

신경회로망을 이용한 원전SG 세관 결합패턴 분류성능 향상기법

論文

56-7-8

Performance improvement of Classification of Steam Generator Tube Defects in Nuclear Power Plant Using Neural Network

趙南熏*·李享範†·韓基元**·宋城鎮***
(Nam-Hoon Jo·Hyang-Beom Lee·Ki-Won Han·Sung-Jin Song)

Abstract – In this paper, we study the classification of defects at steam generator tube in nuclear power plant using eddy current testing(ECT). We consider 4 defect patterns of SG 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. In order to improve the classification performance, we propose new feature extraction technique. After extracting new features from the generated ECT signals, multi-layer perceptron is used to classify the defect patterns. Through the computer simulation study, it is shown that the proposed method achieves 100% classification success rate while the previous method yields 91% success rate.

Key Words : Eddy Current Testing (ECT), Steam Generator (SG), Neural Network, Pattern Recognition, Feature Extraction, Back-propagation

1. 서 론

1970년대 이후 집중적으로 건설되어 상업 운전 중인 국내 원자력발전소의 운전연한이 증가됨에 따라 건전성 상실에 대한 사회적 우려가 매우 심각한 문제로 대두되고 있다. 이러한 사회적 우려를 해소하고 원전을 안전하게 운영·관리하기 위해서는 적절한 원전 수명관리 규제 기술의 확보가 무엇보다도 중요한 과제이다. 현재 가동중인 원자력발전소의 건전성 확보를 위해 주기적인 가동중검사(In-Service Inspection; ISI)와 온라인모니터링(on-line monitoring)을 통한 운전중 감시가 실시되고 있다. 이러한 프로그램에서는 원전 주요 기기의 열화 및 노후화 감지를 위한 여러 가지 비파괴검사가 수행되고 있으며, 이러한 비파괴검사의 결과를 바탕으로 파괴역학적 관점에서의 수명평가가 수행되고 있다. 따라서, 원전설비의 수명관리를 위한 핵심기술은 크게 원전설비의 열화 및 노후화 확인 평가를 위한 비파괴검사(Non-Destructive Testing: NDT) 기술과 수명평가를 위한 파괴역학분석(Fracture Mechanics Analysis; FMA) 기술로 분류할 수 있다. 비파괴검사기술은 수명관리의 첫 단계이며, 그 이후 이어지는 모든 수명관리 활동에 대한 기본 자료를 제공하는 핵심 과정이기 때문에 그 신뢰성 확보가 무엇보다도 중요시되고 있다. 원전 설비 중 원자력 발전소 증기발생기 세관은 원자로를 거치는 1차 계통수와 2차 계통수 사이

에서 열을 전달하고 터빈 발전기를 돌리는 증기를 발생시키며 동시에 방사능 차단벽으로서 중요한 기능을 하고 있다. 증기발생기 세관은 가동 특성상 결합발생 가능성이 매우 높으며, 실제로 원전 수명관리에 큰 영향을 미치고 있다. 따라서, 원전의 노후화가 진행됨에 따라 발생하는 다양한 전열관의 결합을 검출하기 위한 신뢰할만한 검사법의 확보가 필요하다. 특히, 2002년 울진 4호기의 세관 파단사고 이후, 증기발생기 세관의 미세한 결합을 더욱 정밀하게 감지할 수 있는 비파괴 검사기법의 필요성은 더욱 증가하고 있다.

증기발생기 전열관에 대해서는 여러 가지 비파괴 검사 기법 중 주로 와전류탐상시험(Eddy Current Testing: ECT) 방법이 적용된다. 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 결합의 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, 결합 신호를 이론적으로 예측코자 하는 연구를 경쟁적으로 수행하고 있다 [1-4]. 또한, 한편으로는 신경회로망 기법 등 최첨단 인공지능 기술을 적용하여 결합신호를 분석하여 결합의 위치, 종류, 크기 등을 자동적으로 결정하는 기법의 개발에 심혈을 기울이고 있다 [5-9]. 이러한 결합 검출 기법이 성공적으로 개발되기 위해서는 결합신호로부터 결합의 종류, 크기 등을 정확하게 구별할 수 있는 특징(feature) 추출 또한 매우 중요한 연구 분야 중의 하나이다.

최근에 4가지 결합형태, 즉 I형 관내벽 결합, I형 관외벽

* 교신저자, 正會員 : 崇實大 工大 電氣工學部 副教授 · 工博
E-mail : hyang@ssu.ac.kr

* 正會員 : 崇實大 工大 電氣工學部 助教授 · 工博

** 正會員 : 崇實大 工大 電氣工學部 석사과정

*** 正會員 : 成均館大 工大 機械工學部 教授 · 工博

接受日字 : 2007年 3月 27日

最終完了 : 2007年 5月 30日

결합, V형 관내벽 결합, V형 관외벽 결합 분류기법이 [7]에서 발표되었다. [7]에서는 전자기 수치해석을 이용하여 ECT 신호를 생성한 후, 임피던스 평면에서 11개의 특징을 추출하여 결합 패턴을 분류하였다. 표기를 간단히 하기 위해서 위의 결합을 각각 I-In, I-Out, V-In, V-Out 결합으로 표시하며, 그림 1은 I-Out 결합과 V-Out 결합을 나타낸다.

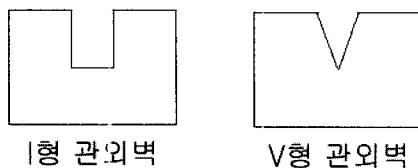


그림 1 I형 관외벽 결합과 V형 관외벽 결합

Fig. 1 The I-shaped flaw in the outer diameter and the V-shaped flaw in the outer diameter

본 논문에서는 서로운 특징추출을 제안하여 [7]에서 제시한 결합패턴 분류기의 분류성능을 더욱 향상시키고자 한다. 즉, [7]에서 사용한 결합패턴에 대해서 [7]이 11개의 특징을 이용하였던 것과 비교하여, 본 논문에서는 새로운 방식으로 3개의 특징을 추출하여 사용할 것을 제안한다. 또한, 기존 연구결과에서는 전술한 11가지 특징을 확률신경회로망(PNN)의 입력으로 사용하여 패턴을 분류하였다. 이와 비교하여, 본 연구에서는 PNN 대신 일반화성능이 우수한 것으로 알려져 있는 다층퍼셉트론(MLP)을 사용하여 분류기를 설계하고자 한다. [7]에서 생성한 ECT 결합신호에 대해서, 기존의 연구결과의 분류 정확도가 91%이었던 것과 비교하여, 본 논문에서 제안하는 방식을 사용할 경우 분류정확도를 100%로 향상시킬 수가 있음을 컴퓨터 모의실험을 통하여 입증하고자 한다.

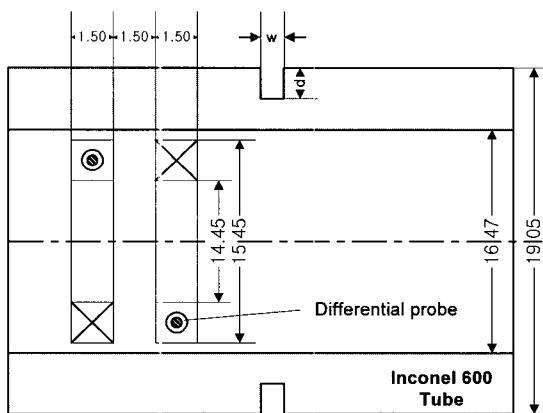


그림 2 축대칭 결합신호 분석을 위한 SG세관 단면도
Fig. 2 A cross section of SG tube for the analysis of axisymmetric flaw signals

2. 결합패턴 분류를 위한 새로운 특징추출

와전류 패턴인식을 위해서는 형상인식 알고리즘 개발의 기반이 되는 충분한 양의 와전류 결합신호 표본들이 필요하다. 본 논문에서는 그림 2와 같은 축대칭 결합신호를 분류하는 것을 목표로 한다. 이를 위해서, 본 연구에서는 축대칭 전자기 수치해석 프로그램으로부터 이론적 표본들을 수집하였다. 이때 수치해석 모델에서 사용한 Inconel 600 관의 크기와 탐상조건에 대한 자료를 정리하면 그림 2와 같다.

축대칭 수치해석 계산을 위해 I형 결합과 V형 결합에 동일한 수의 와전류 탐상시험(ECT) 신호를 생성하였다. 먼저, 표 1에 나타낸 것처럼 결합의 종류를 형상에 따라 2가지(I/V-type), 위치에 따라 2가지(관내벽/관외벽) 총 4가지로 구분하였다. 그 후, 각 범주에 속한 결합의 크기(폭과 깊이)를 다양하게 변화시킨 후, 각 결합에 대해 와전류탐상 주파수를 2가지(100kHz / 400kHz)로 변화시켜 가면서 I-type 결합에 대해서 200개, V형 결합에 대해서 200개의 결합신호를 생성하였다. 여기서, 결합의 깊이는 0.1, 0.2, ~, 1.0mm의 값을 사용하였고, 결합의 폭은 0.2, 0.4, 0.6, 0.8, 1.0mm의 값을 사용하였다.

표 1 축대칭 결합신호의 샘플 데이터

Table 1 Sample data of axisymmetric flaw signals

결합 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

결합신호의 패턴 분류를 위해서 기존의 연구결과 [7]에서는 ECT 결합신호의 특징 11가지(최대 저항값, 최대 저항값을 갖는 점의 위상, 최대 리액턴스값, 최대 리액턴스값을 갖는 점의 위상, 결합 신호 시작점의 출발각, 결합 신호 끝점의 도착각 등등)를 추출하였다. 위와 같은 11가지 특징으로 구성된 특징벡터를 이용하여 확률신경회로망(PNN) 분류기를 구성하였다. 이러한 분류기를 사용할 경우 I-Out, V-Out, V-In 결합에 대해서는 대부분 정확하게 분류할 수 있었다. 하지만, I-In 결합에 대해서는 25개의 샘플신호 중 8개를 V-In 결합으로 분류하여, 잘못 분류하는 경우가 $8/25*100 = 32\%$ 로 매우 높다는 연구결과가 발표되었다 [7]. 이는 연구결과 [7]의 특징추출을 좀 더 개선할 필요가 있음을 의미한다.

본 논문에서는 분류 정확도를 개선하기 위하여 그림 3과 같은 새로운 특징 3가지를 제안한다. 그림 3은 차동(Differential) 프로브로 얻은 ECT 신호를 임피던스 평면에서 나타낸 것으로, x축과 y축은 각각 저항과 리액턴스를 나타낸다. 그림 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

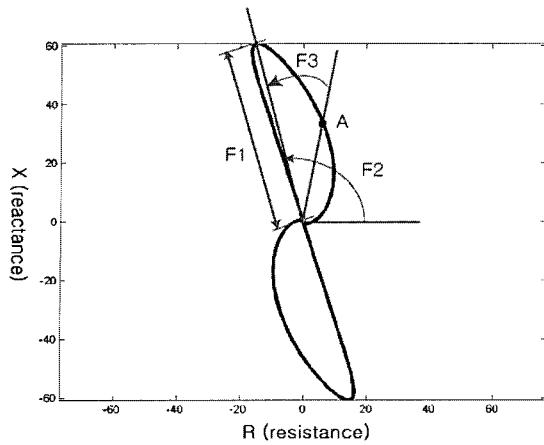


그림 3 결합 형태 분류를 위해 제안된 새로운 특징추출. 위 그림은 차동(Differential) 프로브로 얻은 ECT 신호를 임피던스 평면에서 나타낸 것임. 새로운 특징 F3는 최대 임피던스 값을 갖는 점과 최대 임피던스값의 1/2의 값을 갖는 점 (A로 표시) 사이의 위상각을 나타냄

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.

임피던스값의 1/2의 값을 갖는 점 A 사이의 위상각을 의미한다. F1과 F2는 기존의 특징과 동일하며, F3가 새로이 제안된 특징임을 알 수 있다. 새로운 특징 F3는 결합형태 I-In과 V-In을 효과적으로 구별하기 위하여 추가된 특징으로, 이 특징에 의해 I-In과 V-In을 효과적으로 구별할 수 있다는 것을 4장에서 살펴볼 것이다.

3. 다층 퍼셉트론

본 논문에서 제안하는 결합패턴 분류 시스템의 식별기(classifier)로는 신경회로망(Neural Network)의 일종인 다층 퍼셉트론(Multi-layer Perceptron)을 사용한다. 다층 퍼셉트론(MLP)은 입력층과 출력층 사이에 하나 이상의 은닉층(hidden layer)이 존재하는 신경망이다. 그림 4는 세 개의 층, 즉 두 개의 은닉층으로 구성된 다층 퍼셉트론의 구조를 나타낸다. 다층 퍼셉트론(MLP)은 단층 퍼셉트론과 구조가 유사하지만, 중간층과 각 층의 입력 출력 특성이 비선형으로 표현되어 단층 퍼셉트론이 해결 할 수 없던 문제들을 해결할 수 있다 [10, 11].

MLP의 은닉층의 개수는 특별한 경우가 아니면 하나로 구성하기 때문에 본 논문에서도 하나로 구성하였다. 한편, 은닉층에 존재하는 뉴론의 개수는 MLP의 분류성능에 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 분류 성능이 오히려 저하되는 경우가 많다. 본 논문에서는 여러 번의 모의실험을 통해 뉴런의 개수를 10개로 결

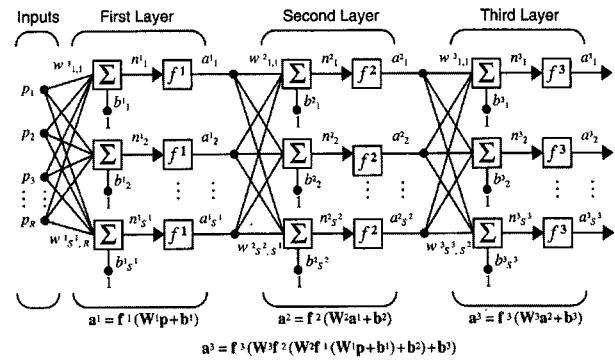


그림 4 두 개의 은닉층을 갖는 다층 퍼셉트론 구조

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

정하였다. 또한, 은닉층의 뉴론의 활성화함수(activation function)는 log sigmoid 함수를 사용하였다. MLP의 학습에는 오차 역전파(Error Back-propagation) 알고리즘, 모멘텀(Momentum) 알고리즘, 결합 경사(Conjugate Gradient) 알고리즘 등이 사용되는데, 알고리즘 구조가 복잡하지만 학습 속도가 가장 빠른 것으로 알려져 있는 결합 경사 알고리즘을 사용한다 [11]. 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. 구간 선정을 위한 최대 반복 횟수는 100, 구간 축소를 위한 최대 반복 횟수는 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 초기조건의 설정이 매우 중요한데, 본 연구에서는 초기조건을 랜덤함수로 생성하여 결정하였다. 또한, MLP는 유일한 해(unique solution)로 수렴하는 것이 보장되지 않기 때문에 여러 번의 컴퓨터 모의실험이 필요한데, 본 연구에서는 컴퓨터 모의실험을 3회 수행하여 그 결과를 분석하였다.

4. 컴퓨터 모의실험

본 논문에서 제안하는 결합분류기의 우수성을 입증하기 위하여 본 절에서는 컴퓨터 모의실험을 수행한다. 제안된 분류기의 분류성능을 측정하기 위해서는 학습데이터(train data)와 평가데이터(test data)를 구별하여야 한다. 와전류 탑상 주파수가 100kHz인 실험 데이터를 수치해석 프로그램으로 200개를 생성시켰으며, 이중에서 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 사용하였다.

4.1 I-In 형태 분류기

I-In 형태의 결합을 분류하기 위하여 I-In 형태 결합 패턴의 목표값(target)을 1, I-In 형태 결합이 아닌 결합(즉,

표 2 I-In 형태 결함 분류기 성능

Table 2 The classification performance for the I-In type flaw

실험번호	MSE	분류성공율(%)	최대 오차
1	0.0042	100	0.1
2	0.0041	100	0.17
3	0.0044	100	0.21

I-Cut, V-In, V-Cut 형태 결함) 패턴의 목표값을 0으로 설정하여 MLP를 학습시킨 후, 분류성능을 평가하였다. 평가시에는 MLP의 출력값이 0.5이상인 패턴은 I-In 형태 결함으로, 0.5이하인 패턴은 I-Out, V-In, V-Out 형태 결함 패턴으로 분류하였다. 또한, 평가데이터(test data)에 대한 분류성능은 평가데이터에 대한 MSE(Mean Square Error)와 최대오차(Max Error)를 사용하여 측정하였다. 결함패턴을 분류하기 위한 특징 벡터는 그림 3에서 정의한 F1, F2, F3를 이용하여

[F1, F2, F3]

로 설정하였다. 한편, 초기조건의 설정에 따라 MLP 결과가 달라지기 때문에 모의실험을 3회를 수행하여 그 경향을 분석하였다. 평가데이터에 대한 패턴 분류 결과를 표 2에서 볼 수 있다. 표 2에서 오차는 아래와 같이 정의되는데

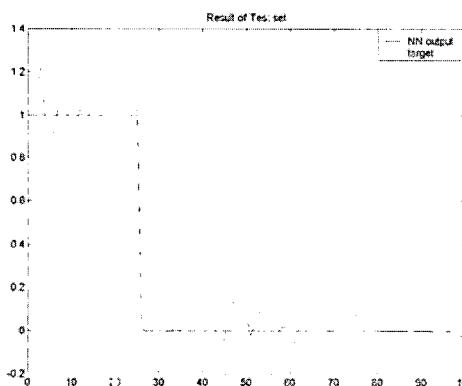


그림 5 I-In 형태 결함 분류기 성능 (표 2의 실험번호 3번에서 학습된 MLP의 성능). x축은 데이터 식별번호를 나타내는데, 1~25는 I-In 데이터, 26~50은 I-Out 데이터, 51~75는 V-In 데이터, 76~100은 V-Out 데이터를 의미함. y축은 MLP의 출력을 나타내는데, 빨간색은 목표값, 파란색은 MLP의 출력을 나타냄. MLP 출력이 0.5보다 크면 I-In 형태로 분류하고 0.5보다 작으면 I-In 형태가 아닌 다른 결함으로 분류함.

Fig. 5 The classification performance for the I-In type flaw (when MLP of the number 3 in Table 2 is used). The x coordinate represents the data identification number and the y coordinate stands for the output of MLP (red and blue line indicate the target value and the output of MLP, respectively). If the output of MLP is greater than 0.5, then the input is classified as I-In type flaw.

표 3 I-Out 형태 결함 분류기 성능

Table 3 The classification performance for the I-Out type flaw

실험번호	MSE	분류성공율(%)	최대오차
1	0.0051	100	0.29
2	0.0043	100	0.25
3	0.0060	100	0.32

$$\text{오차} = |\text{목표값} - \text{MLP 출력값}|,$$

앞서와 같이 목표값을 설정할 경우, 오차가 0.5 이상이 되면 그 패턴에 대한 패턴 분류는 잘못된 것이라는 것을 알 수 있다. 또한, 최대오차는 각각의 평가 데이터에 대한 오차를 계산한 후, 이 오차들의 최대값으로 정의하였다. 표 2로부터 최대오차는 실험번호 3번에서 0.21로 가장 크지만 0.5보다 작기 때문에 분류 성공률은 100%임을 확인할 수 있다.

마지막으로 평가데이터 분류성공율은 $\frac{Sa-n}{Sa} * 100$ 으로 계산되는데, Sa 와 n 은 각각 I-In형태 데이터 개수(여기서는 50)와 오차가 0.5보다 큰 평가 데이터의 개수를 나타낸다. 예를 들어 2개의 데이터에 대한 오차가 0.5 이상이었다고 하면 분류성공율은 96%가 된다. 표 2로부터 세 번의 모의실험 중 가장 성능이 좋지 않았던 경우(즉, 최대오차가 가장 큰 경우인 실험번호 3의 경우)도 분류성공율이 100%임을 알 수 있다. 이는 기존 연구결과 [7]의 분류성공율 68%에 비해서 상당한 개선이 이루어졌음을 의미한다.

그림 5는 표 2의 실험번호 3번에서 학습된 MLP에 대해서 평가데이터가 입력일 때의 MLP 출력결과를 나타낸다. 그림에서 빨간색은 목표값이고 파란색은 MLP의 출력값을 나타내는데, 이 차이가 작을수록 패턴 분류 성능이 우수하다는 것을 의미한다. 또한, x축은 각각의 데이터를 나타내는

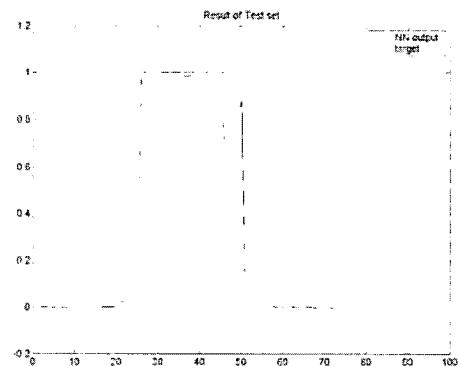


그림 6 I-Out 형태 결함 분류기 성능 (표 3의 실험번호 3번에서 학습된 MLP의 성능). x축은 데이터 식별번호, y축은 MLP 출력 및 목표값을 나타냄.

Fig. 6 The classification performance for the I-Out type flaw (when MLP of the number 3 in Table 3 is used). The x coordinate represents the data identification number and the y coordinate stands for the output of MLP

표 4 V-In 형태 결합 분류기 성능

Table 4 The classification performance for the V-In type flaw

실험번호	MSE	분류성공율(%)	최대오차
1	0.0036	100	0.154
2	0.0035	100	0.162
3	0.0035	100	0.186

데, 1~25는 I-In 데이터, 26~50은 I-Out 데이터, 51~75는 V-In 데이터, 76~100은 V-Out 데이터를 의미한다. 또한, y축은 MLP의 출력을 나타내며, 이 값이 0.5보다 크면 I-In 형태로 분류하고 0.5보다 작으면 I-Out, V-In, V-Out 형태로 분류한다. 그림 5로부터 x=3에 해당하는 데이터에 대해서 오차가 0.21임을 알 수 있고 이 값이 실험번호 3번의 최대오차이다. 그림 5로부터 모든 평가 데이터에 대해서 I-In 결합을 완벽하게 분류할 수 있다는 것을 확인할 수 있다.

4.2 I-Out 형태 분류기

I-Out 형태 결합을 분류하기 위하여 I-Out의 목표값을 1, I-In, V-In, V-Out의 목표값을 0으로 설정한 후 MLP를 학습시킨 후, 분류 성능을 평가하였다. 평가 시에는 MLP의 출력 값이 0.5 이상인 패턴은 I-Out으로, 0.5 이하인 패턴은 I-In, V-In, V-Out으로 분류하였다. 또한, 분류 성능은 평가 데이터에 대한 MSE와 최대오차를 사용하여 측정하였다. 특징 벡터는 4.1 절과 동일한 벡터를 사용하였으며, 학습된 MLP의 평가 데이터에 대한 분류 성능을 표 3에 정리하였다. 표 3으로부터 최대오차는 실험 번호 3번에서 0.32로 가장 크지만 0.5보다 작기 때문에 분류 성공률은 100%임을 확인할 수 있다. 그림 6은 실험 번호 3번에서 학습된 MLP에 대해서 평가

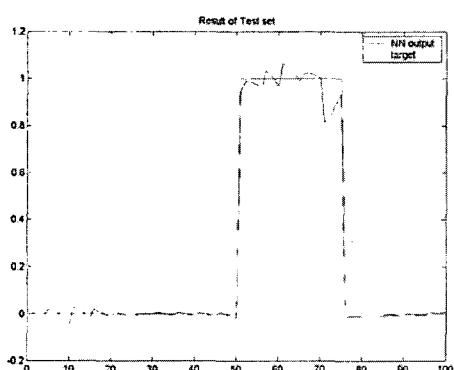


그림 7 V-In 결합 분류기 성능 (표 4의 실험번호 3번에서 학습된 MLP의 성능). x축은 데이터 식별번호, y축은 MLP 출력 및 목표값을 나타냄.

Fig. 7 The classification performance for the V-In type flaw (when MLP of the number 3 in Table 4 is used). The x coordinate represents the data identification number and the y coordinate stands for the output of MLP

표 5 V-Out 형태 결합 분류기 성능

Table 5 The classification performance for the V-Out type flaw

실험번호	MSE	분류성공율(%)	최대 오차
1	0.0033	100	0.16
2	0.0046	100	0.22
3	0.0045	100	0.21

데이터가 입력일 때의 MLP 출력 결과를 나타낸다. 그림에서 x축은 각각의 데이터를 나타내는데, 1~25는 I-In 데이터, 26~50은 I-Out 데이터, 51~75는 V-In 데이터, 76~100은 V-Out 데이터를 의미한다. 또한, y축은 MLP의 출력을 나타내며, 이 값이 0.5보다 크면 I-Out으로 분류하고 0.5보다 작으면 I-In, V-In, V-Out 형태로 분류한다. 그림 6으로부터 모든 평가 데이터에 대해서 우수한 분류 성능을 갖고 있는 것을 확인할 수 있다.

4.3 V-In 형태 분류기

V-In 형태 결합을 분류하기 위하여 V-In의 목표값을 1, I-In, I-Out, V-Out의 목표값을 0으로 설정한 후 MLP를 학습시킨 후, 분류 성능을 평가하였다. 평가 시에는 MLP의 출력 값이 0.5 이상인 패턴은 V-In으로, 0.5 이하인 패턴은 I-In, I-Out, V-Out으로 분류하였다. 특징 벡터는 4.1 절과 동일한 벡터를 사용하였으며, 학습된 MLP의 평가 데이터에 대한 분류 성능을 표 4에 정리하였다. 표 4로부터 최대오차는 실험 번호 3번에서 0.186으로 가장 크지만 0.5보다 작기 때문에 분류 성공률은 100%임을 확인할 수 있다. 그림 7은 실험 번호 3번에서 학습된 MLP에 대해서 평가 데이터가 입력일 때의 MLP 출력 결과를 나타낸다. 그림에서 x축은 각각의 데이터를 나타내는데, 1~25는 I-In 데이터, 26~50은 I-Out 데이터

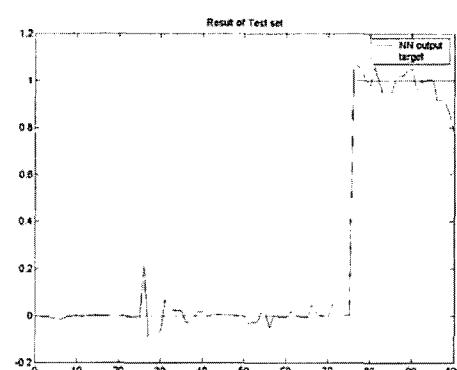


그림 8 V-Out 분류기 성능 (표 5의 실험번호 2번에서 학습된 MLP의 성능). x축은 데이터 식별번호, y축은 MLP 출력 및 목표값을 나타냄.

Fig. 8 The classification performance for the V-Out type flaw (when MLP of the number 2 in Table 5 is used). The x coordinate represents the data identification number and the y coordinate stands for the output of MLP

터, 51~75는 V-In 데이터, 76~100은 V-Out 데이터를 의미한다. 또한, y축은 MLP의 출력을 나타내며, 이 값이 0.5보다 크면 V-In으로 분류하고 0.5보다 작으면 I-In-, I-Out-, V-Out으로 분류한다. 그럼 7로부터 모든 평가 데이터에 대해서 우수한 분류 성능을 갖고 있는 것을 확인할 수 있다.

4.4 V-Out 형태 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, 평가 데이터에 대한 분류 성능은 평가데이터에 대한 MSE와 최대오차를 사용하여 측정하였다. 특징 벡터는 앞서와 동일한 벡터를 사용하였으며, 학습된 MLP의 분류성능을 표 5에 정리하였다. 표 5로부터 최대오차는 실험번호 2번에서 0.22로 가장 크지만 0.5보다 작기 때문에 분류 성공률은 100%임을 확인할 수 있다. 그림 8은 실험번호 2번에서 학습된 MLP에 대해서 평가데이터가 입력일 때의 MLP 출력결과를 나타낸다. 그림에서 x축은 각각의 데이터를 나타내는데, 1~25는 I-In 데이터, 26~50은 I-Out 데이터, 51~75는 V-In 데이터, 76~100은 V-Cut 데이터를 의미한다. 또한, y축은 MLP의 출력을 나타내며, 이 값이 0.5보다 크면 V-Out으로 분류하고 0.5보다 작으면 I-In, I-Out V-In으로 분류한다. 그림 8로부터 모든 평가 데이터에 대해서 우수한 분류 성능을 갖고 있는 것을 확인할 수 있다.

5. 결 론

본 논문에서는 새로운 특징추출방식과 MLP를 사용하여 증기세관 결함패턴을 분류하는 기법을 제시하였다. 제안된 특징추출을 이용하여 결함패턴을 I-In, I-Out, V-In, V-Out 형태로 분류한 결과 기존의 특징추출을 이용한 방법보다 효과적임을 알 수 있었다. 기존의 패턴 분류방식이 11개의 특징을 사용하였던 것과 비교하여 본 연구에서 제시한 특징 벡터는 3개의 특징만을 사용하였다. 또한, 기존의 분류방식의 분류 정확도가 91%이었던 것을 새로운 방식의 특징추출을 이용할 경우 100%로 향상시킬 수가 있음을 컴퓨터 모의 실험을 통하여 입증하였다. 특히, 분류기로 사용된 MLP의 특성상, 초기조건이 분류성능에 영향을 미치게 되는데, 3번의 모의실험을 수행했을 때 모두 우수한 분류 성능을 갖고 있다는 것을 알 수 있었다.

향후에, 분류 성능을 더욱 개선하기 위해서는 추가적인 특징추출 및 선제적 정지(Early Stopping) 전략, 교차검증에 의한 은닉층내의 최적의 뉴런 개수 결정 등에 대한 연구가 추가적으로 필요할 것으로 보인다.

감사의 글

본 연구는 산업자원부의 지원에 의하여 기초전력연구원(R-2005-7-073)주관 및 숭실대학교 교내연구비 지원으로 수행되었음.

참 고 문 헌

- [1] E.E. Kriezis, T.D. Tsiboukis, S.M. Panas, 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, pp. 233-243, 2000.
- [8] H. Haoyu, and T. Takagi, "Inverse analyses for natural and multicracks using signals from adifferential transmit-receive ECT probe," *IEEE Trans. Magnetics*, vol. 38, no. 2, part 1, pp. 1009-1012, 2002.
- [9] 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.
- [10] M.T. Hagan, H.B. Demuth, and M.H. Beale, *Neural Network Design*, PWS Pub. Co, 1995.
- [11] S. Haykin, *Neural Networks*, New Jersey: Prentice-Hall, 1999.

저자 소개



조 남 훈 (趙 南 熏)

1992년 서울대 공대 전기공학과 졸업.
2000년 서울대 대학원 전기공학부 졸업
(공박). 2000년~2001년 서울대 자동화시스템공동연구소 연구원. 2001년~2002년 삼성전자 DVS사업부 책임연구원. 2002년~현재 숭실대학교 전기공학부 조교수.
2006년~현재 대한전기학회 영문논문지 편집위원, 2004년~
현재 제어자동화시스템공학회 국문논문지 편집위원. 연구
분야는 패턴인식 및 비파괴 검사에의 응용, 예측이론, 제
어 시스템 및 시스템 생물학에의 응용.

Tel : 02-820-0643

E-mail : professor.jo@daum.net, nhjo@ssu.ac.kr

Homepage : <http://ee.ssu.ac.kr/~nhjo>



한 기 원 (韓 基 元)

2006년 숭실대 공대 전기제어시스템 공학부 졸업. 2006년~현재, 숭실대 공대 전기공학부 석사과정. 연구분야는 패턴인식, 외관판별기, MPC
Tel : 02-824-0640
E-mail : kwhan79@paran.com



이 향 범 (李 享 範)

1989년 서울대 공대 전기공학과 졸업.
1995년 서울대 대학원 전기공학부 졸업
(공박). 1995년~1996년 기초전력공학공동
연구소 전임연구원. 1996년~1998년 국립
군산대학교 전임강사. 1998년~현재 숭실
대학교 전기공학부 부교수. 연구분야는
전기기기, 전자기수치해석, 비파괴검사.

Tel : 02-820-0641

E-mail : hyang@ssu.ac.kr



송 성 진 (宋 城 鎮)

1981년 서울대 공대 기계공학과 졸업.
1991년 미국 아이오와주립대 기계공학과
졸업(공박). 1983년~1987년 대우중공업
(주) 전략기획부 대리. 1992년~1993년 포
항산업과학기술연구소 계측연구실 주임
연구원. 1993년~1998년 조선대학교 기계
설계공학과 조교수. 1998년~2000년 성균관대학교 기계공
학부 조교수. 2000년~2006년 성균관대학교 기계공학부 부
교수. 2006년~현재 성균관대학교 기계공학부 교수. 2000
년~현재 한국비파괴검사학회 편집이사, 2004년~현재 한국
압력기기공학회 사업이사

Tel : 031-290-7451

E-mail : sjsong@skku.edu