

자기 동적 신경망을 이용한 RCP의 경보 진단 시스템

유동완 · 김동훈** · 이철권** · 성승환** · 서보혁*
경북대학교 전기공학과* · 한국원자력연구소 **

Alarm Diagnosis Monitoring System of RCP using Self Dynamic Neural Networks

Dong-Wan Ryoo · Dong-Hoon Kim** · Cheol-Kwon Lee** · Seung-Hwan Seong** · Bo-Hyeok Seo*
Dept. of Electrical Eng. Kyungpook Nat. Univ.* · KAERI**

Abstract - A Neural network 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.

1. 서 론

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 있다. [1-3] 신경망은 입출력의 비선형 함수관계를 학습에 의해 표현할 수 있고 본질적으로 병렬 처리가 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 신경망이다.[4,5] 어떤 고장이 발생했을 때 시간에 따라 순차적으로 시스템상태가 변화한다. 즉 시스템의 과도현상이 존재한다. 이전상태에 대한 신호도 하나의 정보로 볼 수 있으므로 정적 신경망보다 이전의 상태도 고려하는 동적 신경망이 더욱 적합하다. 시스템을 진단할 때 진단기의 파라미터가 필요 이상으로 많으면 계산시간이 오래 걸린다.[6] 그러므로 진단을 위한 신경망의 연결강도수는 적절하게 할 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 경보진단 시스템에 적용하는 알고리듬을 제안한다. 제안된 기법을

사용한 자기 동적 신경망으로 경보진단시스템을 구성하여 성능을 검토함으로써 진단 알고리듬의 효용성을 확인하였다.

2. 고장진단알고리듬

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 고장검출 진단을 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 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.

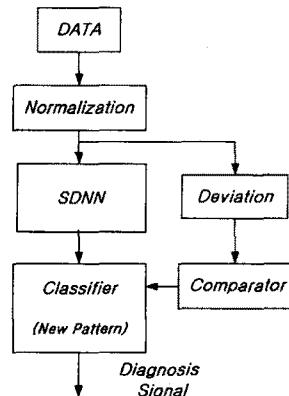


그림 1. 고장진단 알고리듬

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 부문 데이터에 여러 가지 문제를 일으킨다. 시스템의 각 부문에서 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 1에서 나타난 것과 같이 입력 데이터 패턴을 정규화 하여 받아들인다. 입력된 패턴에 대하여 자기동적신경망에 의해 학습이 되어진다. 학습되어

진 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.

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

$$\begin{aligned} O^D(k) &= \sum_{j=1}^n W_j^0 F(S_j(k)) = \sum_{j=1}^n W_j^0 F\left(\sum_{i=1}^m W_{ij}^I I_i(k) + \sum_{i=1}^m W_{ji}^H X_i(k-1)\right) \\ &= \sum_{j=1}^n W_j^0 F\left(\sum_{i=1}^m W_{ij}^I I_i(k) + \sum_{i=1}^m W_{ji}^H X_i(k-1)\right) \end{aligned} \quad (2.2)$$

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. $O^D(k)$ 은 동적 신경망의 출력, W^I, W^H, W^0 는 입력총, 중간층, 출력총의 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. 정적 전방향 신경망은 동적 사상을 표현하지 않는 정적사상인 반면에 동적 신경망은 동적 사상이다. 이 중에 동적 시스템을 표현하기에 적합한 신경망은 내부적으로 동적인 특성을 갖는 동적 신경망이다.

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.

$$O(k) = \sum_j W_j^0 X_j(k) \quad (2.3)$$

여기서, $X_j(k) = F(S_j(k))$, $S_j(k) = W_j^0 X_j(k-1) + \sum_i W_{ij}^I I_i(k)$ 이다.

식 2.3을 다시 전개하여 표현하면 식 2.4와 같이 나타낼 수 있다.

$$\begin{aligned} O(k) &= \sum_{j=1}^n W_j^0 F\left(\sum_{i=1}^m W_{ij}^I I_i(k) + W_j^D\right) \\ &= F\left(\sum_{i=1}^m W_{ij}^I I_i(k-1) + W_j^D X_j(k-2)\right) \\ &= \phi_N^D(I_j(l)) \quad l=0,1,2,\dots,k \end{aligned} \quad (2.4)$$

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^0 는 입력총에서 중간층, 중간층에서 중간층(자기귀환만 존재), 중간층에서 출력총의 연결강도행렬이다. $F(\cdot)$ 는 시그모이드 함수이며, $\phi^D(\cdot)$ 은 비선형 함수이고 l 과 k 는 0 또는 양의 실수이다. 식 2.4는 이전의 입력을 포함하고 있는 비선형 동적 사상을 나타낸다. 시스템

을 진단할 때 식별기의 파라미터가 필요 이상으로 많으면 계산시간이 오래 걸린다. 그러므로 실제 응용에서는 신경망의 연결강도는 적절하게 할 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 사용한 고장진단 시스템의 알고리듬을 사용한다.

2.2.2 자기 동적 신경망의 학습알고리듬

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

$$\widehat{y_n}(k) = \sum_j W_{jn}^0(k) X_j(k) \quad (2.5)$$

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

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

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, $\widehat{y_n}(k)$ 는 진단기의 출력이며, W^D, W^I, W^0 는 입력총에서 중간층, 중간층에서 중간층, 중간층에서 출력총의 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 패턴벡터이며, $f(\cdot)$ 는 비선형 함수이다. 식 2.8의 f 함수를 자기 동적 신경망을 사용하여 진단된 출력은 식 2.9와 같이 나타낼 수 있다.

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

오차 함수는 실제 학습 패턴과 진단기 출력의 함수로 표현된다.

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

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

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

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

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

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

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

$$\frac{\partial \widehat{y}_n(k)}{\partial W_{jn}^0} = X_j(k) \quad (2.13)$$

$$\frac{\partial \widehat{y}_n(k)}{\partial W_j^D} = W_{jn}^0 L_j(k) \quad (2.14)$$

$$\frac{\partial \widehat{y}_n(k)}{\partial W_j^I} = W_{jn}^0 M_j(k) \quad (2.15)$$

여기서 $L_j(k) = \partial X_j(k) / \partial W_j^D$, $M_j = \partial X_j(k) / \partial W_j^I$ 이며 식 2.16과 식 2.17이 성립한다.

$$L_j(k) = F(S_j(k)) (X_j(k-1) + W_j^D L_j(k-1)), \quad L_j(0) = 0 \quad (2.16)$$

$$M_j(k) = F'(S_j(k)) (I_j(k) + W_j^D M_j(k-1)), \quad M_j(0) = 0 \quad (2.17)$$

식 2.13에서 식 2.17에 표현된 자기 동적 신경망 $\widehat{f}(I, W)$ 의 입력총에서 중간층, 중간층에서 중간층, 중간층에서 출력총의 연결강도에 대한 출력의 기울기를 사용하여 역전과 법으로 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. 자기동적신경망을 이용하여 경보의 원인을 진단하기 위해서는 발생되는 경보들과 고장의 원인에 대한 인과관계를 구축해야 한다. 이 시스템은 그림 2와 같이 나타나는데 이 시스템 속에 속한 경보들과 고장의 원인들을 정하기 위한 경보 인과관계는 그림 3과 같다.

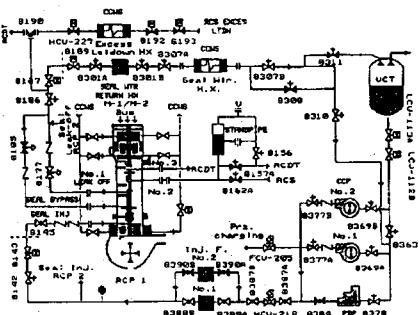


그림 2. 원자력 발전소의 RCP 시스템

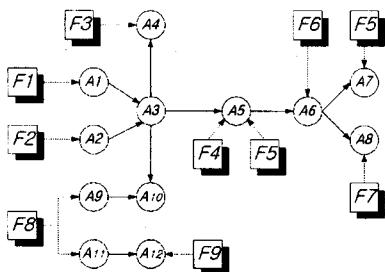


그림 3. RCP 경보들 사이의 인과관계

그림3에서 나타난 것과 같이 총 9개의 고장과 12개의 경보가 있는데 이들은 표 1 와 표 2에서 나타난 것과 같다.

표 1. RCP 시스템의 고장

Fault codes	Descriptions
F1	Seal injection filter blockage
F2	Charging pump failure
F3	Seal injection water high temperature
F4	RCS pressure less than 400 psig
F5	No. 1 seal damaged
F6	VCT back pressure high
F7	No. 2 seal damaged
F8	Insufficient CCW flow to RCP
F9	Motor bearing damaged

표 2. RCP 시스템내의 경보들

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

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. 그럼 3에서 보듯이 어떤 고장에 발생했을 때 시간에 따라 순차적으로 경보가 울린다. 즉 이전의 경보 상태도 하나의 정보로 볼 수 있으므로 정적 신경망보다 이전의 상태도 고려하는 동적 신경망을 사용하였다.

4 결과 및 검토

자기동적신경망을 이용하여 경보진단을 수행하기 위해서는 먼저 고장데이터베이스를 이용하여 학습 패턴을 만들었다. 경보가 발생 시는 0.9로 하고 경보가 발생되지 않는 것은 0.1로 하여 패턴을 생성하였다. 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 0~5.0 사이의 램덤값을 사용하였다. 신경망의 학습률은 0.005로 하여 학습을 시켰다. SDNN 진단 시스템의 MSE(Mean square Error)를 그림 4에 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 동적 신경망보다 연결 가중치가 적은 자기동적신경망으로 구성된 진단시스템의 학습오차 수렴특성을이다. 고장 1이 발생하였을 때 SDNN 진단 시스템의 출력력을 그림 5에 나타내었으며 고장 2가 발생하였을 때 SDNN 진단 시스템의 출력을 그림 6에 나타내었다.

그림7은 고장 4, 5가 같이 발생했을 때의 진단시스템의 출력이다. 그리고 고장 6과 8이 발생했을 때의 SDNN 진단 시스템의 출력을 그림8과 9에 나타내었다.

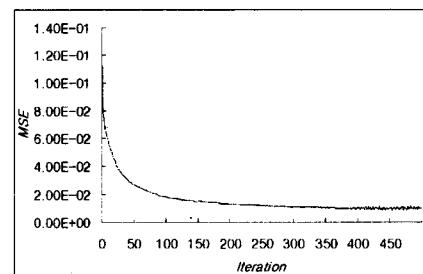


그림 4. SDNN 진단 시스템의 MSE(Mean square Error)

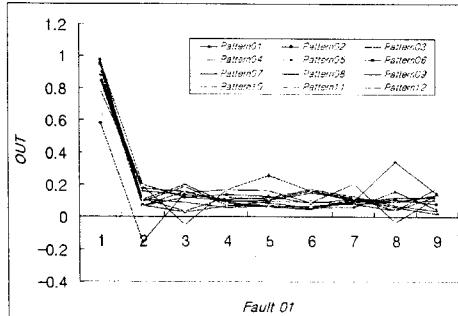


그림 5 RCP시스템의 고장 1에 대한 진단

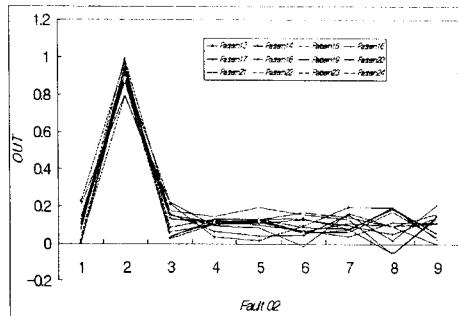


그림 6 RCP시스템의 고장 2에 대한 진단

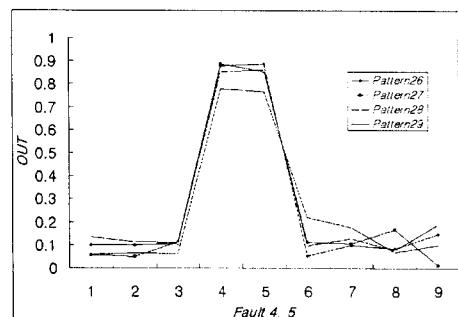


그림 7. RCP시스템의 고장 4, 5에 대한 진단

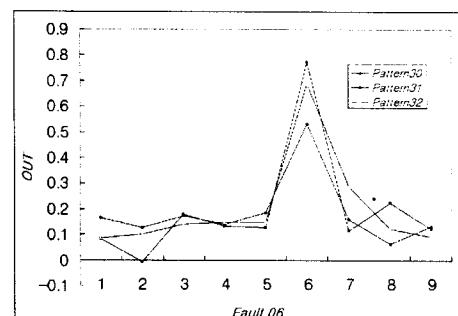


그림 8. RCP시스템의 고장 6에 대한 진단

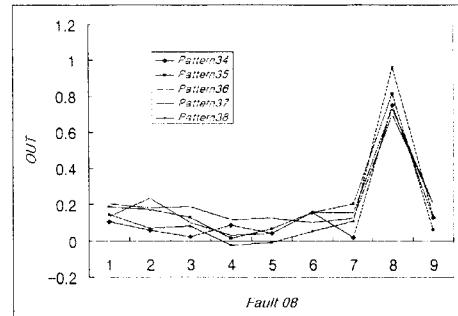


그림 9. RCP시스템의 고장 8에 대한 진단

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 가지고므로 원자력 발전소의 고장진단시스템을 만드는데도 많이 연구되고 있다. 정적 전방향 신경망은 동적 사상을 표현하지 않는 정적사상인 반면에 동적 신경망은 동적 사상을 한다.

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 경보진단 시스템을 구성하여 성능을 검토함으로써 진단 알고리듬의 효용성을 확인하였다.

(참 고 문 헌)

- [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", 한국원자력발전소, KAERI/AR-503/98, 1998
- [4] Liang Jin, Peter N. Nikiforuk, and Madan M. Gupta, "Dynamics and Stability of Multilayered Recurrent Neural Networks," in Proc. 1993 IEEE Int. Conf. Neural Net., Vol II, pp. 1135-1140, 1993.
- [5] 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.
- [6] L.Ljung, "Issue in system identification," IEEE Contr. Syst. Mag., Vol. 11, pp. 270-280, 1989.
- [7] S. I Sudharsanan and M. K. Sundaresan, "Training of a three layer Dynamical 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.