

신경회로망을 이용한 원전SG 세관 결함크기 예측

Prediction of Defect Size of Steam Generator Tube in Nuclear Power Plant Using Neural Network

한기원*, 조남훈*[†], 이향범*

Ki-Won Han*, Nam-Hoon Jo*[†] and Hyang-Beom Lee*

초 록 본 논문에서는 신경회로망을 이용하여 원자력 발전소 증기발생기 세관의 결함 깊이와 폭을 예측하는 연구를 수행한다. 결함 크기 추정을 위하여 우선, I-In 형태, I-Out 형태, V-In 형태, V-Out 형태의 4가지 결함형상에 대한 와전류탐상시험(ECT) 신호를 생성한다. 특히, 유한요소법에 기반한 수치해석 기법을 이용하여 여러 가지 폭과 깊이를 갖는 결함 400개의 ECT 신호를 생성한다. 이와 같이 생성된 ECT 신호로부터, 결함 크기와 폭을 예측하기 위한 새로운 특징벡터를 추출하는데, 이 특징벡터에는 최대 임피던스 값을 갖는 점과 최대 임피던스값의 1/2의 값을 갖는 점 사이의 위상각이 포함된다. 추출된 특징벡터를 이용하여 결함의 크기를 예측하기 위해서 하나의 은닉층을 갖는 다층퍼셉트론을 이용하였다. 컴퓨터 모의실험 연구를 통하여 제안된 방법이 우수한 예측성능을 갖는다는 것을 보였다.

주요용어: 와전류탐상, 증기발생기, 신경회로망, 다층 퍼셉트론, 특징추출

Abstract In this paper, we study the prediction of depth and width of a defect in steam generator tube in nuclear power plant using neural network. To this end, we first generate eddy current testing (ECT) signals for 4 defect patterns of SG tube: I-In type, I-Out type, V-In type, and V-Out type. In particular, we generate 400 ECT signals for various widths and depths for each defect type by the numerical analysis program based on finite element modeling. From those generated ECT signals, we extract new feature vectors for the prediction of defect size, which include the angle between the two points where the maximum impedance and half the maximum impedance are achieved. Using the extracted feature vector, multi-layer perceptron with one hidden layer is used to predict the size of defects. Through the computer simulation study, it is shown that the proposed method achieves decent prediction performance in terms of maximum error and mean absolute percentage error (MAPE).

Keywords: Eddy Current Testing (ECT), Steam Generator (SG), Neural Network, Multi-layer Perceptron, Feature Extraction

1. 서 론

원전 설비 중 원자력 발전소 증기발생기 세관은 원자료를 거치는 1차 계통수와 2차 계통수 사이에서 열을 전달하고 터빈 발전기를 돌리는 증기를 발생시키며 동시에 방사능 차단벽으로서 중요한 기능

을 하고 있다. 증기발생기 세관은 가동 특성상 결함발생 가능성이 매우 높으며, 실제로 원전 수명관리에 큰 영향을 미치고 있다. 따라서, 원전의 노후화가 진행됨에 따라 발생하는 다양한 전열관의 결함을 검출하기 위한 신뢰할만한 검사법의 확보가 필요하다. 비파괴검사기술은 원전설비의 수명관리

를 위한 핵심기술의 첫 단계로서, 그 이후에 이루어지는 모든 수명관리의 기본자료를 제공하므로 그 신뢰성 확보가 매우 중요하다. 2002년 4월 울진 4호기의 증기발생기관 파단사고와 같은 사고를 미연에 방지하기 위해서는 비파괴검사 신뢰도를 개선하기 위한 연구가 필요하다. 만일 증기 세관 결함을 검출할 수 있는 비파괴검사법에 대한 연구가 충분히 이루어져 있었다면 미연에 방지할 수도 있었을지 모른다. 원자력발전소에서의 사고는 방사능이라는 문제와 연결되기 때문에 기술적인 문제, 정치적인 문제, 사회적인 문제 모든 면에서 반드시 예방하고 사전에 처치하여 신뢰도를 100%로 맞추어야만 하는 문제이다.

원전설비검사에 사용되는 대표적인 비파괴검사법으로 와전류탐상시험(eddy current testing: ECT)방법이 있는데, 증기발생기 세관 검사에 주로 사용된다. 와전류탐상시험(ECT)은 도체에 와전류를 유도하여 그 왜곡 여부를 관찰함으로써 검사체의 이상 유무를 판단하는 비파괴검사 방법이다. ECT는 비접촉 방식으로서 고속 자동화가 가능하고 취득한 신호의 저장성이 우수하며 다른 비파괴 검사법에 비하여 상대적으로 비용이 저렴한 장점이 있어 증기발생기 전열관에 대한 검사에 가장 널리 사용되고 있다. 그러나 신호를 발생시키는 요인과 결함의 종류가 다양하여 검사 결과의 분석이 복잡하고 많은 경우 경험에 의존하므로, 검사 결과의 신뢰성 평가를 병행해야 한다. 현재 선진 각국에서는 유한요소법이나 경계요소법 등 수치해석 기법을 이용하여 와전류탐상 검사의 전 과정을 모사하고, 결함 신호를 이론적으로 예측코자 하는 연구를 경쟁적으로 수행하고 있다[1-4]. 또한, 한편으로는 신경회로망 기법 등 최첨단 인공지능 기술을 적용하여 결함

신호를 분석하여 결함의 위치, 종류, 크기 등을 자동적으로 결정하는 기법의 개발에 심혈을 기울이고 있다[5-10]. 이러한 결함 검출 기법이 성공적으로 개발되기 위해서는 결함신호로부터 결함의 종류, 크기 등을 정확하게 구별할 수 있는 특징(feature) 추출 또한 매우 중요한 연구 분야 중의 하나이다.

최근에 참고문헌 [7]에서 Fig. 1과 같은 2차원 축대칭결함에 대해서 수치해석 기법을 이용하여 생성한 ECT 신호에 대한 결함평가를 수행하였다. 이 연구에서는 4가지 결함형태, 즉 I형 관외벽 결함(I-In type), I형 관외벽 결함(I-Out type), V형 관내벽 결함(V-In type), V형 관외벽 결함(V-Out type)을 고려하였는데, 이를 분류하기 위하여 임피던스 평면에서 11개의 특징을 추출하여 결함 패턴을 분류하였다. 참고로, Fig. 2는 위의 4가지 결함 중 I-Out 결함과 V-Out 결함 형태를 나타낸다.




Fig. 2 The I-shaped flaw in the outer diameter (IO type) and the V-shaped flaw in the outer diameter (VO type)

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

본 논문에서는 Fig. 1과 같은 축대칭 결함신호의 깊이와 폭 크기를 추정하는 것을 목적으로 한다. 이를 위해서, 우선 축대칭 전자기 수치해석 프로그램으로부터 I-In 결함, I-Out 결함, V-In 결함, V-Out 결함의 와전류 탐상시험(ECT) 신호를 생성하였다. 우수한 결함크기 추정성능을 보장하기 위해서는 생성된 ECT 신호로부터 적절한 특징(feature) 추출이 매우 중요하다. 참고문헌 [8]에서

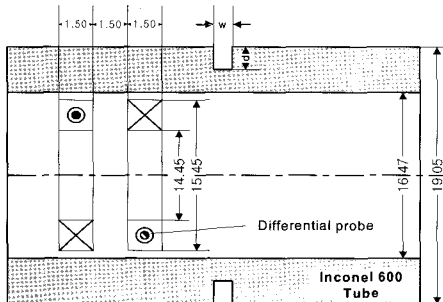


Fig. 1 A cross section of SG tube for the analysis of axisymmetric flaw signals

는 일반적으로 세 가지 특징을 사용하여 결함형태를 분류하였는데, 본 논문에서는 결함크기를 추정하기 위하여 [8]의 세 가지 특징을 두 개의 주파수 (100 kHz와 400 kHz) 별로 생성하여 총 6개의 특징을 사용하고자 한다. 추출된 특징벡터를 이용하여 결함크기를 예측하는 알고리즘으로는 인공지능 기술 중 하나인 신경회로망(neural network) 기법을 사용한다. 신경회로망 기법 중 다층 퍼셉트론 (multi layer perceptron)은 입력층과 출력층의 특성이 비선형으로 표현되어 많은 응용분야에서 우수한 예측성능을 보여주기 때문에, 본 논문에서도 다층 퍼셉트론을 결함 크기 추정기로 사용하고자 한다. 또한, 4가지 결함형태를 구별하지 않고 하나의 추정기를 사용하여 결함의 크기를 추정하는 것은 정확도가 상당히 떨어지므로, 결함형태별로 각각의 결함 크기 추정기를 설계한다. 따라서, 결함크기를 예측하고자 하는 데이터가 주어지면, 우선 [8]에서 제시한 방법을 사용하여 결함형태를 분류하고, 그 결과에 따라 4가지 결함크기 추정기중 적절한 것을 선택하여 사용한다. 마지막으로 본 논문에서 제안된 기법이 우수한 추정 성능을 갖는다는 것을 컴퓨터 모의실험을 통하여 입증하고자 한다.

2. 결함 크기 추정을 위한 특징추출

신경회로망을 이용하여 크기를 산정하기 위해서는 추정 알고리즘을 학습시키는 데 충분한 량의 와전류 결함신호 표본들이 필요하다. 따라서, 축대칭 수치해석 계산을 위해 I형 결함 100개와 V형 결함 100개에 동일한 수의 와전류 탐상시험 신호를 생성하였다. Table 1에 나타난 것처럼 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 리액턴스값, 최대 리액턴스값을 갖는 점

Table 1 Sample data of axisymmetric flaw signals

결함 형태	샘플 개수			신호전체 개수
	w (폭)	d (깊이)	f (주파수)	
I-Out	5	10	2	100
I-In	5	10	2	100
V-Out	5	10	2	100
V-In	5	10	2	100
전체	-	-	-	400

의 위상, 최대 임피던스값, 최대 임피던스값을 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, 분류 실패율이 $8/25 \times 100 = 32\%$ 로 상대적으로 높다는 것이 보고되었는데, 이는 연구결과 [7]의 특징추출을 좀 더 개선할 필요가 있음을 의미한다. 최근에 저자들의 논문 [8]에서 분류 정확도를 개선하기 위하여 Fig. 3과 같은 새로운 특징 3가지를 제안하였다. Fig. 3은 차동 (differential) 프로브로 얻은 ECT 신호를 임피던스 평면에서 나타낸 것으로, x축과 y축은 각각 저항과 리액턴스를 나타낸다. Fig. 3에서 F1, F2, F3는 각각 상반 평면(upper half plane)에서의 최대 임피던스값, 상반 평면에서의 최대 임피던스값을 갖는 점의 위상, 최대 임피던스 값을 갖는 점과 최대 임피던




Fig. 3 New feature extraction for the classification of flaw types. The ECT signals obtained using differential probe is shown in the impedance plane. The new feature F3 represent the angle between the two points where the maximum impedance and half the maximum impedance are achieved

스값의 1/2의 값을 갖는 점 A 사이의 위상각을 의미한다. F1과 F2는 기존의 특징과 동일하며, F3이 새로 제안된 특징임을 알 수 있다. 참고문헌 [8]에서는 이러한 세 가지 특징을 사용하여 결합패턴을 분류할 경우 기존의 연구결과 [7]보다 우수한 결과를 얻을 수 있음을 보였다.

본 논문에서는 향상된 결합패턴 분류를 위해서 [8]에서 제시된 특징을 사용하여 결합의 폭과 깊이를 추정하는 MLP(multilayer perceptron) 추정기를 설계하고자 한다. 참고문헌 [8]에서는 일반적으로 세 가지 특징을 사용하였는데, 본 논문에서는 결합 크기를 추정하기 위하여 100 kHz와 400 kHz ECT 신호를 동시에 사용한다. 결과적으로 본 논문에서는 아래와 같은 6가지 특징을 사용한다.

- F1: 주파수가 100 kHz일 때의 상반 평면에서의 최대 임피던스값
- F2: 주파수가 100 kHz일 때의 상반 평면에서의 최대 임피던스값을 갖는 점의 위상
- F3: 주파수가 100 kHz일 때의 최대 임피던스값을 갖는 점과 최대 임피던스값의 1/2의 값을 갖는 점 A 사이의 위상각
- F4: 주파수가 400 kHz일 때의 상반 평면에서의 최대 임피던스값
- F5: 주파수가 400 kHz일 때의 상반 평면에서의 최대 임피던스값을 갖는 점의 위상
- F6: 주파수가 400 kHz일 때의 최대 임피던스값을 갖는 점과 최대 임피던스값의 1/2의 값을 갖는 점 A 사이의 위상각

3. 다층 퍼셉트론

2장에서 소개한 6개의 특징을 사용하여 결합 깊이 및 결합 폭을 추정하기 위하여 본 논문에서는 신경회로망의 일종인 다층 퍼셉트론(multi-layer perceptron; MLP)을 사용한다. MLP는 충분히 많은 뉴런을 사용할 경우 임의의 함수를 근사할 수 있는 성질이 알려져 있기 때문에, 함수 근사화, 예측이론 등에 자주 사용되는 신경 회로망이다[11,12]. MLP는 입력층과 출력층 사이에 하나 이상의 은닉층(hidden layer)이 존재하는 퍼셉트론으로서 Fig. 4는 두 개의 은닉층을 갖는 MLP의 구조를 나타낸다.

MLP를 설계하기 위해서는 은닉층의 개수, 은닉층 내의 뉴런의 개수, 활성화 함수, 학습알고리즘 등을 적절히 선정하여야 한다. MLP의 은닉층의 개수는




Fig. 4 The structure of multi-layer perceptron (MLP) with two hidden layers

특별한 경우가 아니면 하나로 구성하기 때문에 본 논문에서도 하나로 구성하였다. 또한, 은닉층에 존재하는 뉴런의 개수는 MLP의 예측성능에 상당한 영향을 주는 요소이다. 이 값이 작으면 학습데이터에 대한 MLP의 학습이 잘 수행되지 않으며, 반대로 이 값이 너무 크면 과대학습(over-training)이 이루어져 평가데이터에 대한 추정 성능이 오히려 저하되는 경우가 발생한다. 본 논문에서는 여러 번의 모의실험을 통해 뉴런의 개수를 10개로 결정하였다. 또한, 은닉층의 뉴런의 활성화함수(activation function)로는 log sigmoid 함수를 사용하였다.

한편, MLP의 학습에는 오차 역전파(error back-propagation) 알고리즘, 모멘텀(momentum) 알고리즘, 결합 경사(conjugate gradient) 알고리즘 등이 사용되는데, 알고리즘 구조가 복잡하지만 학습속도가 가장 빠른 것으로 알려져 있는 결합 경사 알고리즘을 사용한다[12]. 본 논문에서는 결합 경사 알고리즘의 최대 반복 횟수는 3000번, 수렴여부를 판정하는 ϵ 은 0.003으로 설정하였다. 또한, 결합 경사 알고리즘에서는 선 탐색(line search)이 사용되는데, 이는 다시 구간 선정(interval location)과 구간 축소(interval reduction)로 나누어진다[11]. 구간 선정을 위한 최대 반복횟수는 100, 구간 축소를 위한 최대 반복횟수는 1000, 구간 축소의 수렴여부 판정에 사용되는 ϵ 은 10^{-6} , 선 탐색의 스텝 크기(step size)는 0.01, 황금분할(golden search) 검색에 사용되는 $\tau=0.618$ 로 설정하였다. 마지막으로 MLP는 국소적 최소점(local minima)으로 수렴할 수도 있기 때문에 초기조건을 선정이 매우 중요하데, 본 연구에서는 초기조건을 랜덤함수로 생성하여 결정하였다.

4. 컴퓨터 모의실험

본 절에서는 제안하는 결함크기 추정기의 우수성을 입증하기 위하여 컴퓨터 모의실험을 수행한다. 제안된 추정기의 결함 크기 추정성능을 검증하기 위해서는 우선 전체 실험 데이터를 학습데이터(train data)와 평가데이터(test data)로 나누어야 한다. 학습데이터는 MLP 추정기를 학습시킬 때 사용하는 데이터로서, 적절히 학습된 MLP 추정기의 경우 학습데이터를 입력으로 인가하게 되면 추정오차는 매우 작은 값이어야 한다. 따라서, 학습데이터에 대한 추정오차를 분석하는 것은 별 의미가 없으며, 학습시 사용하지 않은 데이터, 즉 평가데이터에 대한 추정오차를 성능분석에 사용해야 한다. 이를 위해서, 전체 200개의 실험 데이터 중에서 깊이(depth)가 1, 3, 5, 7, 9 mm 인 데이터 100개를 학습데이터로, 깊이가(depth)가 2, 4, 6, 8, 10 mm인 데이터 100개를 평가데이터로 선정하였다. 또한, 결함크기 추정시에는 대상 데이터를 각각의 결함별로 분류한 후, 결함크기 추정을 하여야 훨씬 정확한 결과를 얻을 수 있다. 따라서, 본 절에서는 각각의 결함별로 결함크기 추정성능을 분석하는데, 결과적으로 각각의 결함별로 25개의 학습데이터와 25개의 평가데이터가 사용가능하다.

또한, 결함크기 추정 성능은 평가데이터에 대한 MSE(mean square error), 최대오차(max error), MAPE(mean absolute percent error)를 사용하여 측정하였는데,

$$MAPE = 100 \frac{\sum_{i=1}^n \left| \frac{x_i - \hat{x}_i}{x_i} \right|}{n}$$

이다. 여기서, x_i 는 실제 결함크기이고 \hat{x}_i 는 결함크기 추정치이며, n 은 실험 데이터 개수이다.

결함크기를 추정하기 위한 특징 벡터는 2장에서 정의한 F1, F2, F3, F4, F5, F6을 이용하여

$$[F1, F2, F3, F4, F5, F6]$$

로 설정하였다.

마지막으로, MLP는 초기조건에 따라 설계변수(weight, bias)가 유일한 해(unique solution)로 수렴하는 것이 보장되지 않기 때문에 여러 번의 컴퓨터 모의실험이 필요하다. 본 연구에서는 이를 고려하여 컴퓨터 모의실험을 3회 수행하여 그 결과를

분석하였다.

4.1. I-In 결함크기 추정

I-In 형태 결함의 크기 산정을 위해서 결함 깊이(depth) 추정기와 결함 폭(width) 추정기를 독립적인 두 개의 MLP로 설계하였다. MLP에서 사용하는 여러 가지 파라미터는 3장에서 소개한 바와 같다.

4.1.1. I-In 결함깊이 추정

학습된 MLP의 결함 깊이 추정성능은 학습 데이터와 평가 데이터의 추정성능을 모두 계산하여 비교하였으며, Table 2는 그 결과를 나타낸다. 표에서 학습데이터인지 평가데이터인지 표시하지 않은 항목은 모두 평가데이터에 대한 결과이다. 즉, 2번째 열 MSE는 학습데이터에 대한 결과, 3, 4, 5번째 열 MSE, Max Error, MAPE는 모두 평가데이터에 대한 결과를 나타낸다. 또한 초기조건 설정에 따라 실험 결과가 달라지는데, 실험번호 1은 첫 번째 모의실험 결과, 실험번호 2는 두 번째 모의실험 결과 등을 나타낸다.

Table 2 Depth prediction for I-In type defect

실험 번호	MSE (학습데이터)	MSE	Max Error	MAPE (%)
1	0.00295	0.00575	0.062	0.5
2	0.00296	0.0231	0.273	1.48
3	0.00298	0.0212	0.271	1.29




Fig. 5 Depth prediction for I-In type defect. MLP output (predicted depth) and target value (actual depth) for validation data

Table 2로부터 Max Error는 실험번호 2번에서 0.273으로 가장 큰 것을 알 수 있으며, Fig. 5는 실험번호 2번에서 학습된 MLP에 대해서 평가데이터가 입력일 때의 MLP 출력결과를 나타낸다. 그림에서 x축은 각각의 데이터 식별번호를 나타내며, y축은 MLP의 출력, 즉 결함 깊이 추정치를 나타낸다. 여기서, 빨간 점선은 목표치(실제 결함깊이), 파란실선은 MLP출력(결함깊이 추정치)를 나타낸다. Fig. 5로부터 MLP 추정 성능이 매우 우수함을 알 수 있다.

4.1.2. I-In 결함 폭 추정

I-In 결함의 폭을 추정하기 위하여 MLP를 학습시켰다. 학습된 MLP의 결함 폭 추정성능은 학습 데이터와 평가 데이터의 추정성능을 모두 계산하여 비교하였으며, Table 3은 그 결과를 나타낸다.

Table 3으로부터 Max Error는 실험번호 1번에서 0.78로 가장 큰 것을 알 수 있으며, Fig. 6은 실험번호 1번에서 학습된 MLP에 대해서 평가데이터가 입력일 때의 MLP 출력결과를 나타낸다. 그림에서 x축은 각각의 데이터 식별번호를 나타내며, y축은

Table 3 Width prediction for I-In type defect

실험 번호	MSE (학습데이터)	MSE	Max Error	MAPE (%)
1	0,00298	0,0412	0,78	1,46
2	0,00296	0,026	0,34	1,52
3	0,00295	0,0302	0,63	0,84




Fig. 6 Width prediction for I-In type defect. MLP output (predicted width) and target value (actual width) for validation data

MLP의 출력, 즉 결함 폭 추정치를 나타낸다. 여기서, 빨간 점선은 목표치(실제 결함폭), 파란실선은 추정치를 나타낸다. Fig. 6으로부터 MLP 추정 성능이 매우 우수함을 알 수 있다.

4.2. I-Out 결함 크기 추정

I-Out 형태 결함의 크기 산정을 위해서 깊이와 폭에 대한 추정기를 두 개의 독립적인 MLP로 설계하였다.

4.2.1. I-Out 결함 깊이 추정

I-Out 결함의 깊이를 추정하기 위하여 MLP를 학습시켰다. 학습된 MLP의 결함 깊이 추정성능은 학습 데이터와 평가 데이터의 추정성능을 모두 계산하여 비교하였으며, Table 4는 그 결과를 나타낸다.

Table 4로부터 Max Error는 실험번호 3번에서 0.894로 가장 큰 것을 알 수 있는데, Fig. 7은 실험번호 3번에서 학습된 MLP에 대해서 평가데이터가 입력일 때의 MLP 출력결과를 나타낸다. 빨간 점선은 목표치(실제 결함깊이), 파란실선은 MLP출력(결

Table 4 Depth prediction for I-Out type defect

실험 번호	MSE (학습데이터)	MSE	Max Error	MAPE (%)
1	0,00298	0,0938	0,843	5,37
2	0,00287	0,0787	0,684	4,99
3	0,00297	0,106	0,894	7,35




Fig. 7 Depth prediction for I-Out type defect. MLP output (predicted depth) and target value (actual depth) for validation data

합깊이 추정치)를 나타낸다. 결함 깊이가 2 mm, 4 mm, 6 mm인 경우에는 우수한 추정 성능을 보여 주고 있으며, 다만, 8 mm, 100 mm인 경우에는 약 1 mm 정도의 추정오차가 존재함을 알 수 있다. 이러한 추정오차를 더욱 작게 하기 위해서는 깊이가 8 mm, 10 mm 데이터와 비슷한 데이터 (예를 들면, 11 mm 12 mm 등등)를 학습데이터가 포함하도록 하여야 할 것으로 판단된다. 한편, MLP가 적절히 학습되었는지를 확인하기 위하여 학습데이터에 대한 MLP추정 결과를 알아 보았으며, Fig. 8은 학습데이터에 대한 MLP 추정결과를 나타낸다. Fig. 8로부터 MLP 학습에는 문제가 없음을 알 수 있다.




Fig. 8 Depth prediction for I-Out type defect. MLP output (predicted depth) and target value (actual depth) for train data

4.2.2. I-Out 결함 폭 추정

I-Out 결함의 폭을 추정하기 위하여 MLP를 학습시켰다. 학습된 MLP의 결함 폭 추정성능은 학습 데이터와 평가 데이터의 추정성능을 모두 계산하여 비교하였으며, Table 5는 그 결과를 나타낸다.

Table 5로부터 Max Error는 실험번호 3번에서 3.09로 가장 크며, Fig. 9는 실험번호 1번에서 학습된 MLP에 대해서 평가데이터가 입력일 때의 MLP

Table 5 Width prediction for I-Out type defect

실험 번호	MSE (학습데이터)	MSE	Max Error	MAPE (%)
1	0,00298	0,142	1,96	14,4
2	0,00298	0,171	1,68	12,8
3	0,00295	0,298	3,09	22,3

출력결과를 나타낸다. 그림에서 빨간 점선은 목표치, 파란실선은 추정치를 나타낸다. Fig. 9로부터 MLP 추정 성능이 실제로 사용하기에 충분함을 알 수 있다.




Fig. 9 Width prediction for I-Out type defect. MLP output (predicted width) and target value (actual width) for validation data

4.3. V-In 결함 크기 추정

V-In 형태 결함의 크기 산정을 위해서 깊이와 폭에 대한 추정기를 두 개의 독립적인 MLP로 설계하였다.

4.3.1. V-In 결함 깊이 추정

V-In 결함의 깊이를 추정하기 위하여 MLP를 학습시켰다. 학습된 MLP의 결함 깊이 추정성능은 학습 데이터와 평가 데이터의 추정성능을 모두 계산하여 비교하였으며, Table 6은 그 결과를 나타낸다.

Table 6으로부터 Max Error는 실험번호 2번에서 0.526으로 가장 크며, Fig. 10은 실험번호 2번에서 학습된 MLP에 대해서 평가데이터가 입력일 때의 MLP 출력결과를 나타낸다. 그림에서 x축은 각각의 데이터를 나타내며, y축은 MLP의 출력을 나타내는데, 빨간 점선은 목표치, 파란실선은 추정치를 나타

Table 6 Depth prediction for V-In type defect

실험 번호	MSE (학습데이터)	MSE	Max Error	MAPE (%)
1	0,00299	0,038	0,368	3,47
2	0,00299	0,05	0,526	3,46
3	0,00292	0,035	0,372	3,13

낸다. Fig. 10로부터 MLP 추정 성능이 우수함을 알 수 있다.




Fig. 10 Depth prediction for V-In type defect. MLP output (predicted depth) and target value (actual depth) for validation data

4.3.2. V-In 결함 폭 추정

V-In 결함의 폭을 추정하기 위하여 MLP를 학습시켰다. 학습된 MLP의 결함 폭 추정성능은 학습 데이터와 평가 데이터의 추정성능을 모두 계산하여 비교하였으며, Table 7은 그 결과를 나타낸다.

Table 7로부터 Max Error는 실험번호 2번에서 1.01로 가장 크며, Fig. 11은 실험번호 2번에서 학습된 MLP에 대해서 평가데이터가 입력될 때의 MLP 출력결과를 나타낸다. 그림에서 x축은 각각의 데이터 식별번호를 나타내며, y축은 MLP의 출력, 즉 결함깊이 추정치를 나타내는데, 빨간 점선은 목표치, 파란실선은 추정치를 나타낸다. Fig. 11로부터 MLP 추정 성능이 우수함을 알 수 있다.

4.4. V-Out 결함 크기 추정

V-Out 형태 결함의 크기 산정을 위해서 깊이와 폭에 대한 추정기를 두 개의 독립적인 MLP로 설계하였다.

4.4.1. V-Out 결함 깊이 추정

V-Out 결함의 깊이를 추정하기 위하여 MLP를 학습시켰다. 학습된 MLP의 결함 깊이 추정성능은 학습 데이터와 평가 데이터의 추정성능을 모두 계산하여 비교하였으며, Table 8은 그 결과를 나타낸다.

Table 8로부터 Max Error는 실험번호 2번에서 1.41로 가장 크며, Fig. 12는 실험번호 2번에서 학습된 MLP에 대해서 평가데이터가 입력될 때의 MLP 출력결과를 나타낸다. 그림에서 x축은 각각의 데이터 식별번호를 나타내며, y축은 MLP의 출력을 나타내는데, 빨간 점선은 목표치, 파란실선은 추정치를 나타낸다. Fig. 12로부터 결함 깊이가 6 mm, 8 mm인 경우에는 매우 우수한 추정 성능을 보여주고 있으며, 다만 2 mm, 4 mm, 10 mm에서 약간의 추정 오차가 존재함을 알 수 있다. 이러한 추정오차를 줄이기 위해서는 좀 더 많은 학습데이터를 이용하여 MLP를 학습시키는 것이 필요할 것으로 판단된다. 한편, Fig. 13은 학습데이터에 대한 MLP 추정결과를 나타내는데, 이로부터 MLP 학습에는 문제가 없음을 알 수 있다.

Table 7 Width prediction for V-In type defect

실험 번호	MSE (학습데이터)	MSE	Max Error	MAPE (%)
1	0.00296	0.061	0.87	4.01
2	0.00299	0.074	1.07	4.73
3	0.00299	0.064	1.01	4.29




Fig. 11 Width prediction for V-In type defect. MLP output (predicted width) and target value (actual width) for validation data

Table 8 Depth prediction for V-Out type defect

실험 번호	MSE (학습데이터)	MSE	Max Error	MAPE (%)
1	0.00299	0.082	1.37	7.96
2	0.00299	0.088	1.41	6.93
3	0.00292	0.071	1.23	5.34




Fig. 12 Depth prediction for V-Out type defect. MLP output (predicted depth) and target value (actual depth) for validation data




Fig. 13 Depth prediction for V-Out type defect. MLP output (predicted depth) and target value (actual depth) for train data

4.4.2. V-Out 결함 폭 추정

V-Out 결함의 폭을 추정하기 위하여 MLP를 학습시켰다. 학습된 MLP의 결함 폭 추정성능은 학습 데이터와 평가 데이터의 추정성능을 모두 계산하여 비교하였으며, Table 9는 그 결과를 나타낸다.

Table 9로부터 Max Error는 실험번호 1번에서 2.33으로 가장 크며, Fig. 14는 실험번호 1번에서 학습된 MLP에 대해서 평가데이터가 입력될 때의

Table 9 Width prediction for V-Out type defect

실험 번호	MSE (학습데이터)	MSE	Max Error	MAPE (%)
1	0.00297	0.159	2.33	13.1
2	0.00296	0.137	1.98	11.8
3	0.00299	0.414	2.07	12.9

MLP 출력결과를 나타낸다. 그림에서 x축과 y축은 데이터 식별번호와 MLP의 출력을 각각 나타내며, 빨간 점선은 목표치, 파란실선은 추정치를 나타낸다.

Fig. 14로부터 MLP 추정 성능이 대체로 만족스러운 것을 알 수 있으며, 다만, 깊이가 2 mm, 4 mm (데이터 식별번호가 1 ~ 10번인 데이터)인 경우에 추정성능이 약간 저하되는 것을 알 수 있다.




Fig. 14 Width prediction for V-Out type defect. MLP output (predicted width) and target value (actual width) for validation data

5. 결 론

본 논문에서는 4가지 축대칭 결함, 즉 I-In 결함, I-Out 결함, V-In 결함, V-Out 결함의 와전류 탐상 시험(ECI) 신호로부터 결함의 깊이와 폭을 추정하는 연구를 수행하였다. 결함형태 분류를 위해서 [8]에서는 일반적으로 세 가지 특징을 사용하였는데, 본 논문에서는 [8]의 특징을 100 kHz와 400 kHz에 대해서 각각 생성하여 총 6가지 특징을 사용하였다. 추정 성능 검증을 위한 컴퓨터 모의실험 결과, I-In 형태 결함의 깊이와 폭을 추정할 때의 MAPE는 1.48%, 1.52% 이하이었고, I-Out 형태결함의 경우, 7.35%, 22.3% 이하이었다. 또한, V-In 형태 결함의 깊이와 폭의 추정오차의 MAPE는 3.47%, 4.73% 이하이었으며, V-Out 형태결함의 경우, 7.96%, 13.1% 이하이었다. 따라서, 대부분의 경우, 제안된 결함크기 추정기의 예측성능이 상당히 우수한 것으로 판단된다. 다만, I-Out 형태 결함 폭을 추정할 때의 MAPE가 22.3%로 다른 경우보다 다소 큰데, 이에 대한 추가적인 원인분석 및 성능 개선에 대한 연구가 필요한 것으로 보인다.

감사의 글

본 연구는 산업자원부의 지원에 의하여 기초전력 연구원(R-2005-7-073)주관 및 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. 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. 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, No. 4, pp. 233-243, (2000)
- [8] 조남훈, 이항범, 한기원, 송성진 "신경회로망을 이용한 원전SG 세관 결함패턴 분류성능 향상 기법", 전기학회 논문지, Vol. 56, No. 7, pp. 1224 - 1230, July, (2007)
- [9] H. Haoyu and T. Takagi, "Inverse analyses for natural and multicroacks using signals from a differential transmit-receive ECT probe," IEEE Trans. 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, New Jersey: Prentice-Hall, (1999)