'00 춘계학술발표회 논문집
한국원자력학회

금속파편진단을 위한 신경회로망 적용에 관한 연구

A study of diagnosis of Loose Part Monitoring System using Neural Network

김정수, 황인구, 김태완, 송순자, 함창식
한국원자력연구소

황두성, 박욱기
한국전력공사

요 약

금속파편은 원전의 건설시 혹은 보수공사시 외부에서 유입되거나 원전 자체의 진동에 의해 원전 내부에서 발생하며 주요 구조물에 치명적인 손상을 입힘으로서 원전의 안전성에 많은 영향을 끼친다. 본 논문은 최근 인공지능기법으로 많이 사용되고 있는 신경회로망 이론을 금속파편 진단(질량추정)에 적용하여 진단 가능성을 제시하였다. 신경회로망에서 사용된 알고리즘은 역전파 알고리즘(Back Propagation Network)을 사용하였으며, 세 가지의 입력변수(Rising Time, Half Period, Maximum amplitude)를 이용하였다. 영광 3호기 시운전시 강구의 충격 데이터로 미리 학습을 시킨 후 실제 금속파편 신호와 비교/분석하여 질량값을 추정하였다. 분석한 결과 비교적 만족할 만한 결과를 얻어 금속파편 진단에 신경회로망의 적용이 가능할 것으로 판단하였다.

Abstract

It is known that loose parts in the reactor coolant systems (RCS) cause serious damage into the systems. We applied the neural network algorithm to LPMS in order to estimate the mass of loose parts. We trained the impact test data of YGN3 using the backpropagatiom method. The input parameter for training is Rising Time, Half Period, Maximum amplitude. The result showed that the neural network would be applied to LPMS.

이 연구는 과학기술부 원자력 성과이전 과제의 지원을 받아 수행하였음

1. 서 론

원자력 발전소 냉각재 계통내의 금속파편은 유체유동, 응력 부식, 구조요소간 비정상적 마찰 등에 의해 구조물로부터 분리되거나 원전 건설기간 핵연료 재장전, 기타 보수활동시 외부로부터 금속이물질이 계통 내로 유입됨으로써 발생된다. 금속파편은 계통내 구조물들을 취약하게 하거나 파손을 일으키므로 이러한 금속파편에 대한 분석 알고리즘은 원자로의 운전성 및 안전성과 직결된다. 그러므로 원자력 발전소에는 이들 금속파편을 감시하기 위한 금속파편 감시시스템 (LPMS, Loose Parts Monitoring System)이 설치, 운용되고 있다. 그러나, 국내 원전에 설치되어있는 금속파편 감시계통은 금속파편이 발생된 위치나 금속파편의 질량에 대한 정보는 제공하지 않고 단지 경보 발생 및 기록을 수행하는 단계에 머무르고 있다[1]. 현재의 금속파편 시스템을 개선하기 위해 본 논문에서는 원자력 발전소 내에 발생하는 금속파편진단을 위해 최근 많이 사용되고 있는 인공지능기법인 Neural Network을 적용하여 가능성을 제시하였다.

금속파편 충격신호를 분석하여 질량을 판별하는 기존의 방법은 전력스펙트럼 밀도(PSD)를 이용한 질량 평가법[2], 중심 주파수를 이용하는 질량 평가법[3] 및 Hertz의 충격이론[4, 5, 6, 7, 8]을 이용하는 방법 등이 있다. 이 방법들중 전력스펙트럼 밀도(PSD)를 이용한 질량 평가법과 중심 주파수를 이용하는 질량 평가법은 센서의 공진 및 배경잡음이 발생할 때 정확한 충격질량을 판별하기가 어렵다. Hertz 충격이론을 기본으로 하는 질량추정 기법은 무한평면에 반구를 충격 시킨다는 가정하에 금속파편의 질량을 추정하는 이론이나 이러한 Hertz 이론을 기반으로 금속파편을 추정하는 알고리즘을 개발하였다[9,10,11]. 그러나 발전소의 구조가 무한평면이 아니고 또한 실제 발생되는 금속파편이 반구가 아니기 때문에 Hertz 이론을 바탕으로 금속파편의 질량값을 추정하는 경우, 상당한 오차가 발생하는 것으로 알려져 있다. 본 논문은 이러한 Hertz 이론을 기반으로 수정 알고리즘을 보완할 수 있는 신격회로망 이론은 이용하여 금속파편의 질량값을 추정하여 신격회로망 이론의 적용 가능성을 제시하였다. 이 금속파편의 알고리즘의 유용성을 판단하기 위해 영광 3호기 시 운전데이터를 이용하였다. 본 논문의 2장에서 신경회로망의 역전파 알고리즘에 대한 기본적인 이론을 제시하였고, 3장에서는 실제 영광 3호기 시운전 데이터를 이용한 실험결과를 설명하였으며, 마지막으로 4장에는 결론 및 추후 연구 방향에 대해 제시하였다.

2. 신경회로망 이론

2.1 역전파 (BackPropagation) 알고리즘[12,13,14,15]

역전파 신경회로망(BP)의 학습알고리즘은 룸멜하트에 의해 제안된 알고리즘으로 ⊿-rule이 이용되고 있다. 이 규칙에 의한 학습은 현재 주어진 연결강도로 생성되는 오차값을 구하여 이를

감소시키는 방향으로 연결강도의 값을 조정하게 된다. 즉, 일반화된 ⊿-rule은 가중치 변화에 대한 오차의 최대 경사를 이용한다. 출력층의 오차는 목표값과 실제 출력값 사이의 차이로 쉽게 계산할 수 있다. 이 역전파 신경회로망은 먼저 입력벡터를 이용하여 실제 출력값을 계산하고 만일 이 값과 미리 정해진 목표값과의 사이에 오차가 발생하지 않으면 학습이 이루어지지 않고 오차가 존재하면 식 (1) 에 의해 가중치가 변화되고 이에 따라 학습이 이루어진다. 그림 1은 역전파 신경망의 일반적인 구성도를 보여주고 있다.

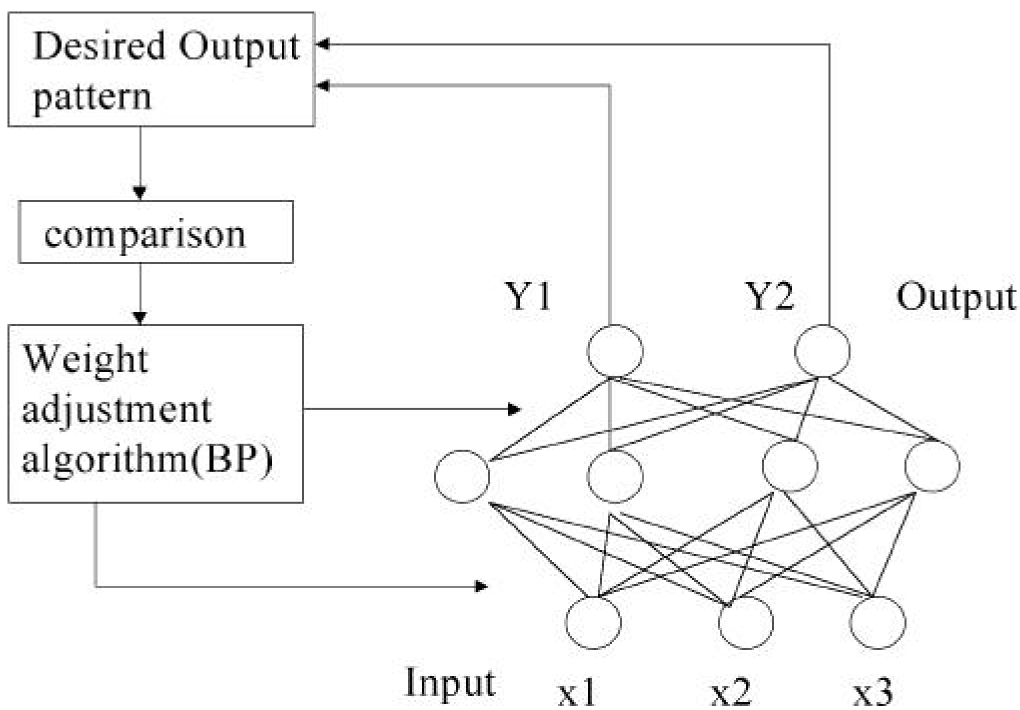

그림 1. 역전파 모델의 일반적인 구조

$$\Delta_p W_{ij} = \eta(t_{pj} - O_{pi})I_{pi} = \eta\ \delta_{pj}\ I_{pi} \quad (1)$$

여기서, η : learning rate

t_{pj} : 패턴 p의 j 번째 요소의 목표값

O_{pi} : 입력패턴 p의 i 번째 요소의 실제값

I_{pi} : 입력패턴 p의 i 번째 요소의 값

W_{ji} : 연결 가중치

$\Delta_p W_{ij}$: 패턴 p의 i번째에서 j 번째까지의 가중치의 변화량

⊿-rule은 입출력 함수의 모든 입출력 함수로부터 얻어지는 출력과 목표 출력과의 차이인 오차의 제곱의 합을 최소로 하도록 가중치를 조정한다. ⊿-rule에 의한 가중치의 변화는 가중치 공간상에 주어진 오차의 제곱의 높이오 하는 곡면에 대한 오차의 제곱이 가장 많이 감소하는 방향으로 변화한다. 이를 수식으로 나타내면 식 (2)과 같다. 즉, 입/출력 패턴 p의 오차는 K_p이고 측정 오차는 $K = \sum K_p$로 표현된다.

$$K_p = 1/2 \sum (t_{pj} - O_{pj})^2 \qquad (2)$$

식(2)의 최대 경사(gradient descent)를 구하기 위해, 가중치에 대한 K_p의 미분치를 구한다.

$$- \partial K_p / \partial W_{ji} = \delta_{pj} I_{pi} \qquad (3)$$

여기서, 연쇄법칙(chain rule)을 적용하면 식(3)은 다음과 같이 두개 항으로 분리할 수 있다. 식(3)의 부호는 방향성분을 의미한다.

$$\partial K_p / \partial W_{ji} = (\partial K_p / \partial O_{pj})(\partial Opj / \partial W_{ji}) \qquad (4)$$

이 식에서 첫번째 항은 j 번째 출력에 따른 오차율, 두번째 항은 가중치 Wji 의 변화에 따른 출력의 변화율을 나타낸다. 실제로 중간층이 없는 경우에는 오차의 제곱에 대한 곡면이 하나의 최소점을 갖는 포물선의 모양을 하고 있으므로, 최대경사법에 의해 오차의 제곱을 최소화하는 값을 얻을 수 있다. 하지만 중간층이 있는 경우 오차(K_p)의 미분을 구하는 것을 쉽지 않으며, 이러한 최대경사법이 local minima로 수렴할 가능성이 있다. 따라서 중간층이 고려한 일반화된 ⊿-rule을 적용해야 한다.

⊿-rule을 일반화하기 위해서는 먼저 임의의 비선형 입/출력 함수를 고려해야한다. 이 비선형함수는 물론 미분 가능한 함수로 식(5)으로 표현할 수 있다.

$$net_{pj} = \sum W_{ji} O_{pi}$$

$$O_{pj} = f_j (net_{pj}) \qquad (5)$$

⊿-rule의 일반식을 구하기 위해 비선형 함수에 대한 K_p 에 대한 오차의 제곱 합으로 하면 가중치의 변화량($⊿_p W_{ij}$)은 (1) 및 (3) 식에 의해 아래와 같이 나타낼 수 있다.

$$⊿_p W_{ij} \propto - \partial K_p / \partial W_{ji} \qquad (6)$$

식(6)에 chain rule을 적용하면 식(7)과 같이 표현된다.

$$\partial K_p / \partial W_{ji} = (\partial K_p / \partial net_{pj})(\partial net_{pj} / \partial W_{ji}) \qquad (7)$$

식(5)을 이용하여 식(7)의 두번째 미분 값을 계산하면 O_{pi} 가 되며, δ_{pj} 를 아래 식과 같이 정의하면 식(7)은 아래식과 같이 변환된다.

$$\delta_{pj} \equiv -\partial K_p / \partial net_{pj}, \quad -\partial K_p / \partial W_{ji} = \delta_{pj} O_{pj} \tag{8}$$

따라서 K_p에 대한 최대경사를 구하기 위해 ⊿-rule를 이용하여 가중치를 변화시키면 된다.

$$\Delta_p W_{ij} = \eta \delta_{pj} O_{pj} \tag{9}$$

여기서 δ_{pj} 을 어떻게 정하는 가이다. δ_{pj} 를 계산하기 위하여 합성 함수 연쇄법칙을 사용한다. 즉 (8)식을 오차의 출력에 관한 미분과 출력의 입력총합에 관한 미분으로 나누면 아래식과 같다.

$$\delta_{pj} = -\partial K_p / \partial net_{pj} = -(\partial K_p / \partial O_{pj})(\partial O_{pj} / \partial net_{pj}) \tag{10}$$

식(10)에서 첫번째 항과 두번째 항은 아래식에 의해서 계산된다.

$$\partial K_p / \partial O_{pj} = -(t_{pj} - O_{pj}) \tag{11}$$

$$\partial O_{pj} / \partial net_{pj} = f'_j (net_{pj}) \tag{12}$$

위의 관계를 이용하여 출력층과 중간층에 관한 δ_{pj} 를 각각 계산하면 아래식으로 표현된다.

$$\delta_{pj} = -(t_{pj} - O_{pj}) f'_j (net_{pj}) \tag{13}$$

$$\delta_{pj} = f'_j (net_{pj}) \sum \delta_{pj} W_{ji} \tag{14}$$

위 식에서 $f'_j (net_{pj})$ 활성화 함수에 따라 정해지는 값이며 시그모이드 함수에 대해서 이 값은 다음과 같다.

$$f'_j (net_{pj}) = O_{pj} (1 - O_{pj}) \tag{15}$$

최종적인 오차신호 δ_{pj} 는 출력층과 중간층에 대해서는 다음식으로 표현된다.

$$\delta_{pj} = -(t_{pj} - O_{pj}) O_{pj} (1 - O_{pj})$$

$$\delta_{pj} = O_{pj} (1 - O_{pj}) \sum \delta_{pj} W_{ji} \tag{16}$$

즉, 최종 Updata 식은 다음과 같다.

① 출력층인 경우 :

$$W_{kj} (n+1) = W_{kj} (n) + \Delta W_{kj} \tag{17}$$

여기서, $\Delta W_{kj} = \eta \delta_k O_j$ 및 $\delta_k = -(t_k - O_k) O_k (1 - O_k)$ 이다.

② 중간층인 경우 :

$$W_{ji} (n+1) = W_{ji} (n) + \Delta W_{ji} \tag{18}$$

여기서, $\Delta W_{ji} = \eta \delta_j O_i$ 및 $\delta j = O_j (1 - O_j) \sum \delta_k W_{ki}$ 이다.

2.2 진단을 위한 신경회로망 구성

금속파편 진단을 위한 신경회로망의 구조는 다층신경망으로 구성하였는데, 이 회로망의 장점은 출력 형태를 임의의 영역으로 구분하여 출력시킬 수 있다. 또한 여기서 사용된 전이함수(비선

형함수)는 sigmoid 라는 비선형 함수를 사용하여 다층 신경망으로서의 역할을 할 수 있게 하였다. 이 함수의 형태는 아래식과 같다.

$$\text{sigmoid 함수} = \frac{1}{1+\exp(-1\times x)} \quad (\text{slope 변수 : 1}) \tag{19}$$

신경회로망의 구조를 그림 2와 같이 구성하였다. 여기서 Hidden layer는 한 층이며, 여기에 속한 node의 수는 5개이다. 학습시키기 위한 입력 패턴을 4가지(52g, 175g, 288g, 443g)를 선정하여 입력시켰다. 또한 learning rate는 0.7, bias rate는 0.8 그리고 momentum은 0.9 하였다. 입력 node는 3개로서, 각각 충격 신호에서 취득한 변수인 Rising Time, Half Period, Maximum amplitude가 있다. 이 값들을 얻기 위하여 신호분석 tool을 이용하였다. 최대 반복횟수는 1000이며, 전체 오차가 0.05이하일 경우엔 학습을 마치도록 설계하였다. 입력의 범위를 0 1로 하기 위하여 입력값 중 최대가 되는 값으로 나머지 값을 나누어 normalize 하였다.

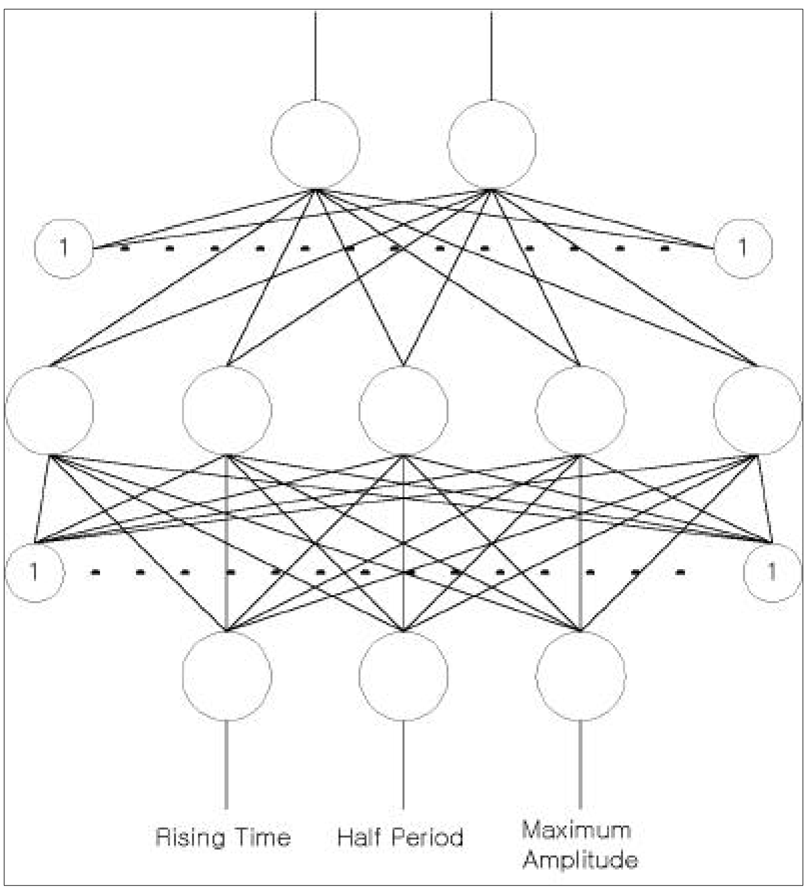

그림 2. 신경회로망의 구조

3. 실험 및 분석

영광 3호기의 충격 시험은 1차 계통의 RCP를 구동하여 증기발생기의 온도를 상온상태(100℃)로 만들어 시험하였다. 그리고 증기발생기 하부에 설치된 센서를 기준으로 하여 좌측, 10cm, 위 또는 아래로 거리가 30cm 근처를 강구로 충격을 발생시켰다. 충격시험에 사용된 강구는 4가지 종류를 사용하였으며, 각 강구의 무게는 52g, 175g, 288g, 443g이다. 증기발생기 내부의 유속은 1 m/sec, 증기 발생기의 하부의 두께는 7inch(17.78cm), 그리고 증기발생기상에 설치된 가속도계 센서의 측정감도는 10pC/g 50pC/g이다. 센서를 통하여 유입된 신호를 레코더(TEAC RD-135T; 샘플링 주파수 : 50 kHz(1/$\Delta t=2\times10^{-5}$), 대역폭 : 20kHz, 4채널(채널당 14bit), S/N비 : 72dB)에 저장하였다. 영광 3호기 실험데이터에서 질량을 평가하는데 필요한 입력값을 구하기 위해서 분석용 소프트웨어(Origin6.0)를 사용하였다.

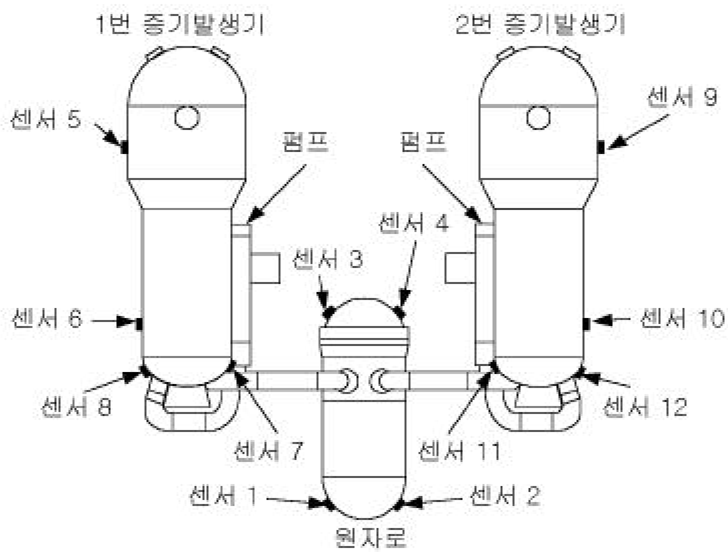

그림 3. 영광 3호기 원자로 및 증기발생기상에 설치된 센서의 위치

영광 3호기에 설치된 각 센서의 위치 및 번호는 그림 3와 같다. 원자로를 중심으로 양쪽에 두 개의 증기발생기가 설치되어 있다. 원자로에는 하부 헤드(반구부분)에 두 개, 상부 헤드에 두 개의 센서가 설치되어 있으며, 증기발생기에는 상부에 한 개, 하부에 세 개의 센서가 설치되어 있다. 그림 3의 센서들 중 영광 3호기 증기 발생기 내의 금속파편 충격질량을 추정하기 위해 이용된 센서들은 증기발생기의 6 8번 센서 및 증기발생기 10 12번 센서들이다. 이들 센서들 중 충격시험 시 6번, 7번, 8번 센서들의 주위에서 충격신호를 발생 시켰으며 총 6번이 수행되었다. 그림 4는 시운전 충격신호를 각 무게별로 보여주고 있다. 신호의 반주기와 최대 변위를 구하기 위해서 그림 4를 그림 5와 같이 확대하여

Rising Time, Half Period, Maximum Amplitude를 **구하게 된다**.

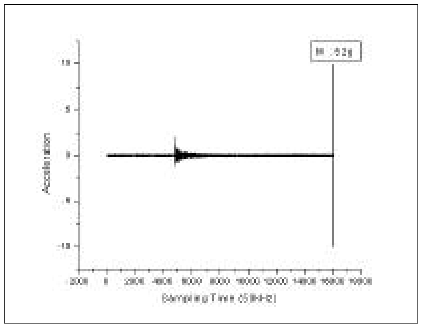

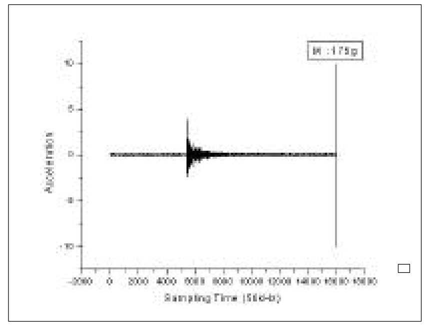

(a) (b)

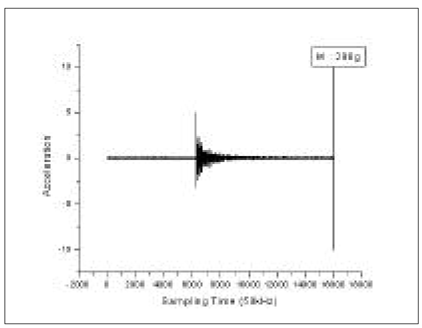

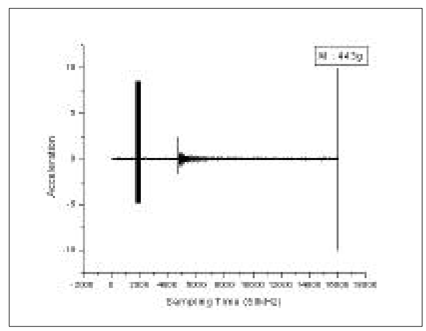

(c) (d)

그림 4. **충격실험 데이터**, (a) 52g (b) 175g (c) 288g (d) 443g

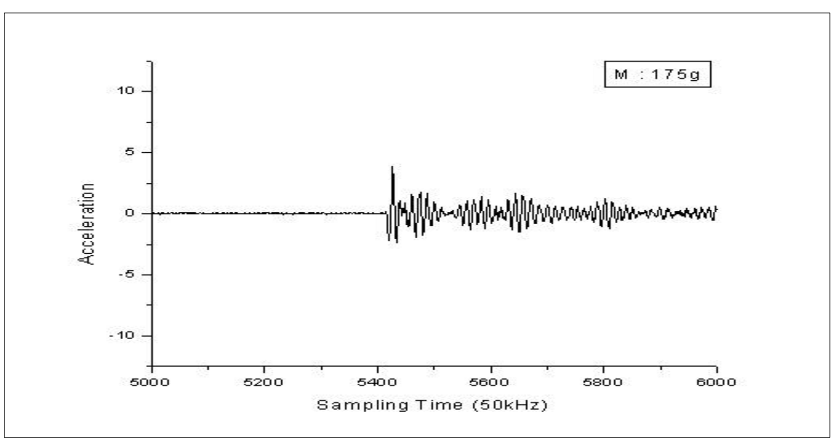

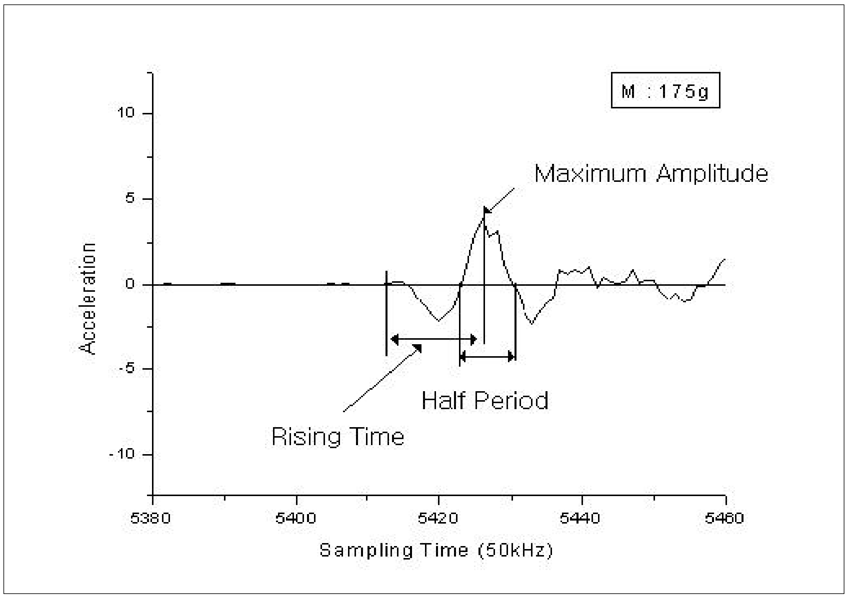

그림 5. 충격실험 데이터의 확대 파형(175g)

표 1은 각 신호의 신호분석 tool을 이용하여 Rising 시간, Half 주기, 최고 Amplitude등을 보여주고 있다. 본 표에서 보는 바와 같이 각 입력값들은 금속파편의 질량에 비례함을 알 수 있다. 본 표에서 검은색으로 나타나 있는 부분은 각 열에 최대값으로 이를 신경망에 적용하기 위해 기준값이 된다. 표2 는 이를 기준으로 Normalized 한 값을 보여주고 있다. 이를 신경망에 미리 학습시키는데 사용하였다.

표 1. 각 신호의 패턴 입력 데이터

	Rising Time	Half Period	Maximum Amp.
52g	227.4204 μs	144.416 μs	2.083
175g	292.835 μs	144.8804 μs	3.871
288g	371.8876 μs	147.1092 μs	5.045
443g	485.4702 μs	203.8542 μs	2.423

표 2. Normalized 패턴 입력 데이터

	Rising Time	Half Period	Maximum Amp.
52g	0.468454	0.708428	0.412884
175g	0.603199	0.710704	0.767294
288g	0.766037	0.721643	1
443g	1	1	0.480278

표 2를 기본으로 신경망에 Off-line으로 학습시켰다. 그리고 실제 금속파편이 일어난 신호를 이용하여 신경망의 학습된 신호와 비교 질량치를 추정하였다. 그림 6은 금속파편이 실제 일어난 신호를 보여주고 있다.

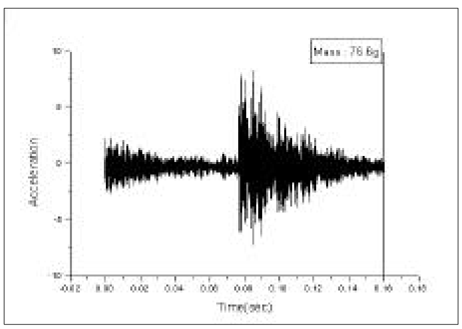

(a)

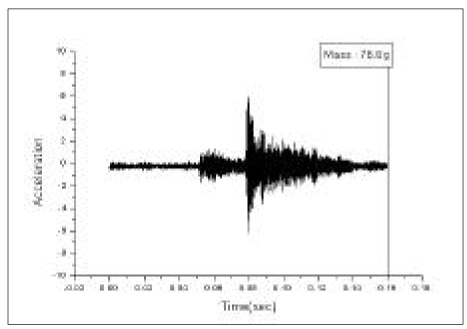

(b)

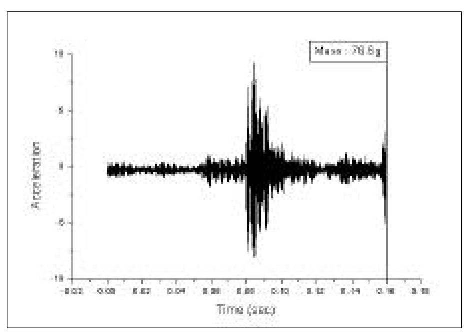

(c)

그림 6. 금속파편 충격신호 (a)(b)(c)

이 금속파편의 실제질량은 76.6 gram이다. 위의 신호로부터 신경망의 입력에 사용하기 위해 표 3과 같이 classification 하였다.

표 3. 금속파편 신호의 신경망 입력 데이터

	Rising Time	Half Period	Maximum Amp.
1(76.6g)	0.312880	0.356397	0.784143
2(76.6g)	0.205640	0.370579	1.065430
3(76.6g)	0.222428	0.422572	0.896531

표 3의 각 신호를 신경망을 학습한 결과 271회에서 오차범위 0.05 이내로 들어오면서 학습을 멈추었다. 학습된 신경망에 금속파편 신호를 입력한 결과 패턴입력에서의 52g로 분류하였다. 그림 7의 위에 나타난 값은 미리 학습시킨 결과를 나타내는데 00은 52 gram으로, 01은 175 gram으로, 10은 288 gram으로 그리고 11은 443 gram 으로 학습된 결과를 나타내며, 아래값은 금속파편 신호인 76.6 gram을 신경망에 학습시킨 결과를 보여주고 있다. 즉, 00으로 모두 인식됨을 알 수 있었다. 즉, 금속파편 신호가 52 gram에 유사한 값임을 그림 7에서 보여주고 있다. 실제 질량은 76.6g 로써 52 gram에 근접한 값으로 상당히 만족할 만한 결과를 보여 주었다.

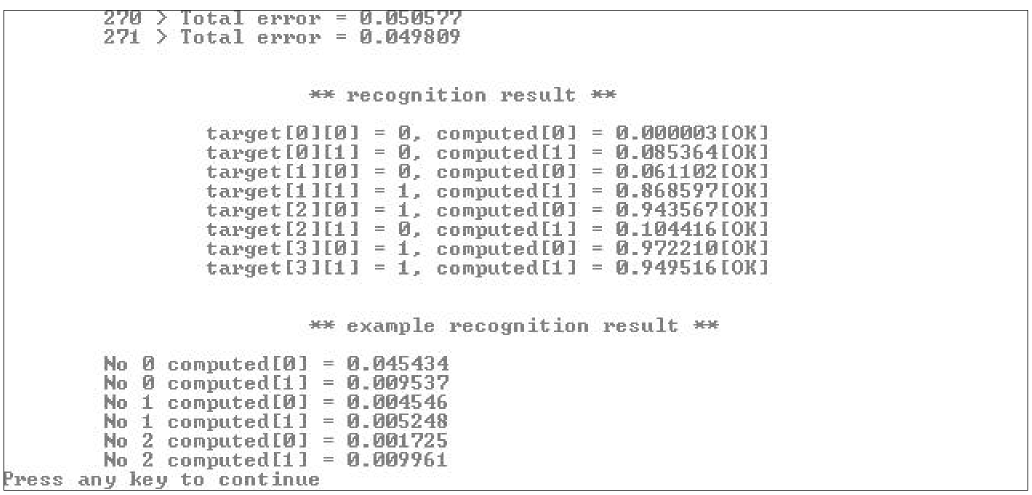

그림 7. 학습한 결과 및 실제 금속파편 질량 인식결과

4. 결론 및 향후 연구방향

냉각재 계통 기기 내부의 금속파편 진단을 위해 최근에 여러 분야에서 사용중인 인공지능기법인 신경회로망을 사용하여 질량을 추정하였다. 이 신경망을 영광 3호기 시운전 데이터에 적용하여 미리 학습시키고 실제 금속파편 신호를 학습시킨 결과, 실제 질량과 거의 유사한 결과를 얻을 수 있었다. 또한 이러한 신경망을 기존

질량추정 알고리즘과 병행하여 금속파편질량을 추정하는데 사용된다면, 상당히 정확한 질량 추정값을 얻을 수 있을 것으로 판단된다. 추후 연구과제로는 학습된 패턴의 범주 외에 있는 event가 발생했을 경우, 오판을 할 가능성이 크다. 이를 보완하기 위해 좀더 많은 라이브러리를 구축하여 신경망에 미리 학습시킨다면 좀더 정확한 질량 추정값을 얻을 수 있을 것으로 판단된다. 그리고 원전의 출력 증가시 자주 발생하는 오경보는 원전의 출력이 증가함에 따라 구조물의 변형 등으로 발생하는 구조물 자체의 팽창 진동, 구조물간의 마찰에 의한 진동 등이 원인이다. 이러한 신호는 금속파편 신호음과 동일한 에너지를 가지고 있어 금속파편의 충격신호와 구별이 어렵다. 이러한 경보를 구별하기 위해 본 논문에서 제시한 신경망등을 적절히 이용하면 오경보등을 많이 줄일 수 있을 것으로 판단된다.

참 고 문 헌

[1] 고압구조물의 이상신호 발생위치 검출기술 개발, KAERI/CM-102/94, 위탁과제 1차년도 연차보고서, 한국원자력연구소, 1995.

[2] K. Y. Sung, Acceleration Signal Characteristics of Steel Plate Impacted by Metallic Loose Parts, 63p, Department of Nuclear Engineering, 1992.

[3] I. K. Rhee, et. al., Development of Loose Part Signal Location Estimating Technique in High Pressured Structure, KAERI/CM-102/94.

[4] W. K. Shin, et. al., A Study on the Plant Diagnostic Techniques Using Reactor Noise, KAERI/NSC-454/89, 1989.

[5] Donald E. Hall, Basic Acoustics, John Wiley & Sons, 1987.

[6] EPRI. NP-5743, Loose Parts Monitoring Systems, Project No. 2642-1, Mar. 1988.

[7] Olma, "Experience with Digital Acoustic Monitoring Systems for PWR's and BWR's." Proceeding of technical committee meeting, Diagnostic Systems in NPP, IAEA-1ER-NPPCI-98/2, vol. 214, pp. 75 85, 1988.

[8] Thie, Power Reactor Noise, America Nuclear Society, 1981.

[9] 김태완외 5명,“ 발전소 시운전데이터를 이용한 금속파편 질량추정 알고리즘 개발”, ‘99 추계 원자력학술 발표회 논문집, pp 102, 서울대학교, 1999.10.

[10] 김정수외 7명, 금속파편 추정 알고리즘 개발 및 충격시험 데이터 분석, KAERI/AR-554/99.

[11] 김정수외 10명, NSSS 디지털 건전성 감시계통 국산화, KAERI/RR-1947/98.

[12] Yoh-Han Pao, Adative Pattern Recognition and Neural Network, Addison-Wesley Publishing Co. 1989.

[13] **오성헌이** 2**명**,“ **다층 신경회로망을 이용한 원자력 발전소 가압기 센서검증**”, **대한 전기학회 논문지**, **제** 42**권** 7**호**, pp 35-42, 1993**년** 7**월**.

[14] L. H. Tsoukalas and R. E. Urig, Fuzzy and Neural approaches in Engineering, John Wiley & Son, New York, Jul. 1996.

[15] Matrin T. Hagan etc., Neural Network Design, PWS Publishing Company, 1998.