와 Max Error 모두 개선된 특징벡터를 사용하는 것이 우수한 결과를 준다는 것을 알 수 있다.

Table 15와 Table 16은 와전류 탐상 주파수가 400 kHz 일 때의 분류결과 비교이다. MSE와 Max Error 모두 개선된 특징벡터를 사용하는 것이 우수한 결과를 준다는 것을 알 수 있다.

5. 결론

본 논문에서는 4가지 축대칭 결함, 즉 I-In 결함, I-Out 결함, V-In 결함, V-Out 결함의 와전류 탐상 시험(ECT) 신호로부터 결함 형태 분류를 위한 특징 추출에 대한 연구를 수행하였다. 결함 형태 분류를 위해서 [8]에서는 일반적으로 세 가지 특징을 사용하였는데, 본 논문에서는 [8]의 특징을 좀 더 일반화하여 총 7가지 특징을 사용하였다. 결함 분류 성능 검증을 위한 컴퓨터 모의실험 결과, 다음과 같

은 두 가지 결론을 얻을 수 있었다. 첫 번째로는, 개선된 특징벡터를 사용하는 경우가 기존의 특징벡터를 사용할 때보다 MLP 학습시 필요한 epoch가 훨씬 적었다. 이는 개선된 특징벡터가 결합의 특성을 훨씬 효과적으로 표현하고 있음을 의미한다. 두 번째로는, MSE와 Max Error도 개선된 특징벡터를 사용하는 것이 훨씬 작았는데, 이는 제안된 방식의 분류 성능이 우수하다는 것을 의미한다.

감사의 글

본 연구는 숭실대학교 교내연구비 지원으로 수행되었음.

참고문헌

- [1] E. E. Kriezis, T. D. Tsiboukis, S. M. Panas and J. A. Tegopoulos, "Eddy currents: theory and applications," Proceedings of the IEEE, Vol. 80, No. 10, pp. 1559-1589, (1992)
- [2] H. B. Lee and D. H. Kim, "Impedance calculation for a plate with crack in eddy current NDT using 3D indirect BIEM," IEEE Transactions on Magnetics, Vol. 36, No. 5, pp. 3131-3133, (2000)
- [3] K. Miya, "Recent advancement of electromagnetic nondestructive inspection technology in Japan," IEEE Transactions on Magnetics, Vol. 38, No. 2, pp. 321-326, (2002)
- [4] M. Rebican, Z. Chen, N. Yusa, L. Janousek and K. Miya, "Shape reconstruction of multiple cracks from ECT signals by means of a Stochastic method," IEEE Transactions on Magnetics, Vol. 42, No. 4, pp. 1079-1082, (2006)
- [5] H. Fukutomi, T. Takagi, J. Tani, M. Hashimoto, J. Shimone and Y. Harada, "Numerical evaluation of ECT impedance signal due to minute cracks," IEEE Trans. on Magnetics, Vol. 33, No. 2, Part 2, pp. 2123-2126, (1997)
- [6] C. Gangzhu, A. Yamaguchi and K. Miya, "A novel signal processing technique for eddy-current testing of steam generator tubes," IEEE Trans. on Magnetics, Vol. 34, No. 3, pp. 642-648, (1998)
- [7] S. J. Song and Y. K. Shin, "Eddy current flaw characterization in tubes by neural networks and finite element modeling," NDT & E International, Vol. 33, pp. 233-243, (2000)
- [8] 조남훈, 이항범, 한기원, 송성진 "신경회로망을 이용한 원전SG 세관 결함패턴 분류성능 향상기법", 전기학회논문지, Vol. 56, No. 7, pp. 1224-1230, July, (2007)
- [9] H. Haoyu and T. Takagi, "Inverse analyses for natural and multicracks using signals from a differential transmit-receive ECT probe," IEEE Trans. on Magnetics, Vol. 38, No. 2, Part 1, pp. 1009-1012, (2002)
- [10] M. Rebican, N. Yusa, Z. Chen, K. Miya, T. Uchimoto and T. Takagi, "Reconstruction of multiple cracks in an ECT round-robin test," International Journal of Applied Electromagnetics and Mechanics, Vol. 19, No. 1-4, pp. 399-404, (2004)
- [11] M. T. Hagan, H. B. Demuth, and M. H. Beale, Neural Network Design, PWS Pub. Co, (1995)
- [12] S. Haykin, Neural Networks, Prentice-Hall, New Jersey, (1999)