

# 자기 동적 신경망을 이용한 RCP 감시 시스템의 정보진단

論文

49D - 9 - 3

## Alarm Diagnosis of RCP Monitoring System using Self Dynamic Neural Networks

柳東完\* · 金東勳\*\* · 成承桓\*\*\* · 具仁守§ · 朴省昱§§ · 徐輔煥§§§  
(Dong-Wan Ryoo · Dong-Hoon Kim · Seung-Hawn Seong · In-Soo Koo · Seong-Wook Park · Bo-Hyeok Seo)

**Abstract** – A Neural networks has been used for a expert system and fault diagnosis system. It is possible to nonlinear function mapping and parallel processing. Therefore It has been developing for a Diagnosis system of nuclear power plant. In general Neural Networks is a static mapping but Dynamic Neural Network(DNN) is dynamic mapping. When a fault occur in system, a state of system is changed with transient state. Because of a previous state signal is considered as a information, DNN is better suited for diagnosis systems than static neural network. But a DNN has many weights, so a real time implementation of diagnosis system is in need of a rapid network architecture. This paper presents a algorithm for RCP monitoring Alarm diagnosis system using Self Dynamic Neural Network(SDNN). SDNN has considerably fewer weights than a general DNN. Since there is no interlink among the hidden layer. The effectiveness of Alarm diagnosis system using the proposed algorithm is demonstrated by applying to RCP monitoring in Nuclear power plant.

**Key Words** : RCP Monitoring System, Alarm Diagnosis, Static Neural Network, Self Dynamic Neural Network,

### 1. 서 론

신경망이론은 여러 가지 전문가 시스템이나 고장진단 시스템을 만드는데 많이 사용되고 있다. 신경망이론은 학습시킨 패턴들에 대해서도 정확한 결과를 나타낼 뿐만 아니라 약간의 오차가 존재하는 패턴들에 대해서도 어느 정도 신뢰할 수 있는 결과를 나타내기 때문에 원자력 발전소의 고장 진단시스템을 만드는데도 많이 연구되고 있으며, 원자력플랜트의 고장진단에는 정적 신경망을 이용한 연구가 많이 되어 왔다.[1-4]

신경망은 입출력의 비선형 함수관계를 학습에 의해 표현할 수 있고 본질적으로 병렬처리가 가능한 구조와 일반화 특성을 가지므로 비선형성이 강한 시스템에 대해서도 좋은 성능을 보인다. 신경망은 두 가지로 분류될 수 있다. 하나는 정적 전방향 신경망(Static Forward Neural Network)구조이며, 다른 하나는 동적 신경망 구조(Dynamic Neural Network)이다. 정적 전방향 신경망은 동적 사상을 표현하지 않는 정적사상인 반면에 동적 신경망은 동적 사상이다. 이 중에 동적 시스템에 적용하기에 적합한 신경망은 내부적으로 동적인 특성을 갖는 동적 신경

망이다.[5,6,8] 어떤 고장이 발생했을 때 시간에 따라 순차적으로 시스템상태가 변화한다. 즉 시스템의 과도현상이 존재 한다. 이전상태에 대한 신호도 하나의 정보로 볼 수 있으므로 정적 신경망보다 이전의 상태도 고려하는 동적 신경망이 더욱 적합하다. 시스템을 진단할 때 진단기의 파라미터가 필요 이상으로 많아서는 좋지 않으며 계산시간이 오래 걸린다.[7] 그러므로 빠른 진단을 위해 계산량을 줄일 필요가 있다. 그러나 동적 신경망은 연결강도의 수가 많기 때문에 실시간 적용을 수행하기 위해서는 무엇보다도 학습속도가 빠른 신경망 구조가 필요하다.

따라서 본 논문에서는 연결강도수가 적은 자기 동적 신경망을 사용하여 원자력 발전소의 RCP 시스템의 정보진단 시스템에 적용하는 알고리듬을 제안한다. 제안된 기법을 사용한 자기 동적 신경망으로 정보진단시스템을 구성하여 성능을 검토함으로써 진단 알고리듬의 효용성을 확인하였다.

### 2. 고장진단 알고리듬

고장진단기법에는 여러 가지가 있으나, 일반적으로 수학적 모형을 기반으로 하는 기법과 수학적 모형을 기반으로 하지 않은 기법으로 크게 나누어지며, 수학적 모형을 기반으로 하는 기법은 다시 정량적 모형을 기반으로 한 기법과 정성적 모형을 기반으로 한 기법으로 나뉜다.

수학적 모형을 기반으로 하는 기법은 수학적 모형에 근거하여 모델의 출력과 실제 시스템의 출력을 비교 분석함으로서 고장검출진단을 수행하는 해석적 기법으로 동적 시스템의 초기고장 검출에 유용하다. 그러나 이러한 기법은 시스템의 모형화가 정확하지 않을 경우 많은 문제를 일으킨다. 시스템 모형의 불확실성은 관찰할 수 있는 정보의 예측을 어렵게 만들고 잘못된

\* 正會員 : 韓國原子力研究所 研究員

\*\* 正會員 : 韓國原子力研究所 先任研究員

\*\*\* 正會員 : 韓國原子力研究所 先任研究員

§ 正會員 : 韓國原子力研究所 責任研究員 · 工博

§§ 正會員 : 龜尾一大學 電氣科 助教授 · 工博

§§§ 正會員 : 慶北大 電子電氣工學部 教授 · 工博

接受日字 : 2000年 4月 14日

最終完了 : 2000年 8月 28日

진단으로 인한 손실을 야기할 수 있다.

한편, 모델을 기반으로 하지 않는 고장진단기법은 시스템의 변수 또는 파라미터를 측정하고 이들의 통계적 특성에 대한 가설 검사에 의해 고장을 검출하는 기법, 시스템의 변수의 측정치를 도표를 이용하여 관찰함으로서 시스템을 감시하는 기법들이 있다.

본 논문에서는 모델에 기반을 두지 않고 실제 시스템에서 나오는 자료로부터 프로세서의 고장을 진단하는 기법을 사용한다.

시스템의 한 부분의 고장은 다른 부분에도 여러 가지 파급효과를 가져오게 된다. 그래서 한 부분의 고장은 여러 부분에서 각 부분 데이터에 여러 가지 문제를 일으킨다. 시스템의 각 부분에서 나오는 데이터들을 시간에 대해서 분석해 보면 일정한 패턴의 형태로 생각할 수 있다. 이러한 패턴의 형태를 잘 분석하면 고장의 종류를 파악하는데, 중요한 자료가 될 수 있다.

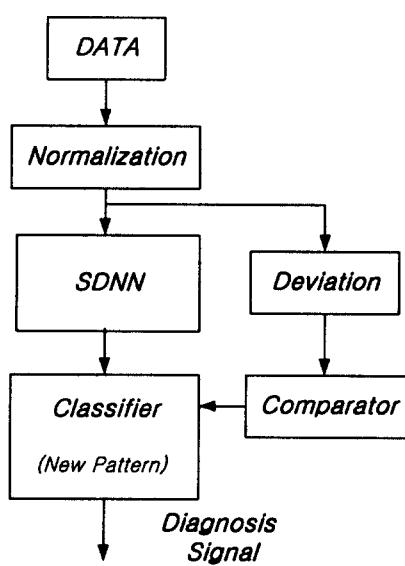


그림 1 고장진단 알고리듬

Fig. 1 Fault diagnosis algorithm

그림 1에서 나타난 것과 같이 입력 데이터 패턴을 정규화하여 받아들인다. 입력된 패턴에 대하여 자기동적신경망에 의해 학습이 되어진다. 학습되어진 패턴에 의해 분류기에 의해 고장의 종류를 출력한다. 신경망에 입력되어 들어오는 패턴의 편차(Deviation)를 측정하여 정상상태는 비하여 어느 정도 벗어났는가를 비교한다. 이것은 실제 알려지지 않은 고장이 발생했을 때 새로운 패턴으로 저장하기 위해서이다. 이는 예측하지 못한 고장에 대해서도 검출은 가능하다.

신경망이론은 학습시킨 패턴들에 대해서도 정확한 결과를 나타낼 뿐만 아니라 약간의 오차가 존재하는 패턴들에 대해서도 어느 정도 신뢰할 수 있는 결과를 나타내기 때문에 원자력 발전소의 고장진단시스템을 만드는데도 많이 연구되고 있으며 정적 신경망은 동적 사상을 표현하지 않는 정적사상인 반면에 동적 신경망은 동적 사상이다. 이 중에 동적 시스템이나 과도적인 현상을 갖는 시스템을 표현하기에 적합한 신경망은 내부적으로 상태특성을 갖는 동적 신경망이다. 시스템을

진단할 때 식별기의 파라미터가 많으면 계산시간이 오래 걸리므로 실시간 적용을 수행하기 위해서는 계산량을 줄일 수 있는 신경망 구조가 필요하다. 따라서 본 논문에서는 연결강도수가 적은 자기 동적 신경망을 사용한 고장진단 시스템의 알고리듬을 제안한다.

## 2.1 정적 신경망과 동적 신경망의 구조

정적 전방향 신경망은 단순히 연결강도에 가해진 입력의 합을 활성화 함수를 통해 출력을 나타낸다. 반면에 동적 신경망은 상태 변수의 방정식으로 출력을 표현할 수 있다. 정적 전방향 신경망의 표현식은 식 2.1과 같다.

$$O^F(k) = \sum_{j=1}^n W_j^0 F(S_j(k)) = \sum_{j=1}^n W_j^0 F \left( \sum_{i=1}^m W_{ij}^I I_i(k) \right) \quad (2.1)$$

$$\text{단 } S_j(k) = \sum_{i=1}^m W_{ij}^I I_i(k)$$

여기서  $O^F(k)$ 는 정적 전방향 신경망의 출력,  $I_i(k)$ 는 신경으로 들어오는 외부입력을 나타내고,  $W_{ij}^I$ ,  $W_j^0$ 는 입력층, 출력층의 연결강도를 나타낸다. 그리고  $m, n$ 은 각각 입력층, 중간층의 노드를 나타내고,  $k$ 는 이산시간을 나타낸다. 동적 신경망의 수학적인 표현은 식 2.2로 표현된다.

$$\begin{aligned} O^R(k) &= \sum_{j=1}^n W_j^0 F(S_j(k)) = \sum_{j=1}^n W_j^0 F \left( \sum_{i=1}^m W_{ij}^I I_i(k) + \sum_{o=1}^l W_{oj}^H X_o(k-1) \right) \\ &= \sum_{j=1}^n W_j^0 F \left( \sum_{i=1}^m W_{ij}^I I_i(k) + \sum_{o=1}^l W_{oj}^H \right. \\ &\quad \left. F \left( \sum_{i=1}^m W_{oi}^I I_i(k-1) + \sum_{o=1}^l W_{oo}^H X_o(k-2) \right) \right) \end{aligned} \quad (2.2)$$

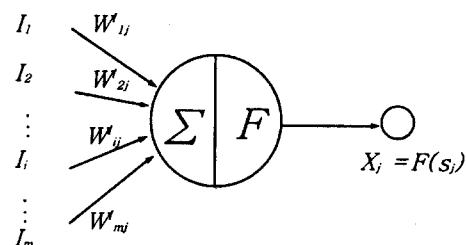


그림 2 정적 전방향 신경기(FNU)의 구조

Fig. 2 Structures of feedforward neural unit.

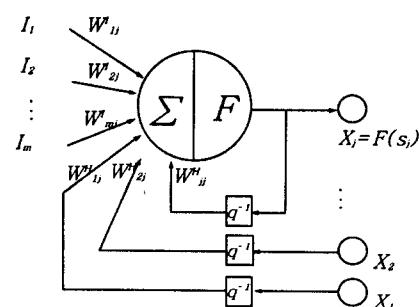


그림 3 동적 신경기(DNU)의 구조

Fig. 3 Structures of Dynamic neural unit.

여기서  $X_i(k-1)$ 은  $k-1$  시각에서  $i$  번째 신경의 상태이며,  $I_i(k)$ 는 신경으로 들어오는 외부입력,  $S_j(k)$ 는 외부 입력의 합을 나타낸다.  $O^R(k)$ 는 동적 신경망의 출력,  $W^I, W^H, W^O$ 는 입력층, 중간층, 출력층의 연결강도행렬을 나타낸다.  $F(\cdot)$ 는 신경의 활성화 함수로 하이퍼볼릭탄젠트( $\tanh(\cdot)$ ) 함수를 일반적으로 사용한다. 식 2.1은 정적 전방향 신경망으로 정적 사상이고 식 2.2는 동적 신경망으로 동적 사상을 나타내고 있다. 이러한 신경기의 기본구조를 그림 2와 그림 3에 나타내었다.

## 2.2 자기 동적 신경망의 구조와 학습 알고리듬

### 2.2.1 자기 동적 신경망의 구조

자기 동적 신경망은 동적 신경망에서 변화된 구조를 가진다. 즉 자기 동적으로 구성된 신경으로 구성되며 연결강도의 수가 적다. 자기 동적 신경망을 수학적인 표현식으로 나타내면 식 2.3과 같다.

$$O(k) = \sum_j W_j^O X_j(k) \quad (2.3)$$

여기서,  $X_j(k) = F(S_j(k))$ ,  $S_j(k) = W_j^D X_j(k-1) + \sum_i W_{ij}^I I_i(k)$ 이다. 식 2.3을 다시 전개하여 표현하면 식 2.4와 같이 나타낼 수 있다.

$$\begin{aligned} O(k) &= \sum_j W_j^O F \left( \sum_i W_{ij}^I I_i(k) + W_j^D \right. \\ &\quad \left. F \left( \sum_i W_{ij}^I I_i(k-1) + W_j^D X_j(k-2) \right) \right) \\ &= \Phi_N^D(I_i(l)) \quad l=0,1,2,\dots,k \end{aligned} \quad (2.4)$$

여기서  $X_j(k)$ 는  $j$  번째 동적 신경의 출력이며,  $I_i(k)$ 는 신경으로 들어오는  $i$  번째 외부입력이며,  $S_j(k)$ 는  $j$  번째 동적 신경으로 들어오는 외부입력의 합이며,  $O(k)$ 는 신경망의 출력이며,  $W^I, W^D, W^O$ 는 입력층에서 중간층, 중간층에서 중간층, 중간층에서 출력층의 연결강도행렬이다.  $F(\cdot)$ 는 시그모이드 함수이며,  $\Phi_N^D(\cdot)$ 은 비선형 함수이고  $l$ 과  $k$ 는 0 또는 양의 실수이다. 식 2.4는 이전의 입력을 포함하고 있는 비선형 동적 사상을 나타낸다. 각각 신경망의 연결강도 수(바이어스 연결강도를 포함)를 비교해 보면, 정적 전방향 신경망의 연결강도수 ( $G^F$ )는  $(b+r+1)*h$ 이며, 일반적인 동적 신경망의 연결강도수 ( $G^R$ )는  $(b+r+1)*h+h^2$ 이며, 자기 동적 신경망의 연결강도수 ( $G^S$ )는  $(b+r+2)*h$ 이다. 여기서  $b$ 는 신경망의 입력수이며,  $r$ 는 출력층 뉴런의 수이며,  $h$ 는 중간층 뉴런의 개수이다. 만약  $b=4$ ,  $h=9$  그리고  $r=1$ 이라면  $G^F=54$ ,  $G^S=63$ ,  $G^R=135$ 이다. 이러한 경우 일반적인 동적 신경망의 연결강도 수는 자기 동적 신경망의 연결강도 수에 비해 거의 두 배 정도나 됨을 알 수 있다. 자기 동적 신경망은 동적 특성을 가지면서 일반적인 동적 신경망에 비해 가중치 개수가 적으므로 학습시나 진단시 가중치에 거

의 비례하여 시간을 줄일 수 있다.

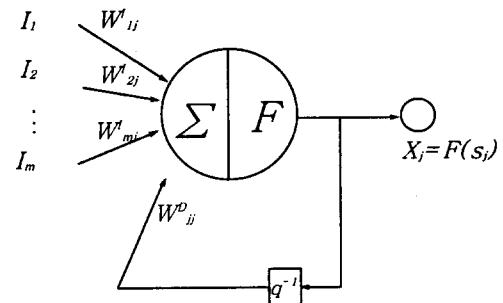


그림 4 자기 동적 신경기(SDNU)의 구조

Fig. 4 Structure of Self Dynamic neural unit.

자기동적 신경기의 구조를 그림 4에 나타내었다.

### 2.2.2 자기 동적 신경망의 학습알고리듬

자기 동적 신경망으로 구성을 다시 수식으로 표현하면 식 2.5-2.9와 같이 나타낼 수 있다.

$$\hat{y}_n(k) = \sum_j W_{jn}^O(k) X_j(k) \quad (2.5)$$

$$X_j(k) = F(S_j(k)) \quad (2.6)$$

$$S_j(k) = W_j^D X_j(k-1) + \sum_i W_{ij}^I I_i(k) \quad (2.7)$$

여기서  $X_j(k)$ 는  $j$  번째 동적 신경의 출력이며,  $I_i(k)$ 는 신경으로 들어오는  $i$  번째 외부입력이며,  $S_j(k)$ 는  $j$  번째 동적 신경으로 들어오는 외부 입력의 합이며,  $\hat{y}(k)$ 는 진단기의 출력이며,  $W^I, W^D, W^O$ 는 입력층에서 중간층, 중간층에서 출력층의 연결강도행렬이다.

임의의 고장 패턴을 함수로 표현하면 식 2.8과 같이 표현할 수 있다.

$$Y(k+1) = f[P(k)] \quad (2.8)$$

여기서  $P(k)$ 는 입력 패턴 벡터이며,  $f(\cdot)$ 는 비선형 함수이다. 식 2.8의  $f$  함수를 자기 동적 신경망을 사용하여 진단된 출력은 식 2.9와 같이 나타낼 수 있다.

$$\hat{y}(k+1) = \hat{f}(I, W^f) \quad (2.9)$$

오차 함수는 실제 학습 패턴과 진단기 출력의 함수로 표현된다.

$$E = \frac{1}{2} \sum_{n=1}^N (y_n(k) - \hat{y}_n(k))^2 = \frac{1}{2} \sum_{n=1}^N e_n(k) \quad (2.10)$$

추정되는 함수의 각 연결강도 오차 기울기는 식 2.11과 같이 나타낼 수 있다.

$$\frac{\partial E}{\partial W} = -e(k) \frac{\partial \hat{y}(k)}{\partial W} \quad (2.11)$$

여기서  $e(k)$ 는 오차 벡터이다. 신경망의 연결강도의 학습 법칙은 식 2.12와 같다.

$$W(k+1) = W(k) + [\eta] \left( -\frac{\partial E}{\partial W} \right) \quad (2.12)$$

여기서  $[y]$ 는 추정되는 함수  $\hat{f}(I, W)$ 의 각 연결강도 학습률이다.

본 논문에서 사용된 자기 동적 신경망의 입력층, 중간층, 출력층의 연결강도에 대한 출력의 기울기는 식 2.13-2.15와 같이 나타낼 수 있다.

$$\frac{\partial \hat{y}_n(k)}{\partial W_{ji}^D} = X_j(k) \quad (2.13)$$

$$\frac{\partial \hat{y}_n(k)}{\partial W_{ij}^D} = W_m^D L_i(k) \quad (2.14)$$

$$\frac{\partial \hat{y}_n(k)}{\partial W_{ii}^D} = W_m^D M_{ii}(k) \quad (2.15)$$

여기서  $L_i(k) \equiv \partial X_i(k) / \partial W_{ji}^D$ ,  $M_{ii} \equiv \partial X_i(k) / \partial W_{ii}^D$ 이며 식 2.16와 식 2.17이 성립한다.

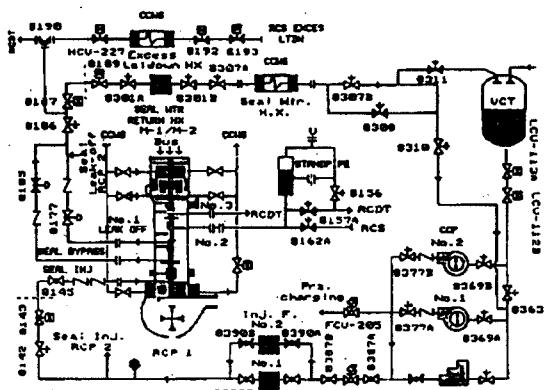
$$L_i(k) = F(S_i)(X_i(k-1) + W_{ji}^D L_i(k-1)), \quad L_i(0) = 0 \quad (2.16)$$

$$M_{ii}(k) = F(S_i)(I_i(k) + W_{ii}^D M_{ii}(k-1)), \quad M_{ii}(0) = 0 \quad (2.17)$$

식 2.13에서 식 2.17에 표현된 자기 동적 신경망  $\hat{f}(I, W)$ 의 입력층에서 중간층, 중간층에서 중간층, 중간층에서 출력층의 연결강도에 대한 출력의 기울기를 사용하여 역전파법으로 학습시킬 수 있다.

### 3. RCP 감시 시스템

일반적으로 플랜트에는 발생하는 오류나 고장을 미리 운전원에게 알려 주는 경보들이 있다. 그러나 원자력 발전소와 같은 대규모 시스템들에 심각한 고장이 발생할 경우 많은 경보들이 발생되기 때문에 이 경보들로부터 고장의 원인을 파악하기란 매우 어렵고 또한 이러한 경보들이 운전원들이 고장의 원인을 파악하는데 도움을 주기보다는 오히려 부담을 가중시켜 별로 도움을 주지 못하고 있다. 그래서 발생되는 경보들을 적절히 필터링하여 운전원에게 도움을 주는 경보처리시스템이 필요하다.



각각의 고장에 대해 발생될 수 있는 경보들은 표 3와 같이 나타나는데 각 고장에 대해 여러 경보들의 집합이 나타나는 것은 시간이나 고장의 전파방향에 따라 경보들이 다르게 발생될 수 있기 때문이다.

표 2 RCP 시스템내의 경보들

Table 2 Alarms of RCP system

Alarm codes	Descriptions
A1	Seal injection filter differential pressure high
A2	Charging pump flow low
A3	Seal injection flow low
A4	No. 1 seal differential pressure low
A5	No. 1 seal leak-off flow low
A6	Standpipe level low
A7	Standpipe level high
A8	No. 1 seal leak-off flow high
A9	Thermal barrier flow low
A10	Thermal barrier temperature high
A11	Bearing flow low
A12	Bearing temperature high

표 3 각 고장에 대한 발생 가능한 경보집합

Table 3 Possible alarm sets of system faults

Faults	Possible alarm set corresponding to each fault
C1	{A1}, {A1, A3}, {A1, A3, A4}, {A1, A3, A5}, {A1, A3, A10}, {A1, A3, A4, A5}, {A1, A3, A5, A6}, {A1, A3, A5, A10}, {A1, A3, A4, A10}, {A1, A3, A5, A6, A7}, {A1, A3, A5, A6, A8}, {A1, A3, A4, A5, A10}
C2	{A2}, {A2, A3}, {A2, A3, A4}, {A2, A3, A5}, {A2, A3, A10}, {A2, A3, A4, A5}, {A2, A3, A5, A6}, {A2, A3, A5, A10}, {A2, A3, A4, A10}, {A2, A3, A5, A6, A7}, {A2, A3, A5, A6, A8}, {A2, A3, A4, A5, A10}
C3	{A4}
C4 or C5	{A5}, {A5, A6}, {A5, A6, A7}, {A5, A6, A8}
C6	{A6}, {A6, A7}, {A6, A8}
C7	{A8}
C8	{A9}, {A11}, {A9, A10}, {A11, A12}, {A9, A11}
C9	{A12}
C1 or C2	{A3}
C1, C2 or C3	{A10}

그림 6에서 보듯이 어떤 고장이 발생했을 때 시간에 따라 순차적으로 경보가 울린다.

즉 이전의 경보 상태도 하나의 정보로 볼 수 있으므로 정적 신경망보다 이전의 상태도 고려하는 동적 신경망을 사용하였다.

표 3의 각 고장에 대한 발생 가능한 경보집합에서 예를 들어 C4 또는 C5 경우에서 A5의 경보가 울리고 A5 경보가 울리는 상태에서 A6경보가 울리는 상태를 {A5, A6}으로 나타내었으며, 그 다음상태 즉 A5와 A6경보가 울리는 상태에서 A7또는 A8경보가 울리는 것을 {A5, A6, A7}또는 {A5, A6, A8}로 나타내었다. 즉 표의 모든 경보셋은 이와 같은 표현하였다.

그림 6 혹은 표 3에서의 고장정보는 고정되었다기보다는 계속해서 증가하고, 고장원인은 다양하게 증가하므로 원인에 대한 데이터베이스는 계속해서 증가 할 것이고 복잡해지게 되며, 이들 증상들간에 연결성이 많아 해석하기가 쉽지 않으므로 이럴 경우 신경망을 이용한 고장진단이 더욱 유용할 것이다.

#### 4. 결과 및 검토

자기동적신경망을 이용하여 경보진단을 수행하기 위해서는 먼저 표 3을 이용하여 학습 패턴을 만들었다. 경보가 발생 시는 1로 하고 경보가 발생되지 않는 것은 0로 하여 입력 패턴을 생성하였으며, 신경망출력의 학습은 수렴성을 용이하게 하기 위하여 고장은 0.9 정상은 0.1로 하여 학습시켰다.

총 패턴은 정상상태 즉 경보가 울리지 않는 경우를 포함하여 42 개이고, 입력층 신경망 유니트는 12개, 중간층 신경망의 유니트는 20개이며, 출력단신경망의 유니트는 9개로 하였다. 초기 가중치를 -0.5에서 0.5사이의 램덤값을 사용하였다. 신경망의 학습률은 0.005로 하여 학습을 시켰다.

SDNN 진단 시스템의 MSE(Mean square Error)를 그림 7에 나타내었다. 정적 전방향 신경망(Static Forward Neural Network)과 동적 신경망(Dynamic Neural Network)의 학습에 따른 오차수렴의 우수성은 이미 참고문헌[7]에서 Sudharsanan 의해 비교되었다. 본 논문에서는 일반 동적신경망보다 연결 가중치가 적은 자기동적신경망으로 구성된 진단시스템의 학습오차 수렴특성이다.

고장 1이 발생하였을 때 SDNN 진단 시스템의 출력을 그림 8에 나타내었으며 고장 2가 발생하였을 때 SDNN 진단 시스템의 출력을 그림 9에 나타내었다.

그림 10은 고장 4, 5가 같이 발생했을 때의 진단시스템의 출력이다. 그리고 고장 6과 8이 발생했을 때의 SDNN 진단 시스템의 출력을 그림 11과 12에 나타내었다. A6과 A8이 발생하였을 때 진단기의 출력을 그림 11의 패턴30에 나타내었다. F6에서 고장이 일어났음을 진단하고 있다. A5가 발생하였을 때 진단기의 출력을 그림 10의 패턴26에 나타내었다. F4와 F5에서 고장이 일어났음을 진단하고 있다.

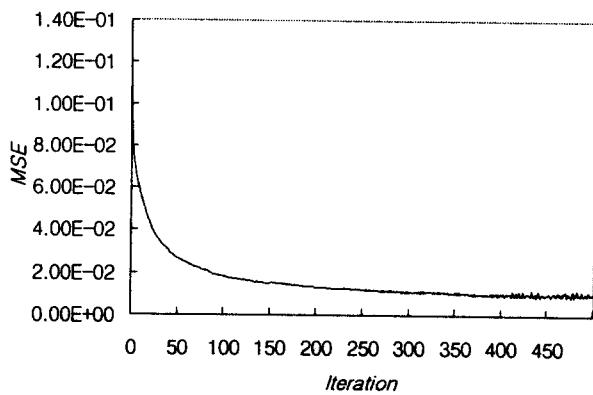


그림 7 SDNN 진단 시스템의 MSE(Mean square Error)  
Fig. 7 Mean Square Error of SDNN diagnosis system

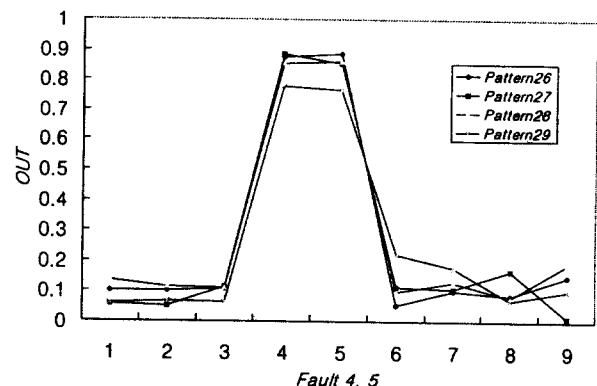


그림 10 RCP시스템의 고장 4, 5에 대한 진단  
Fig. 10 Diagnosis of Fault #4, 5 for RCP system

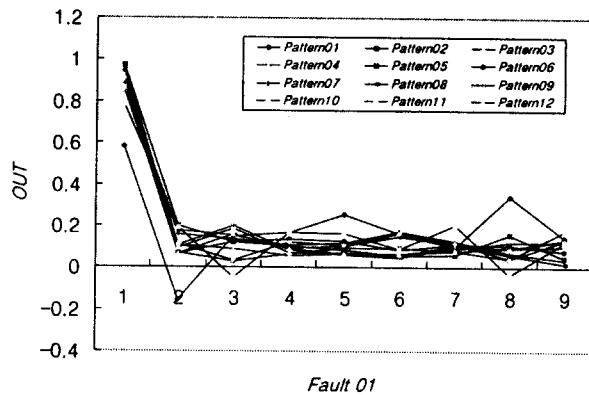


그림 8 RCP시스템의 고장 1에 대한 진단  
Fig. 8 Diagnosis of Fault #1 for RCP system

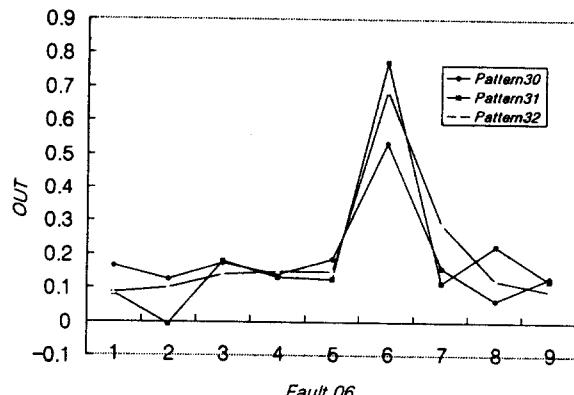


그림 11 RCP시스템의 고장 6에 대한 진단  
Fig. 11 Diagnosis of Fault #6 for RCP system

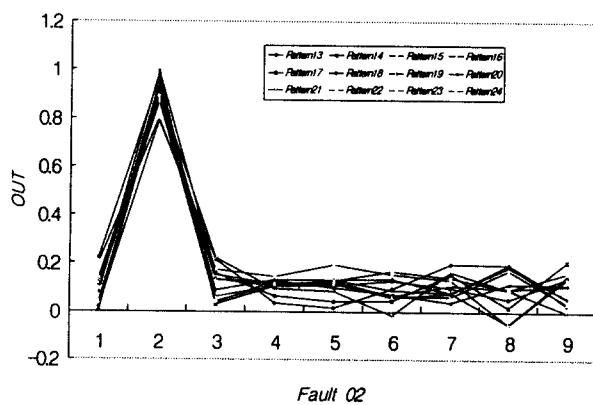


그림 9 RCP시스템의 고장 2에 대한 진단  
Fig. 9 Diagnosis of Fault #2 for RCP system

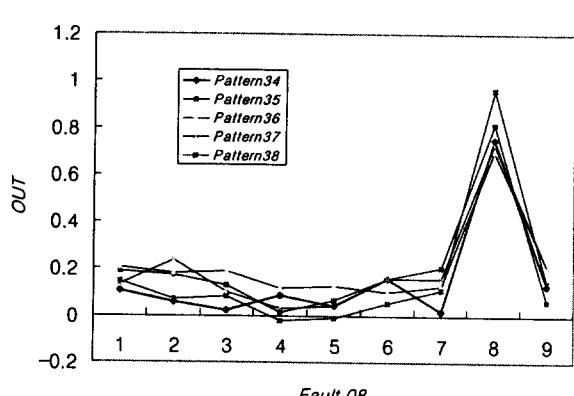


그림 12 RCP시스템의 고장 8에 대한 진단  
Fig. 12 Diagnosis of Fault #8 for RCP system

## 5. 결 론

신경망이론은 여러 가지 전문가 시스템이나 고장진단 시스템을 만드는데 많이 사용되고 있다. 신경망이론은 입출력의 비선형 함수관계를 학습에 의해 표현할 수 있고 본질적으로 병렬처리가 가능한 구조와 일반화 특성을 가지므로 원자력 발전소의 고장진단시스템을 만드는데도 많이 연구되고 있다. 정적 전방향 신경망은 동적 사상을 표현하지 않는 정적사상인 반면에 동적 신경망은 동적 사상이다.

동적 신경망은 연결강도의 수가 많기 때문에 실시간 적용을 수행하기 위해서는 무엇보다도 학습속도가 빠른 신경망 구조가 필요다. 따라서 본 논문에서는 연결강도수가 적은 자기 동적 신경망을 사용하여 원자력 발전소의 RCP 시스템의 경보진단 시스템에 적용하는 알고리듬을 제안하였다. 제안된 기법을 사용한 자기 동적 신경망으로 경보진단시스템을 구성하여 성능을 검토함으로써 진단 알고리듬의 효용성을 확인하였다.

### 감사의 글

본 연구는 과학기술부의 원자력연구기술개발사업 일환으로 수행되었습니다.

### 참 고 문 현

- [1] Eric B. Barflett, Robert E. Uhrig, " Nuclear Power Plant Status Diagnostic using an Artificial Neural Network", Nuclear Technology, Vol. 97, 1992
- [2] Robert E. Uhrig, " Potential Application of Neural Networks to the Operation of Nuclear Power Plants", Nuclear Safety, Vol.32 No. 1, 1991

- [3] 김정택 외 "고장진단기술 개발 방법 및 현황", 한국원자력 발전소, KAERI/AR-503/98, 1998
- [4] Keehoon Kim and Eric B.Bartlett "Nuclear Power Plant Fault Diagnosis Using Neural Networks with Error Estimation by Series Association" IEEE Trans on Nuclear Science, Vol. 43 No.4 1996
- [5] Liang Jin, Peter N. Nikiforuk, and Madan M. Gupta, "Dynamics and Stability of Mutilayered Recurrent Neural Networks," in Proc. 1993 IEEE Int. Conf. Neural Net, Vol II, pp. 1135-1140, 1993.
- [6] George A. Rovithakis and A. Christodoulou, "Adaptive Control of Unknown Plants Using Dynamical Neural Networks," IEEE Trans on SMC, Vol. 24 No. 3, pp. 400-411, March, 1994.
- [7] L.Ljung, "Issue in system identification," IEEE Contr. Syst. Mag., Vol. 11, pp. 270-280, 1989.
- [8] S. I Sudharsanan and M. K. Sundaresan, "Training of a three layer Dinamical recurrent neural network for nonlinear input-output mapping," in Proc. Int. Joint Conf. Neural Networks (IJCNN-91), vol. II, pp. 111-116, Seattle, WA 1991.
- [9] 성승환, 구인수외 3인 "신경망을 이용한 빠른 속도의 부하추종운전모사 기법 개발" 한국원자력학회 '98 추계학술대회 1998.
- [10] 이철권, 하재홍, 박진석, 구인수 "냉각재펌프 진동진단의 온-라인화에 관한 연구" 한국원자력학회 '97 춘계학술대회 1997. 5
- [11] 성승환, 서용석, 구인수 "SMART 인간기계 연계체계" 대한 기계학회 기계저널 1999.3
- [12] 유동완, 김동훈, 이철권, 성승환, 서보혁 "자기 동적신경망을 이용한 RCP의 경보 진단 시스템" 대한전기학회 하계학술대회 논문집 2000.7.19 pp2448-2491

## 저자 소개



유동완 (柳東完)

1968년 10월 4일 생. 1995년 영남대 공대 전기공학과 졸업. 1997년 경북대 대학원 전기공학과 졸업(석사). 1999년 동 대학원 박사과정 수료. 1999년~현재 한국원자력연구소 근무

Tel : 042-868-8245, Fax : 042-861-9618

E-mail : rdw@palgong.knu.ac.kr



구인수 (具仁守)

1953년 5월 6일 생. 1977년 경북대 전자공학과 졸업. 1995년 청주대 대학원 전자공학과 졸업(석사). 1998년 전자기술사(공업계측제어). 2000년 충남대 대학원 전자공학과 졸업(공박). 1980년~현재 한국원자력연구소 책임연구원

Tel : 042-868-2905, Fax : 042-861-9618

E-mail : iskoo@nanum.kaeri.re.kr



김동훈 (金東勳)

1961년 4월 5일 생. 1984년 한국항공대 항공전자과 졸업. 1987년~현재 한국원자력연구소 선임연구원

Tel : 042-868-8252, Fax : 042-861-9618

E-mail : dhkim4@nanum.kaeri.re.kr



박성욱 (朴省昱)

1964년 11월 16일 생. 1987년 경북대 공대 전기공학과 졸업. 1989년 동 대학원 전기공학과 졸업(석사). 1996년 동 대학원 전기공학과 졸업(공박). 1998.2.~1998.12. 영국 버밍엄 대학 Post-Doc. 연수 1992년~현재 구미1대학 전기과 조교수.

Tel : 054-440-1203

E-mail : swpark@blue.kumi.ac.kr



서보혁 (徐輔赫)

1965년 1월 16일 생. 1987년 서울대 원자핵공학과 졸업. 1989년 동 대학원 원자핵공학과 졸업(석사). 1995년 동 대학원 원자핵공학과 졸업(공박). 1995년~현재 한국원자력연구소 선임연구원

Tel : 042-868-8244, Fax : 042-861-9618

E-mail : shseong@nanum.kaeri.re.kr