

## 2단 신경망을 이용한 원자력 발전소의 고장 진단

### The Fault Diagnosis using Two-Steps Neural Networks for Nuclear Power Plants

배현·권순일\*·이종규\*·송치권·김성신

Hyeon Bae, Soon-il Kwon\*, Jong-kyu Lee\*, Chi-kwon Song and Sung-shin Kim

부산대학교 전기공학과, \*한국수력원자력(주) 원자력교육원

#### 요약

원자력발전소는 안전성을 최우선으로 하는 매우 복잡한 대규모 시스템으로써 이를 제어하는 주제어실에는 4000여 개의 경보 및 감시장치들이 설치되어 있다. 원자력발전소는 시설의 위험성과 복잡성으로 인해 대부분의 공정관리와 진단이 운전원에 의해 이루어지는데, 운전원은 여러 가지 센서나 계측기들로부터 얻어지는 방대한 양의 데이터를 이용하여 운전 상태를 파악한다. 따라서, 발전소가 비정상 상태로 운전될 때, 운전원이 정확한 사고 원인을 분석하고 빠른 시간 안에 해결 방법을 찾는 것이 어려울 수 있다. 이러한 문제점을 해결하기 위하여 본 논문에서는 2단 신경망을 이용하여 센서나 계측기들로부터 얻어진 데이터의 유형을 파악하여 고장 진단 시스템을 구성하였다.

#### Abstract

Operating the nuclear power generations safely is not easy way because nuclear power generations are very complicated systems. In the main control room of the nuclear power generations, about 4000 numbers of alarms and monitoring devices are equipped to handle the signals corresponding to operating equipments. Thus, operators have to deal with massive information and to analyze the situation immediately. If they could not achieve these task, then they should make big problem in the power generations. Owing to too many variables, operators could be also in the uncontrolled situation. So in this paper, the fault diagnosis system is designed using 2-steps neural networks. This diagnosis method is based on the pattern of the principal variables which could represent the type and severity of faults.

**Key Words :** Nuclear power, diagnosis, 2-steps neural networks

## 1. 서 론

원자력 발전은 1950년대 중반에 처음으로 도입된 이래 지속적으로 성장하여, 현재는 전세계적으로 440여기의 원자력발전소가 전체 전력생산의 약 16%를 담당하고 있다[1].

원자력발전소는 안전성을 최우선으로 하는 복잡한 대규모 시스템으로써 이를 제어하는 주제어실에는 4000여 개의 경보 및 감시장치들이 설치되어 있다. 따라서, 발전소가 어떤 원인에 의해 과도현상이나 운전 정지 또는 비상상태로 진전되면 사건 초기에 약 500여 개 이상의 경보가 발생되고, 많은 운전변수들이 동시에 변하게 되어 운전원에게 어려움을 준다 [2]. 예로서 1979년 TMI (Three Mile Island : 미국) 원전 사고의 원인 분석에서 각종 경보 및 감시계기 등을 통한 너무 많은 정보들이 운전원의 인지를 혼란시켜 적절한 대응조치를 취하는데 어려움을 준다는 결과를 보고하였다 [3], [4]. 본 논문에서는 고장시 운전원에게 진단의 어려움을 유발하는 많은 데이터들의 패턴을 신경망의 입력으로 사용하여 사고 결과를 분류하는 효과적인 사고진단 방법을 적용하였다.

## 2. 원자력 발전소 개요

### 2.1 시뮬레이터

본 실험에서 사용한 실험 데이터들은 실제 가동중인 원자력발전소를 모방한 시뮬레이터를 통해서 획득한 것들이다. 실제 사고가 발생하였을 때와 같은 조건아래서 만들어진 데이터이므로 신뢰도가 높다고 할 수 있다 [5].



그림 1. 실제 사용중인 시뮬레이터.

Fig. 1. Picture of real simulator.

### 2.2 가압경수형 원자로

실험에 사용한 데이터들은 현재 전세계적으로 널리

채택되고 있는 가압경수형 원자로(PWR: Pressurized Water Reactor)를 이용하는 발전소 모델에 대한 것이다. 이 원자로의 특징은 약 2~4%의 저농축 우라늄(UO<sub>2</sub>)을 핵연료로 사용하고 1차계통의 원자로 냉각재인 방사성 유체와 2차계통의 터빈·발전기측의 비방사성 유체가 서로 직접 접촉하지 않고 분리되어 있기 때문에 방사선 차폐가 잘되어 있으며 원자로 냉각재로는 경수(H<sub>2</sub>O)를 사용하고 감속재, 반사체 및 차폐체 역할도 냉각재가 겸하고 있다. 이 가압경수형 발전소는 두 개의 폐쇄회로로 구성되어 있으므로 원자로 냉각재 계통의 방사성 유체가 터빈·발전기 계통의 비방사성 유체가 완전 분리된다.

### 3. 신경망 학습 알고리즘

#### 3.1 신경망의 개요

인공 신경망의 연구는 사람의 뇌가 전통적인 디지털 컴퓨터와는 완전히 다른 방법으로 연산을 한다는 인식으로부터 시작되었다. 뇌는 매우 복잡하고, 비선형적이며 병렬연산자이다. 또한, 뉴런을 조직화하는 능력을 가지고 있다 [6]. 그림 2의 인공 뉴런의 구성도에서 입력신호는  $x_0, x_1, \dots, x_n$ 으로 표현된다. 입력신호들은 가중치(weight)에 의해 수정된다. 이런 과정은 입력의 가중치 합과 활성함수로 구성된다.

$$I_j = x_0 w_0 + x_1 w_1 + \dots + x_n w_n = \sum_{i=0}^n w_i x_i \quad (1)$$

$$\Phi(I_j) = \frac{1}{(1 + e^{-\alpha I})} = (1 + e^{-\alpha I})^{-1} \quad (2)$$

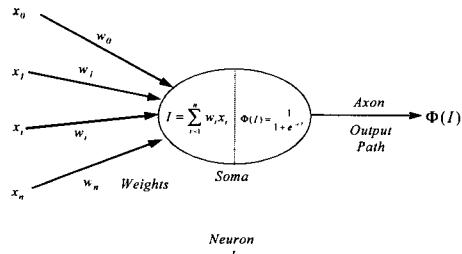


그림 2. 인공 뉴런의 구성도.  
Fig. 2. Diagram of a neuron.

#### 3.2 다층신경망을 위한 역전파 학습

만약 신경망이 단층으로 되어 있으면 입력 데이터에 존재하는 표현을 있는 그대로 출력으로 나타낼 수 있다. 따라서 데이터가 이산적이거나 비선형적이라면 내부적인 관계들이 존재하지 않고 학습되지 않는다. 여기에 다른 한층(은닉층)을 추가하면 내부적 표현들이 학습될 것이다. 이러한 다층 퍼셉트론 (MLP)의 복잡하고 풍부한 내부적 표현 능력이 평평을 위한 계층적 신경망을 구성한다 [7].

##### 3.2.1 출력층 뉴런에 대한 가중치 연산

그림 3은 출력층 뉴런의 가중치를 위한 역전파 학습과정에 대한 흐름도를 보여주고 있다. 여기서 뉴런 p와 q에 대한 출력은  $\Phi_{pj}(I)$ 와  $\Phi_{qk}(I)$ 이고 입력 가중치는  $w_{hp,j}$ 와  $w_{pq,k}$ 로 나타내고 목표치는  $T_q$ 이다. k층에서 뉴런의 출력은 목표치에서 뺀 값을 제곱시켜 자승오차를 구한다.

$$\varepsilon = \varepsilon_q = [T_q - \Phi_{q,k}] \quad (3)$$

$$\varepsilon^2 = \varepsilon_q^2 = [T_q - \Phi_{q,k}]^2 \quad (4)$$

$$\Delta w_{pq,k} = -\eta_{p,q} \frac{\partial \varepsilon_q^2}{\partial w_{pq,k}} \quad (5)$$

여기서  $\eta_{p,q}$ 는 학습률로서 상수를 사용한다. 위 식의 편미분을 계산하기 위해 체인공식을 사용한다. 각 항들은 차례로 연산되고 결과식은 아래와 같다.

$$\Delta w_{pq,k} = -\eta_{p,q} \frac{\partial \varepsilon_q^2}{\partial w_{pq,k}} = -\eta_{p,q} \delta_{pq,k} \Phi_{p,j} \quad (6)$$

$$w_{pq,k}(N+1) = w_{pq,k}(N) - \eta_{p,q} \delta_{pq,k} \Phi_{p,j} \quad (7)$$

여기서 N은 반복횟수를 나타낸다.

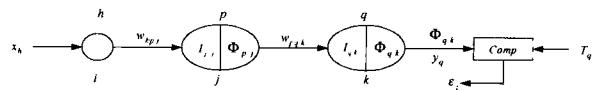


그림 3. 출력층 뉴런에 대한 가중치 학습.

Fig. 3. Weights of output-layer.

##### 3.2.2 은닉층 뉴런을 위한 가중치 연산

역전파는 신경망을 통해서 조정된 오차를 역방향으로 전파시켜 은닉층을 학습한다. 은닉층을 위한 식들은 오차항  $\delta_{pq,k}$ 를 목표 벡터 없이 만들어야 한다는 것을 제외하면 출력층에 대한 식들과 똑같다. 학습하는 동안 가중치들은 역순으로 연산되고  $\delta_{pq,k}$ 의 값은 출력층에서 역방향으로 은닉층까지 간다. 그림 4에서 보는 것처럼 오차는  $w_{hp,j}$ 를 변화시키기 위하여 역방향으로 전파된다.

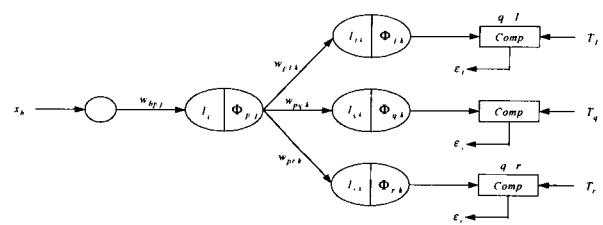


그림 4. 은닉층 뉴런에 대한 가중치 학습.

Fig. 4. Weight of a hidden layer.

$\varepsilon^2$ 은 여러 개의 출력 오차가 존재하기 때문에 다음과 같이 정의한다.

$$\Delta w_{hq,j} = -\eta_{h,p} \frac{\partial \varepsilon^2}{\partial w_{hp,j}} = -\eta_{h,p} \sum_{q=1}^r \frac{\partial \varepsilon_q^2}{\partial w_{hp,j}} \quad (8)$$

$$\varepsilon^2 = \sum_{q=1}^r \varepsilon_q^2 = \sum_{q=1}^r [T_q - \Phi_{q,k}]^2 \quad (9)$$

학습 상수  $\eta_{hp,j}$ 는 일반적으로  $\eta_{p,q}$ 와 같다. 다시 체인 공식을 사용하여, 식 (8)의 마지막 항을 계산하면 다음과 같다.

$$\frac{\partial \varepsilon^2}{\partial w_{hp,j}} = \sum_{q=1}^r \frac{\partial \varepsilon_q^2}{\partial \Phi_{q,k}} \cdot \frac{\partial \Phi_{q,k}}{\partial I_{q,k}} \cdot \frac{\partial I_{q,k}}{\partial \Phi_{p,j}} \cdot \frac{\partial \Phi_{p,j}}{\partial I_{p,j}} \quad (10)$$

$$\delta_{hp,j} \equiv \delta_{pq,k} w_{pq,k} \frac{\partial \Phi_{p,j}}{\partial I_{p,j}} \quad (11)$$

$$\frac{\partial \varepsilon^2}{\partial w_{hp,j}} = - \sum_{q=1}^r \delta_{hp,j} x_h \quad (12)$$

$$\Delta w_{hp,j} = -\eta_{hp} \frac{\partial \varepsilon^2}{\partial w_{hp,j}} = \eta_{hp} \sum_{q=1}^r \delta_{hp,j} w_{hp,k} \frac{\partial \Phi_{hp,j}}{\partial I_{hp,j}} x_h \quad (13)$$

$$= \eta_{hp} x_h \sum_{q=1}^r \delta_{hp,j}$$

따라서 가중치 갱신(update)식은 다음과 같다.

$$w_{hp,j}(N+1) = w_{hp,j}(N) + \eta_{hp} x_h \sum_{q=1}^r \delta_{hp,j} \quad (14)$$

한 학습과정이 끝나면 새로운 학습 입력이 적용되고 전체 과정이 다시 시작된다.

## 4. 모의실험 및 결과

### 4.1 원자력발전소의 사고 데이터

발전소의 주요 고장시 고장원인을 조기에 분석하여 적당한 조치를 취하는 것이 쉽지 않다. 또한 이러한 고장에 의한 발전소의 반응이 빠르게 진행되므로 신속 정확한 고장진단이 필요하다 [8]. 본 논문에서는 고장진단을 위하여 원자력발전소 사고시 변화되는 11개의 주요 운전변수들의 시간적 변화추이를 신경회로망을 이용하여 학습시켰다. 모의실험에서 각 사고의 종류 및 크기에 따라 분류할 수 있도록 구성하였다. 그림 5는 사고내용과 관련된 원자력발전소의 주요계통도를 나타내고 있으며, 화살표가 고장부위를 나타낸다 [9].

그림 6은 LOCA 사고에 대하여 다른 사고크기(severity)의 추이를 보여준다. 사고시 사고크기의 변화에 따라 주요한 변수 11개의 값들은 크기가 변하게 된다. 그림에

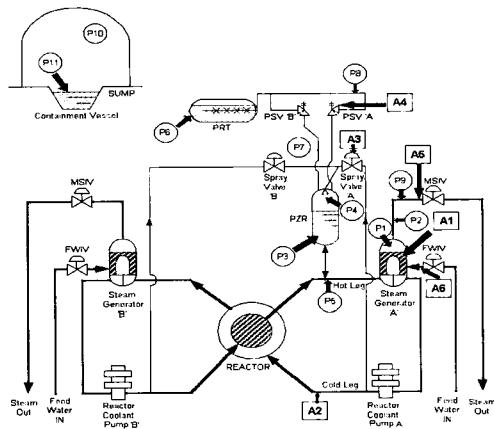


그림 5. 원자력발전소의 주요계통도.

Fig. 5. Systems of the nuclear power plant.



그림 6. 같은 종류의 다른 크기 사고.

Fig. 6. Different severity of faults.

서 보는 것과 같이 40%일 때와 60%일 때를 비교하면 변화 추이는 거의 유사하지만 크기에서 차이가 난다. 이러한 크기의 변화를 이용하여 사고의 크기를 진단하고자 하였다.

### 4.2 신경망의 구조

본 논문에서 사용한 신경망은 두 개의 독립된 신경망을 직렬로 연결하여 구성하였다. 분류하고자 하는 결과가 사고의 종류와 크기로 나누어지기 때문에 동시에 학습하는 방법보다는 하나의 학습을 마치고 나온 결과를 기반으로 하여 두 번째 결과를 테스트하는 것이 보다 효과적이라고 생각하였기 때문이다. 모의실험에 사용한 신경망의 1차 신경망에서 사고크기는 고려하지 않고 사고의 종류에 대해서만 학습한 후 학습된 신경망을 이용하여 임의의 사고 데이터를 이용하여 사고 종류를 분류한다 [10]. 분류된 정보를 가지고 다시 2차 신경망을 이용하여 사고 크기만 분류하는데 2차 신경망은 이미 각 사고에 대한 사고크기만 고려하여 학습되고 모델이 완성된 상태이다. 1차 신경망의 입력으로 사용한 데이터를 다시 2차 신경망의 입력으로 넣으면 출력단에서 사고의 크기를 분류할 수 있을 것이다. 그림 7의 흐름도에서 알 수 있듯이 실제 사용된 두 신경망이 구조적으로 연결되어 있는지는 않지만 최종적인 결과를 위해서 상호 보완적인 역할을 수행한다. 이러한 방법을 통해 많은 데이터를 단일 신경망을 이용하여 학습할 경우 발생할 수 있는 학습의 비효율성을 줄일 수 있고 적은 변수를 통해 우수한 결과를 유도할 수 있다.

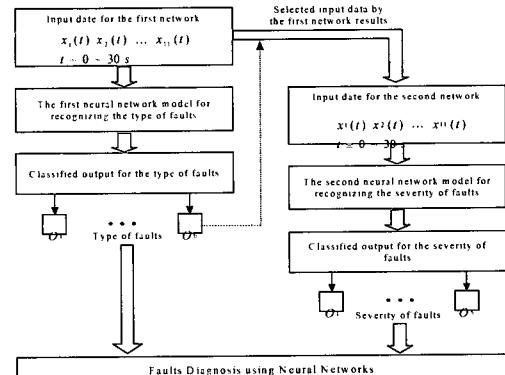


그림 7. 사고 진단을 위한 2단 신경망 구조도.

Fig. 7. Two-steps neural networks.

### 4.3 신경망의 입·출력 데이터

표 1은 사고의 종류를 보여주고 있는데 이 사고들은 대형사고로 발전할 수 있는 가능성들을 가지고 있다. 표 2에서는 고장을 판단하기 위해 사용한 주요 11개 운전변수를 보여주고 있다. 표에서 보여준 데이터의 변화들은 실제 사고의 특징을 대변하는 것으로 원자력 발전소의 운전에서 중요하게 취급되는 변수들이다. 이 변수들은 각각 30초 동안의 추이이므로 31개의 값으로 이루어진다. 따라서 신경망의 입력은 한번 적용될 때마다 11개씩 사용되며 이러한 과정을 31번 수행하고 나면 하나의 사고에 대하여 학습이 끝나게 된다. 본 논문에서는 교사학습을 하므로 학습되는 동안 출력측은 원하는 결과값으로 고정된다 [7]. 본 모의실험에서는 신경망을 단일 구조로 사용하지 않고 2개의 독립구조의 결합으로 사용하였다. 즉 1차와 2차 신경망을 구성하여 두 종류의 분류목적을 수행하고자 하였다. 표 1

과 2에서 보여준 사고 종류와 주요 변수들은 편의상 사각형 번호와 원 번호로 각각 표기한다.

표 1. 원자력 발전소 사고종류.

Table 1. Faults of nuclear power plants.

사고명	약어	영문표기
증기 발생기 튜브 파열	SGTR	Steam Generator Tube Rupture
원자로 냉각재 상실	LOCA	Loss of Coolant Accident
가압기 살수 밸브 개방 고착	PZR SPRAY	Pressurizer Spray valve stuck open
가압기 안전 밸브 개방 고착	PZR PSV	Pressurizer Pressure Safety Valve stuck open
주증기관 파단	MSLB	Main Steam Line Break
주급수관 파단	MFLB	Main Feed Line Break

표 2. 사고 진단을 위해 사용하는 주요변수.

Table 2. Principal variables for the fault diagnosis.

변수명	약어	영문표기
증기발생기 수위	SG1L	Steam Generator 1 Level
증기발생기 압력	SG1SP	Steam Generator 1 Steam Pressure
가압기 수위	PZRL	Pressurizer Level
가압기 압력	PZRP	Pressurizer Pressure
광역 고온관 온도	LP1WT	Loop 1 Wide range Temperature
가압기 압력방출탱크 수위	PRTL	Pressurizer Relief Tank Level
가압기 살수밸브 후 단온도	SLDT	Spray Line Discharge Temperature
가압기 안전밸브 후 단온도	PSLT	Pressurizer Safety valve Line Temperature
증기발생기 취출수 방사능	SGBR	Steam Generator Blowdown Radiation
격납용기 광역 방사능	CVHR	Containment Vessel High range Radiation
격납용기 배수조 수위	CVSL	Containment Vessel Sump Level

#### 4.3.1 1차 신경망 모델을 위한 데이터 구조

신경망 학습을 위한 입력 데이터 구조는 표 3과 같다. 각 사고에 대하여 각각의 변수는 31개의 데이터로 구성

표 3. 1차 신경망 모델을 위한 입력데이터 구조.

Table 3. Input data structure for the 1st network.

x												
입력	$x_1$	$x_2$	$x_3$	$x_4$	$x_5$	$x_6$	$x_7$	$x_8$	$x_9$	$x_{10}$	$x_{11}$	
변수	①	②	③	④	⑤	⑥	⑦	⑧	⑨	⑩	⑪	
시간	0 [1~6]	...			...				...	[1~6]		
0	[1~6]	...			...				...	[1~6]		
1	..								..			
..	..								..			
29	..								..			
30	[1~6]	...			...				...	[1~6]		

①SGTR ②LOCA ③PZR SPRAY ④PZR PSV ⑤MSLB  
⑥MFLB 각각 입력 (40→80%)

되어 있다. 이렇게 구성된 각 데이터는 초당 입력으로 들어가게 되고 표 4에서 보는 것과 같은 출력 데이터에 의해서 원하는 값으로 학습시킨다. 본 논문에서는 사고의 수가 6개이므로 출력층은  $6 \times 31$ 의 행렬로 구성된다. 또한 사고의 강도는 사용한 신경망의 구조에 의해 2차 신경망에서 고려하게 되므로 사고 종류를 분류하기 위한 1차 신경망에서는 고려하지 않는다. 따라서 40~80%까지 10%씩 고려한 사고강도에 대한 출력층 목표값은 각각 0.6, 0.7, 0.8, 0.9, 1.0을 사용한다.

표 4. 1차 신경망 모델의 출력층 데이터 구조.

Table 4. Target data structure for the 1st network.

목표치	$y \times 0.6 \sim 1.0$ (40%~80% 사고크기 고려)					
	$y_1$	$y_2$	$y_3$	$y_4$	$y_5$	$y_6$
SGTR	1	0	0	0	0	0
LOCA	0	1	0	0	0	0
PZR SPRAY	0	0	1	0	0	0
PZR PSV	0	0	0	1	0	0
MFLB	0	0	0	0	1	0
MSLB	0	0	0	0	0	1

#### 4.3.2 2차 신경망 모델을 위한 데이터 구조

2차 신경망에서는 이미 분류된 사고에 해당하는 입력데이터를 이용하여 사고 강도를 분류하기 위한 작업을 수행한다. 따라서 신경망의 입·출력데이터 구조가 1차 신경망 모델과는 다르다. 이미 사고분류가 끝난 상태이므로 다시 분류해야하는 경우의 수가 줄어든다. 전체 30초까지의 데이터를 순서대로 입력으로 넣는다. 그리고 사고의 크기가 5개(40%에서 80%까지 10%씩)로 나누어지므로 31개의 데이터를 사고크기 순서대로 입력으로 넣으면서 신경망을 학습하게 된다. 표 5와 6에서 데이터구조를 보여주고 있다. 출력층 데이터는 다섯 가지 사고

표 5. 2차 신경망 모델을 위한 입력데이터 구조.

Table 5. Input data structure for the 2nd network.

x												
입력	$x_1$	$x_2$	$x_3$	$x_4$	$x_5$	$x_6$	$x_7$	$x_8$	$x_9$	$x_{10}$	$x_{11}$	
변수	①	②	③	④	⑤	⑥	⑦	⑧	⑨	⑩	⑪	
시간	0 [1~6]	...			...				...	[1~6]		
0	[1~6]	...			...				...	[1~6]		
1	..								..			
..	..								..			
29	..								..			
30	[1~6]	...			...				...	[1~6]		

표 6. 2차 신경망 모델의 출력층 데이터 구조.

Table 6. Target data structure for the 2nd network.

목표치	y				
	$y_1$	$y_2$	$y_3$	$y_4$	$y_5$
40%	1	0	0	0	0
50%	0	1	0	0	0
60%	0	0	1	0	0
70%	0	0	0	1	0
80%	0	0	0	0	1

크기를 고려하기 때문에  $5 \times 1$  행렬로 구성된다. 목표값은 데이터의 양이 줄어들었기 때문에 보다 확실한 분류를 위하여 1의 값을 사용하여 학습한다.

#### 4.4 사고진단 모의실험 결과

##### 4.4.1 1차 신경망에 의한 사고종류 진단

신경망을 이용한 모의실험을 고찰하기 위하여 우선 1차 신경망의 인식율을 표로 나타내었다. 1차 신경망에서는 사고의 종류 6가지의 분류를 하므로 각 6가지 사고에 대한 결과이다. 활성함수로는 hyperbolic tangent(은닉층)과 logistic(출력층) 함수를 사용하였다.

본 모의실험의 결과를 통해 전체적으로 사고분류가 잘 됨을 알 수 있다. 단지 사고의 패턴이 비슷하거나 사고시 변수들의 변화가 미미한 경우는 오차의 크기가 큰 것을 확인할 수 있었다. 실제 이런 경우의 변수 데이터들을 보면 육안으로도 차이를 분별하기 어려운 실제 주어진 데이터만으로는 정확한 분류를 하기가 어렵다고 생각된다. 그러나 다소 성능의 차이는 있지만 1차 신경망이 사고종류를 구분하기 위해 사용되기 때문에 오차에 대한 평가보다는 성능을 고려하는 것이 알맞을 것이다.

##### 4.4.2 2차 신경망에 의한 사고크기 진단

2차 신경망은 1차 신경망에서 이미 분류된 사고에 대한 크기분류를 위하여 사용된다. 따라서 실제로 구성되어야 할 신경망 모델은 6개이다. 학습을 위한 출력

표 7. Hyperbolic과 logistic 함수를 이용한 종류 진단.

Table 7. Hyperbolic and logistic functions.

사고 종류	사고 크기	목표치	테스트결과 (30초 동안의 평균값)						30초 후 최종값
			$y_1$	$y_2$	$y_3$	$y_4$	$y_5$	$y_6$	
①	40%	0.6	0.565	0.001	0.125	0.042	0.009	0.029	0.607
	50%	0.7	0.674	0.001	0.060	0.023	0.037	0.021	0.681
	60%	0.8	0.755	0.001	0.048	0.019	0.085	0.017	0.796
	70%	0.9	0.719	0.001	0.055	0.013	0.146	0.026	0.824
	80%	1.0	0.847	0.001	0.025	0.066	0.052	0.233	0.902
②	40%	0.6	0.003	0.676	0.001	0.069	0.042	0.051	0.588
	50%	0.7	0.005	0.734	0.001	0.081	0.057	0.042	0.693
	60%	0.8	0.002	0.771	0.001	0.086	0.067	0.038	0.795
	70%	0.9	0.010	0.774	0.000	0.107	0.077	0.031	0.806
	80%	1.0	0.003	0.815	0.000	0.100	0.092	0.037	0.890
③	40%	0.6	0.019	0.001	0.773	0.002	0.081	0.090	0.673
	50%	0.7	0.033	0.001	0.703	0.002	0.069	0.117	0.706
	60%	0.8	0.033	0.001	0.703	0.002	0.069	0.125	0.771
	70%	0.9	0.056	0.001	0.692	0.002	0.064	0.140	0.803
	80%	1.0	0.094	0.000	0.737	0.005	0.004	0.086	0.639
④	40%	0.6	0.022	0.077	0.001	0.691	0.010	0.034	0.567
	50%	0.7	0.027	0.074	0.001	0.731	0.009	0.043	0.718
	60%	0.8	0.025	0.090	0.001	0.739	0.010	0.036	0.812
	70%	0.9	0.016	0.099	0.001	0.758	0.010	0.034	0.891
	80%	1.0	0.015	0.084	0.001	0.796	0.008	0.037	0.954
⑤	40%	0.6	0.065	0.010	0.036	0.002	0.567	0.043	0.649
	50%	0.7	0.074	0.017	0.029	0.010	0.491	0.041	0.710
	60%	0.8	0.047	0.020	0.030	0.019	0.431	0.040	0.775
	70%	0.9	0.031	0.038	0.021	0.050	0.356	0.050	0.799
	80%	1.0	0.024	0.102	0.016	0.064	0.283	0.058	0.815
⑥	40%	0.6	0.061	0.022	0.171	0.008	0.003	0.364	0.572
	50%	0.7	0.055	0.027	0.138	0.013	0.004	0.474	0.675
	60%	0.8	0.063	0.017	0.097	0.010	0.011	0.519	0.887
	70%	0.9	0.062	0.016	0.078	0.009	0.028	0.594	0.923
	80%	1.0	0.008	0.034	0.093	0.038	0.023	0.761	0.969

측의 목표값은 1로 설정하여 학습동안 출력값이 수렴하도록 하였다. 이는 사고종류 분류와는 다른 값을 사용하였는데 본 2차 신경망에서는 입력 데이터로 단지 다섯 가지의 사고크기에 대한 것만 사용하기 때문에 같은 값을 사용하여 학습해도 성능의 저하는 없다고 고려된다. 실제 1차측 신경망처럼 데이터의 양이 많을 경우 입력 데이터의 사고크기에 대하여 고려하지 않을 경우 성능이 저하됨을 볼 수 있었다. 학습을 마친 후 각 사고의 크기들을 독립적으로 실험한 결과를 표 8에 나타내었다. 사고종류의 분류와 마찬가지로 31초가 경과된 후 나오는 출력값을 보면 사고크기가 클 때 성능이 보다 우수함을 알 수 있다. 이는 출력값의 초기 시작점에서 최종점까지의 크기 변화가 크기 때문에 패턴의 변화가 명확하기 때문일 것이다.

표 8. 2차측 신경망을 이용한 사고크기 분류 결과.

Table 8. The results of classification of severity.

사고 종류	사고 크기	목표치	테스트결과 (30초 동안의 평균값)						30초 후 최종값
			$y_1$	$y_2$	$y_3$	$y_4$	$y_5$	$y_6$	
①	40%	1.0	0.863	0.151	0.017	0.000	0.008	0.931	
	50%	1.0	0.105	0.619	0.335	0.010	0.001	0.809	
	60%	1.0	0.058	0.278	0.390	0.136	0.003	0.521	
	70%	1.0	0.034	0.055	0.271	0.786	0.022	0.982	
	80%	1.0	0.031	0.000	0.000	0.006	0.979	0.995	
②	40%	1.0	0.736	0.304	0.136	0.056	0.024	0.955	
	50%	1.0	0.225	0.345	0.240	0.086	0.035	0.616	
	60%	1.0	0.063	0.192	0.302	0.208	0.065	0.485	
	70%	1.0	0.035	0.103	0.237	0.388	0.235	0.578	
	80%	1.0	0.022	0.086	0.171	0.334	0.710	0.948	
③	40%	1.0	0.816	0.267	0.028	0.008	0.020	0.934	
	50%	1.0	0.093	0.258	0.191	0.078	0.018	0.383	
	60%	1.0	0.006	0.232	0.479	0.339	0.016	0.723	
	70%	1.0	0.058	0.228	0.350	0.464	0.350	0.754	
	80%	1.0	0.043	0.018	0.011	0.026	0.928	0.977	
④	40%	1.0	0.590	0.242	0.107	0.078	0.068	0.976	
	50%	1.0	0.168	0.406	0.226	0.084	0.071	0.714	
	60%	1.0	0.087	0.211	0.449	0.240	0.043	0.726	
	70%	1.0	0.078	0.085	0.236	0.446	0.095	0.694	
	80%	1.0	0.073	0.074	0.065	0.065	0.719	0.974	
⑤	40%	1.0	0.593	0.270	0.211	0.090	0.002	0.817	
	50%	1.0	0.245	0.279	0.235	0.144	0.008	0.465	
	60%	1.0	0.136	0.228	0.257	0.196	0.0231	0.517	
	70%	1.0	0.051	0.147	0.193	0.316	0.1981	0.579	
	80%	1.0	0.056	0.091	0.128	0.313	0.661	0.952	
⑥	40%	1.0	0.543	0.368	0.219	0.065	0.009	0.769	
	50%	1.0	0.317	0.385	0.133	0.013	0.080	0.488	
	60%	1.0	0.147	0.115	0.307	0.301	0.009	0.618	
	70%	1.0	0.090	0.057	0.372	0.619	0.009	0.902	
	80%	1.0	0.032	0.203	0.041	0.008	0.922	0.994	

##### 4.4.3 학습되지 않은 사고 데이터의 진단

본 절에서는 학습되지 않은 사고 크기 데이터를 이용하여 진단이 가능한지를 실험하였다. 예를 들어 40%, 60%, 그리고 80%의 사고크기를 이용하여 신경망 모델을 학습한 후 50%와 70%의 테스트 데이터를 입력했을 때 사고 크기가 정확하게 분류가 되는지를 실험하고자 하였다. 이와 같은 실험은 신경망이 가진 적응성을 통해 유사한 패턴을 가진 신호에 대해서 선별할 수 있는 능력을 확인하고자 하는 것이다. 1차측 신경망의 구조는 사고 종류를 분류하는 신경망 구조와 같이 구성하였다. 단지 학습 방향을 사고종류에만 국한시키지 않고 사고크기도 동시에 진단할 수 있도록 고려하였다. 표 9에서 보는 바와 같이

학습되지 않은 데이터를 적용하여 신경망 모델이 사고종류를 인식할 수 있는지에 대하여 모의실험을 통하여 확인하였다. 학습데이터와 테스트 데이터를 분리하여 학습한 모델이기 때문에 성능이 다소 저하됨을 볼 수 있다. 특히 SGTR사고의 경우 오차의 범위가 크지만 나머지 사고의 경우 30초가 경과된 후 나오는 출력들이 원하는 목표값에 근사하여 수렴함을 볼 수 있다. 따라서 학습되지 않은 데이터에 대해서도 사고진단이 가능함을 알 수 있다.

표 9. 학습되지 않은 데이터의 사고종류 진단.

Table 9. Results of untrained data for test inputs.

사고 종류	사고 크기	목표 치	테스트결과 (30초 동안의 평균값)						30초 후 최종값
			$y_1$	$y_2$	$y_3$	$y_4$	$y_5$	$y_6$	
[1]	50%	0.7	0.581	0.000	0.102	0.002	0.033	0.040	0.691
	70%	0.9	0.445	0.000	0.092	0.003	0.177	0.096	0.664
[2]	50%	0.7	0.001	0.764	0.029	0.057	0.087	0.022	0.704
	70%	0.9	0.001	0.772	0.024	0.104	0.071	0.027	0.864
[3]	50%	0.7	0.098	0.000	0.510	0.017	0.081	0.031	0.707
	70%	0.9	0.113	0.000	0.502	0.011	0.075	0.077	0.805
[4]	50%	0.7	0.001	0.040	0.012	0.761	0.033	0.018	0.704
	70%	0.9	0.000	0.061	0.010	0.781	0.013	0.004	0.866
[5]	50%	0.7	0.045	0.014	0.066	0.013	0.654	0.080	0.704
	70%	0.9	0.020	0.058	0.023	0.024	0.591	0.060	0.916
[6]	50%	0.7	0.158	0.015	0.026	0.000	0.025	0.577	0.713
	70%	0.9	0.073	0.018	0.016	0.000	0.047	0.625	0.889

## 5. 결 론

본 논문에서는 실제 운전중인 원자력발전소를 모방한 시뮬레이터로부터 획득한 데이터를 이용하여 고장진단을 위한 방법을 구현하였다. 각 사고에 대한 변수는 총 11개를 사용하였고 사고의 종류는 6개이다. 11개의 변수는 사고가 발생했을 때 계기들의 값의 변화로서 0초에서 30초까지의 경과를 기준으로 하였다. 본 논문에서 구성한 신경망 모델을 이용하여 학습한 후 테스트를 해본 결과 각 사고의 종류를 효율적으로 분류할 수 있음을 알 수 있었다. 변수의 변화가 미미한 경우에는 신경망으로는 분류하는 것이 쉽지 않았으므로 유사한 패턴을 가진 사고를 분류하기 위해서는 보조적인 방법이 함께 고려되어야 할 것이다.

## 참 고 문 헌

- [1] 장순홍, 백원필, 원자력 안전(*Nuclear Safety*). 청문각, pp. 1-37, 1998.
- [2] R. E. Uhrig, "Potential application of neural networks to the operation of nuclear power plant," *Nuclear Safety*, vol. 32, no. 1, pp. 68-78, 1991.
- [3] 장순홍, 전문현외, 원자력발전소 고장진단 및 비상조치 지원시스템 구축을 위한 연구. 기술보고서, 한국전력공사 기술연구원, 1994.
- [4] PWR Accident Analysis and Mitigating Core Damage. Technical Report, Westinghouse Training and Operational Services, 1991.
- [5] 이용관, 조병학외, 발전소 운전원 훈련용 모의제어반 국산화 개발 적용. 기술보고서, 한국전력공사 전력연구원, 1998.
- [6] Simon Haykin, Neural Networks. NJ: Prentice Hall, pp. 6-67, 1999.
- [7] Lefteri H. Tsoukalas and Robert E. Uhrig, *Fuzzy and Neural Approaches in Engineering*. New York: John Wiley & Sons, Inc., pp. 238-246, 1997.

- [8] 문영현, 박영문외, 전력사업의 인공지능 도입 연구. 기술보고서, 한국전력공사 정보처리처, 1990. 8.
- [9] 고리 2호기 Process Diagram. 기술보고서, 한국수력원자력주식회사 고리원자력본부.
- [10] Robert E. Uhrig and Jhichao Guo, "Use of Neural Network to identify transient operating conditions in Nuclear Power Plants," *SPIE Symposia on aerospace sensing artificial intelligence VII*, Orlando, March 27-31, 1989.

## 저 자 소 개

### 배 현 (Hyeon Bae)

2001년: 부산대학교 전기공학과 졸업 (공학석사)

2001년~현재: 부산대학교 전기공학과 박사과정

관심분야: 퍼지 및 지능제어, 공정자동화



### 권순일 (Soon-il Kwon)

1980년: 한국전력공사 입사

1989년: 동아대학교 전기공학과 졸업

2001년: 부산대학교 산업대학원 전기공학과 졸업 (공학석사)

현재: 원자력교육원 고리훈련센타 교수



### 이종규 (Jong-kyu Lee)

1980: 영남대학교 전기공학과 졸업

1979: 한국전력공사 입사

2001: 부산대학교 산업대학원 전기공학과 졸업 (공학석사)

현재: 원자력교육원 교수실 전문팀 교수



### 송치권 (Chi-kwon Song)

2000년: 부산대학교 전기공학과 졸업 (공학석사)

2000년~현재: 부산대학교 전기공학과 석사과정

관심분야: 데이터 마이닝, 웨이블릿



### 김성신 (Sungshin Kim)

1996년: Georgia Institute of Technology 전기공학과 졸업 (공학박사)

1998년~현재: 부산대학교 전기공학과 조교수

관심분야: 지능제어, 웨이블릿, 데이터 마이닝, 공정최적화



E mail : sskim@pusan.ac.kr