

## Design of Fault Diagnostic System based on Neuro-Fuzzy Scheme

金星鎬\* ·金正壽\*\* ·朴太洪\*\*\* ·李鍾烈<sup>§</sup> ·朴貴泰<sup>§§</sup>  
 (Sung-Ho Kim · Jung-Soo Kim · Taehong Park · Jong-Ryeol Lee · Gwi-Tae Park)

**Abstract** - A fault is considered as a variation of physical parameters; therefore the design of fault detection and identification(FDI) can be reduced to the parameter identification of a non linear system and to the association of the set of the estimated parameters with the mode of faults. Neuro-Fuzzy Inference System which contains multiple linear models as consequent part is used to model nonlinear systems. Generally, the linear parameters in neuro-fuzzy inference system can be effectively utilized to fault diagnosis. In this paper, we propose an FDI system for nonlinear systems using neuro-fuzzy inference system. The proposed diagnostic system consists of two neuro-fuzzy inference systems which operate in two different modes (parallel and series-parallel mode). It generates the parameter residuals associated with each modes of faults which can be further processed by additional RBF (Radial Basis Function) network to identify the faults. The proposed FDI scheme has been tested by simulation on a two-tank system.

**Key Words** : Fault detection and Identification(FDI), Neuro-Fuzzy Inference System, Parallel/Series-parallel mode, Radial Basis Function(RBF) network

### 1. 서 론

최근 산업용 프로세스의 가장 두드러진 특징은 자동화와 집적화라 할 수 있다. 이러한 경향은 프로세스의 고성능화, 다기능화를 가능하게 한다는 입장에서는 필수적이지만 요구되는 바의 신뢰도, 안전성 및 경제성의 확보를 위한 고성능의 감시 및 고장진단시스템(FDI: Fault Detection and Identification)의 개발은 어느 때보다도 절실히 요구되고 있다. 일반적으로 FDI는 고장의 검출을 위한 증상의 발생과 이에 근거한 고장진단 메커니즘을 포함한다. 증상발생기법은 크게 해석적 기법과 정성적 기법으로 구분할 수 있으며 이중 해석적 기법에는 상관함수, FFT 등의 주파수 특성을 이용한 신호해석기법과 파라미터, 상태변수 추정 및 패러티 방정식들을 이용한 모델기반 해석기법이 있다. 모델기반 해석기법은 지난 20년간 Wilksy, Iserman 등에 의해 저차 선형 프로세스의 구동장치 및 측정장치 등의 고장진단에 광범위하게 적용, 연구되어 왔다[1-2]. 그러나 모델기반 해석기

법은 근본적으로 계통에 대한 정확한 수학적 모델을 요구하므로 불확실성을 포함한 계통, 대규모 계통 및 비선형성이 강한 계통에의 직접적인 적용이 곤란하다는 문제점을 갖는다. 이에 반해 정성적 기법은 계통에 대한 정확한 수학적 모델을 요구하지 않으면서도 고장의 검출 및 진단을 수행할 수 있다는 점 때문에 최근 이에 대한 연구가 활발히 진행되고 있다. 이의 대표적인 예로 최근 고장진단 분야에 적극적으로 도입되고 있는 신경망 기반 진단기법을 들 수 있다. 신경망 기반 진단기법은 비선형성이 강한 고장 데이터가 주어질 경우, 다양한 학습기법에 의해 이를 효과적으로 학습시킬 수 있다는 점과 학습시 경험하지 못한 데이터에 대해서도 효율적인 보간을 수행할 수 있다는 점 때문에 진단분야에서 적극적으로 도입되고 있다. 그러나 이 기법과 관련된 하나의 단점으로 신경망 내부에 분산 저장되어 있는 유용한 고장관련 정보를 효과적으로 사용할 수 없다는 것을 들 수 있다. 만일 학습된 신경망으로부터 고장의 진단과 관련된 정보를 이용할 수만 있다면 고장진단 시스템의 신뢰도는 더욱 향상될 수 있다. 이러한 단점을 보완하기 위해 신경망이론에 퍼지개념을 도입한 LOLIMOT(Local Linear Model Tree)에 기반한 진단기법이 Iserman에 의해 페루프 제어시스템의 고장진단 등에 폭넓게 연구되고 있다[3]. 특히 Nells 등에 의해 제안된 LOLIMOT 기법은 본 연구에서 다루고자 하는 퍼지-신경망과 구조 및 기능적으로 유사하지만 고장진단과 관련된 연구들 대부분은 LOLIMOT의 내부에 분산 저장되어 있는 계통에 대한 유용한 정보를 효율적으로 사용하지 못하고 있다.

\* 正 會 員 : 群山大 制御計測工學科 副教授 · 工博

\*\* 準 會 員 : 群山大 大學院 碩士課程

\*\*\* 正 會 員 : 高麗大 情報通信研究所 工博

§ 正 會 員 : 大邱工業大學 電氣科 助教授

§§ 正 會 員 : 高麗大 電波工學科 教授 · 工博

接受日字 : 1999年 2月 11日

最終完了 : 1999年 8月 31日

본 연구에서는 LOLIMOT와 유사한 비선형 계통의 모델링에 효과적으로 사용되고 있는 퍼지-신경망을 기반으로 하는 새로운 형태의 고장진단 시스템을 제안한다. 제안된 진단 시스템은 정상동작 데이터에 의해 학습된 퍼지-신경망을 각기 병렬 및 직·병렬 모드로 동시에 동작시킴으로써 이들로부터 얻어지는 출력간의 잔차 및 퍼지-신경망에 분산 저장되는 계통의 상태와 관련된 유용한 정보 즉, 퍼지-신경망 후건부 선형 모델의 파라미터의 잔차를 이용하여 고장의 검출 및 진단을 수행하는 구조를 갖는다. 또한 Two-tank 시스템에 적용을 통하여 제안된 진단 기법의 유용성을 확인하고자 한다.

## 2. 제안된 고장 진단 시스템의 구조

본 연구에서 제안된 퍼지-신경망기반 고장 진단 시스템의 구조는 그림 1과 같다. 여기서 NN1과 NN2는 정상동작시의 프로세스 입력력 데이터 및 이의 지연된 신호들에 의해 학습된 퍼지-신경망으로 동일한 내부구조 및 파라미터를 갖는다. 이 중 NN1은 퍼지-신경망 모델을 학습 상황과 같은 환경에서 동작시키는 직·병렬모드(Series-Parallel)로 동작시킨 것이며 NN2는 신경망 모델의 추정된 프로세스 출력과 이의 지연된 신호를 입력으로 사용하는 병렬모드(Parallel)로 동작시킨 것이다. 또한 Ps부는 각각의 모드에서 퍼지-신경망 후건부 파라미터의 하중화(weighted sum)를 추출하는 기능을 한다. 일반적으로 퍼지-신경망이 NN2로 동작될 경우, 추정된 프로세스의 출력을 이용하기 때문에 실제 계통에서 고장이 발생하면 그에 대한 정보를 가지고 있지 않기 때문에 그 고장과는 무관하게 프로세스의 정상 동작을 표현하는 특징이 있다.

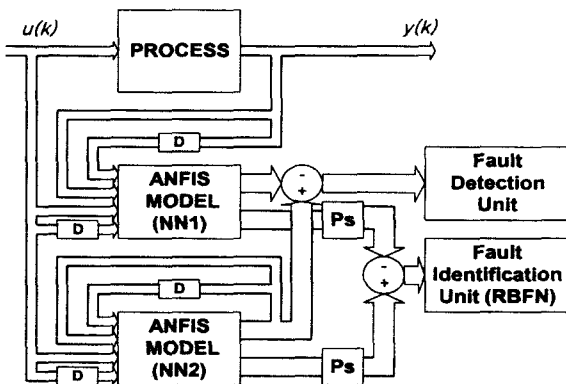


그림 1 제안된 고장진단 시스템의 구조  
Fig. 1 Structure of proposed fault diagnosis system

그러나 직·병렬모드인 퍼지-신경망(NN1)은 고장으로 인한 변동된 프로세스의 출력과 이의 지연된 값을 다시 입력으로 받아들이기 때문에 프로세스의 출력을 추종하는 특징이 있다. 또한 NN1과 NN2의 퍼지-신경망의 하중화된 후건부 선형 파라미터는 정상 동작시에는 서로 같지만 고장이 발생하면 서로 일치하지 않는다. 따라서 고장의 검출은 NN1과 NN2의 출력값 사이의 편차를 이용하여 수행될 수 있으며 고장의 진단은 NN1 및 NN2로부터 추출되는 하중화

된 후건부 선형 파라미터들간의 잔차의 양상을 고찰함으로써 수행될 수 있다. 일반적으로 각 고장원인에 대한 파라미터의 잔차는 서로 다른 양상을 띠며 따라서 이를 학습시킬 수만 있다면 고장의 진단도 가능하게 된다. 본 연구에서는 고장의 진단을 위해 효과적인 분류가 가능한 RBFN(Radial Basis Function Network)을 사용하고자 한다.

## 2.1 퍼지-신경망

퍼지-신경망은 퍼지 시스템의 언어적이고 논리적인 추론 능력과 신경망의 학습능력을 결합하여 서로의 단점을 보완한 것으로 최근 비선형 계통의 모델링 및 제어에 적극적으로 도입되고 있다[4,5]. 이와 관련된 많은 연구중 Jang 등은 퍼지 추론을 수행하는 퍼지-신경망의 결론부를 입력에 대한 선형 방정식으로 대체한 새로운 형태의 퍼지-신경망을 제안한 바 있으며 이를 나타내면 그림 2와 같다.




그림 2 퍼지-신경망의 구조  
Fig. 2 The structure of a neuro-fuzzy system

그림 2의 퍼지-신경망을 언어적 규칙으로 표현하면 다음과 같다.

- Rule 1: If  $x$  is  $A_1$  and  $y$  is  $B_1$ , then  $f_1 = p_1x + q_1y + r_1$
- Rule 2: If  $x$  is  $A_2$  and  $y$  is  $B_2$ , then  $f_2 = p_2x + q_2y + r_2$

여기서  $x, y$ : 입력,  $A_i, B_i$ : 각 입력에 대한 소속 함수,  $f_i$ : 각 규칙에서의 출력,  $(p_i, q_i, r_i)$ : 각 규칙에서 입력에 대한 선형 파라미터를 의미한다.

그림 2의 퍼지-신경망에서 layer 1, 4는 동정될 파라미터를 갖고 있으며 layer 2, 3, 5는 단지 규정된 연산만을 수행한다. layer 1의 파라미터는 신호의 forward pass시 조정되며 layer 4의 파라미터는 신호의 backward pass시 조정된다.

- 각 층의 동작에 대해서 살펴보면 다음과 같다.
- Layer 1: 이 층의 각 노드  $i$ 의 출력은 다음과 같다.

$$\begin{aligned} O_{1,i} &= \mu_{A_i}(x), & i &= 1, 2 \\ O_{1,i} &= \mu_{B_{i-2}}(y), & i &= 3, 4 \end{aligned} \quad (1)$$

식(1)에서  $x, y$ 는 노드  $i$ 의 입력,  $A_i, B_{i-2}$ 는 퍼지 언어변수이다. 출력  $O_{1,i}$ 는 퍼지 변수의 소속함수값으로 각각의 입력( $x, y$ )이 퍼지변수에 소속되는 정도를 의미하며  $\mu_A(x)$ 는 식 (2)와 같은 가우시언 함수로 표현될 수 있다.

$$\mu_A(x) = \frac{1}{1 + \left| \frac{x - c_i}{a_i} \right|^{2b_i}} \quad (2)$$

식(2)에서 {  $a_i, b_i, c_i$  } 를 퍼지-신경망의 전건부 파라미터라 하며 이들을 조절함으로써 소속함수의 모양을 변화시킬 수 있다.

**Layer 2:** 여기에 속한 각 노드는  $\Pi$ 로 표시된 고정 노드이며 각 퍼지 규칙의 전건부 적합도( $w_i$ )를 계산한다.

$$O_{2,i} = w_i = \mu_{A_i}(x) \cdot \mu_{B_{i-2}}(y) \quad (3)$$

**Layer 3:** 이 층의 모든 노드는 고정 노드이며  $i$ 번째 노드와 관련된 규칙의 적합도에 대한 모든 규칙의 적합도 합을 계산한다.

$$O_{3,i} = \bar{w}_i = \frac{w_i}{\sum w_i} \quad i=1,2 \quad (4)$$

**Layer 4:** 이 층에 속한 각 노드의 출력은 다음과 같다.

$$O_{4,i} = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i), \quad (5)$$

식(5)에서 {  $p_i, q_i, r_i$  }는 학습되어야 할 파라미터이며 이를 후건부 파라미터라고 한다(consequent parameter).

**Layer 5:** 모든 입력 신호의 합으로 전체 퍼지-신경망 모델의 출력을 계산한다.

$$f = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (6)$$

이의 추론 메커니즘을 나타내면 그림 3과 같다.




그림 3 퍼지-신경망의 추론 메커니즘  
Fig. 3 Inference mechanism of neuro-fuzzy system

퍼지-신경망의 최종 출력을 나타내는 그림 3은 식(7)과 같이 후건부 파라미터의 선형 조합으로도 표현 될 수 있다.

$$f = \frac{w_1}{w_1 + w_2} f_1 + \frac{w_2}{w_1 + w_2} f_2 = \frac{w_1(p_1x + q_1y + r_1) + w_2(p_2x + q_2y + r_2)}{(w_1p_1 + w_2p_2)x + (w_1q_1 + w_2q_2)y + (w_1r_1 + w_2r_2)} \quad (7)$$

## 2.2 퍼지-신경망의 병렬, 직·병렬 모드 구동

퍼지-신경망은 직·병렬 모델링 또는 병렬 모델링 기법에 의해 학습된다. 직·병렬 모델링은 동정될 시스템의 입출력 데이터를 이용하여 학습되며 병렬 모델링 기법은 시스템의 입력 및 퍼지-신경망의 추정 출력을 학습 입력으로 사용한다. 또한 학습이 완료된 퍼지-신경망도 학습시와 마찬가지로 직·병렬 및 병렬 모드로 동작시키는 것이 가능하다. 일반적으로 시스템이 정상적으로 동작할 경우, 직·병렬 및 병렬 모드로 동작하는 학습완료된 퍼지-신경망은 성공적으로 시스템의 출력을 모사할 수 있다. 그러나 시스템의 내부 파라미터의 변동(프로세스 고장)이 발생한다면 각 모드로 동작하는 퍼지-신경망은 서로 다른 특성을 나타낸다. 즉, 병렬 모드로 동작하는 퍼지-신경망은 자신의 출력을 입력으로 사용하기 때문에 시스템의 파라미터 변동과는 무관하게 시스템의 정상동작을 표현하게 된다. 이에 반해 직·병렬 모드로 동작하는 퍼지-신경망은 시스템의 출력을 입력으로 사용하기 때문에 고장이 발생한 경우, 병렬 모드로 동작하는 퍼지-신경망과는 다른 출력을 나타낸다. 따라서 퍼지-신경망의 상기의 특성을 이용한다면 효과적인 고장의 검출 및 진단이 가능하게 된다. 만일 정상 운전 데이터에 의해 학습된 퍼지-신경망을 각기 직·병렬모드 및 병렬 모드로 동작시킨다면 시스템에 발생된 고장(파라미터의 변동)의 검출은 각 모드로 동작하는 퍼지-신경망의 출력 잔차를 고찰함으로써 간단히 수행될 수 있다. 또한 고장의 진단(고장원인의 판별)은 퍼지-신경망 후건부에 존재하는 선형 시스템의 파라미터의 변화를 고찰함으로써 수행될 수 있다. 즉, 고장의 진단은 병렬 및 직·병렬모드로 동작하는 두 개의 퍼지-신경망의 후건부 하중화된 선형 파라미터의 잔차를 고찰함으로써 수행될 수 있다. 퍼지-신경망 후건부의 선형 파라미터들의 하중화는 다음과 같이 구할 수 있다.

$$P = [p_1, p_2, \dots, p_n]$$

$$p_i = \frac{\sum_{j=1}^l w_j p_{i,j}}{\sum_{j=1}^l w_j} \quad i=1, \dots, n \quad (8)$$

식(8)에서  $n$  은 퍼지-신경망의 후건부 선형 파라미터의 수이며  $l$  은 후건부 선형모델의 개수(규칙의 개수)이다. 또한  $p_{i,j}$ 는  $j$ 번째 규칙의  $i$ 번째 선형파라미터를 의미한다. 따라서 고장의 진단을 위해 사용되는 하중화 파라미터의 잔차는 식(9)와 같다.

$$D = P_{\phi} - P_p \quad (9)$$

식(9)에서  $P_{\phi}$ 와  $P_p$ 는 각각 직·병렬모드 및 병렬모드로 동작하는 퍼지-신경망의 하중화 파라미터를 의미한다.

## 2.3 Radial Basis Function Network의 구조

본 연구에서는 직·병렬 및 병렬모드로 동작하는 퍼지-신

경망으로부터 추출되는 파라미터 잔차를 고장의 진단에 사용하기 위하여 빠른 학습 속도 및 탁월한 분류기능을 갖는 RBFN을 사용하고자 한다. RBFN은 세 개의 층, 즉 입력 벡터에 연결된 입력층과 이 입력 층의 모든 출력을 받아들이는 은닉층 및 출력 함수를 계산하는 출력층으로 구성된다. 은닉층의 각 뉴런들은 중심(centre)과 폭(width)을 갖는 식 (10)과 같이 표현되는 가우시안 함수이다.

$$g_i(\mathbf{p}) = \mathcal{O}(\mathbf{p}, c_i, d_i) = \exp\left(-\frac{\sqrt{(\mathbf{p}-c_i)^2}}{\sigma_i^2}\right) \quad (10)$$

식(10)에서  $\mathbf{p}$ 는 입력 벡터이고  $c_i$ 는  $i$ 번째 기저함수의 중심이고  $\sigma_i^2$ 는 분산으로 함수 폭을 나타낸다. 출력층의 출력은 식(11)과 같이 구할 수 있다.

$$f(\mathbf{p}) = \sum_{i=1}^N H_i \cdot g_i(\mathbf{p}) \quad (11)$$

식(11)에서  $N$ 은 은닉층 가우시안 함수의 개수이고  $H_i$ 는 은닉층과 출력층간의 결합 강도이다.

### 3. 시뮬레이션

본 절에서는 제안된 진단기법의 유용성 확인을 위해 그림 4의 two-tank 시스템에 적용하고자 하며 이의 수학적 모델은 다음과 같다.




그림 4 Two-tank 시스템  
Fig. 4 Structure of Two-tank system

$$A_1 \frac{dL_1}{dt} = F_0 - F_1 - c_1 \sqrt{L_1} \quad (12)$$

$$\frac{dF_1}{dt} = \frac{\pi d^2}{4\rho l} [\rho g L_1 - (f + f_n) - \frac{8\rho l F_1 |F_1|}{\pi^2 d^5}] \quad (13)$$

$$A_2 \frac{dL_2}{dt} = F_1 - F_2 - c_2 \sqrt{L_2} \quad (14)$$

$$\frac{dF_2}{dt} = \frac{\pi d^2}{4\rho l} [\rho g L_2 - (f + f_n) - \frac{8\rho l F_2 |F_2|}{\pi^2 d^5}] \quad (15)$$

식 (12) - (15)에서  $A_1, A_2$ 는 각 탱크의 단면적을 나타내며  $L_1, L_2$ 는 탱크의 수위 그리고  $F_0, F_1, F_2$  각 탱크로 유입

또는 유출되는 유량을 나타낸다.  $d$  및  $l$ 은 각 파이프라인의 반경 및 길이를 나타내며  $c_1, c_2$ 는 탱크에서의 고장(tank-leakage)을  $f_n, f_n$ 는 파이프라인에서의 고장(pipe blockage)을 나타내는 파라미터이다.

시뮬레이션은 Matlab의 Simulink를 사용하여 수행하였으며 이의 블록 다이어그램을 나타내면 그림 5와 같다.






그림 5 시뮬레이션을 위한 Simulink Block diagram  
Fig. 5 Simulink block diagram for simulation

제안된 진단기법에서 중요한 역할을 하는 병렬 및 직·병렬 모드로 동작하는 퍼지-신경망은 정상동작시의 입출력 데이터에 의해 학습된다. 일반적으로 비선형 시스템의 효율적인 학습을 위해서는 시스템의 가능한 모든 상태를 여기시킬 수 있는 다양한 주파수 성분을 갖는 신호를 입력으로 사용하는 것이 바람직하며 따라서 본 연구에서는 그림 6(a)과 같이 평균이 0.9이고 분산이 0.5인 가우시안 분포를 갖는 랜덤 신호를 계통의 입력으로 사용하였다. 만일 그림 4의 two-tank 시스템을 하나의 블랙박스로 간주하여 학습 데이터로  $F_0$ 과  $F_2$ 을 사용한다면 학습 완료된 퍼지-신경망의 모델링 특성은 좋지 않게 된다. 이는 하나의 tank 시스템은 원천적으로 저역 통과필터 특성을 갖으며 따라서 lower tank의 입력(upper tank의 출력)은 시스템을 동정하기에 충분한 주파수 성분을 갖지 못하는 것에 기인한다. 따라서 본 연구에서는 각 tank 마다 하나씩의 퍼지-신경망을 할당하였으며 이의 학습은 그림 6의 입출력 데이터에 의해 수행되었다.




(a) 입력 데이터



(b) 출력 데이터

그림 6 ANFIS 학습에 사용된 입·출력 데이터

Fig. 6 I/O training data for ANFIS learning



(b) 퍼지-신경망의 응답특성

그림 8 학습된 퍼지-신경망의 모델링 특성

Fig. 8 Modeling characteristic for trained ANFIS

본 연구에서는 시행착오에 의해 학습편차를 최소로 하는 입·출력의 차수(지연된 신호의 개수)를 선정하였다. 입력으로는 탱크의 입력량,  $F_0(k)$ 과 이의 한 스텝 이전 값  $F_0(k-1)$  및 출력량,  $F_1(k-1)$ 와 이의 한 스텝 이전 값,  $F_1(k-2)$ 을 사용하였으며 각 입력 당 두 개씩 모두 8개의 소속함수를 정의하였다. 따라서 병렬 및 직·병렬 모드로 구동되는 퍼지-신경망은 상수항을 포함하여 모두 5개의 후건부 선형 파라미터를 갖는다.

상기의 데이터에 의해 학습되는 퍼지-신경망의 학습 편차는 그림 7과 같으며 약 10,000회의 학습시 RMS 학습편차는 0.01 이 된다. 또한 학습 완료된 퍼지-신경망의 모델링 특성을 확인하기 위해 학습시 사용한 입력과는 달리 평균이 0.8이고 분산이 0.5인 랜덤 입력을 인가하였을 경우의 퍼지-신경망의 모델링 특성을 나타내면 그림 8과 같다.






그림 7 퍼지-신경망 학습시의 학습편차

Fig. 7 Training RMS Error for ANFIS


그림 8로부터 알 수 있듯이 학습시 사용한 데이터와 다른 신호가 퍼지-신경망에 인가되어도 실제 시스템의 응답특성을 정확히 표현할 수 있음을 알 수 있다. 학습된 퍼지-신경망이 병렬 및 직·병렬 모드로 동작할 때, 표 1과 같은 고장이 2초인 순간에 발생한다면 각 고장에 대한 10개의 하중화 파라미터의 잔차들( $P_r$ )은 그림 9와 같다. 그림에서  $P_{r,1} \dots P_{r,5}$  및  $P_{r,6} \dots P_{r,10}$ 는 upper tank 및 lower tank의 직·병렬 모드 및 병렬모드로 구동되는 퍼지-신경망 후건부의 하중화된 파라미터들의 잔차를 나타낸다. 이 중  $P_{r,5}, P_{r,10}$ 는 퍼지-신경망 후건부 파라미터중 상수항에 대한 잔차이다. 그림 9 (a)-(e)의 0초부터 약 1초간의 파형은 퍼지-신경망의 입력으로 사용되는 신호의 차이(병렬모드에서는 퍼지-신경망 자신의 출력 및 이의 지연된 신호, 직·병렬모드에서는 실제 계통으로부터의 출력 및 이의 지연된 신호)에 의해 발생하는 것으로 정상동작시의 입·출력 데이터가 각각의 퍼지-신경망에 투입되면 이로부터의 하중화 파라미터의 잔차는 결국 0으로 수렴하게 된다. 그림으로부터 알 수 있듯이 각각의 고장에 대해 하중화된 파라미터 잔차는 각기 다른 양상을 나타내며 따라서 하중화 파라미터 잔차를 이용하여 고장 원인의 판별이 가능하게 된다. 본 시뮬레이션에서는 각각의 퍼지-신경망의 입력을 네 개로 선정하였으므로 각 퍼지-신경망의 후건부 선형 파라미터는 상수항을 포함하여 모두 5개로 된다. 이러한 퍼지-신경망이 각 탱크당 한 개씩 존재하므로 고장원인의 판별을 위한 하중화 파라미터의 잔차는 모두 10개로 된다.




(a) 입력 데이터




(a) Normal operation




(b) Upper pipe blockage



(c) Upper tank leakage



(d) Lower pipe blockage



(e) Lower tank leakage

그림 9 각 고장에 대한 파라미터 잔차  
Fig. 9 Parameter residuals for each faults

표 1 고장 및 출력 패턴  
Table 1 Considered fault and its output pattern

고장	Target
정상	정상 [1 0 0 0 0]
Upper pipe blockage	고장1 [0 1 0 0 0]
Upper tank leakage	고장2 [0 0 1 0 0]
Lower pipe blockage	고장3 [0 0 0 1 0]
Lower tank leakage	고장4 [0 0 0 0 1]

고장의 진단을 위해 도입된 RBFN은 10개의 입력뉴런 및 5개의 출력뉴런을 갖고며 은닉층 뉴런은 50개로 선정하였다. RBFN의 학습에 사용된 데이터는 그림 10과 같으며 정상상태와 각 고장당 20개씩 모두 100개의 학습화 파라미터의 잔차를 사용하였다.

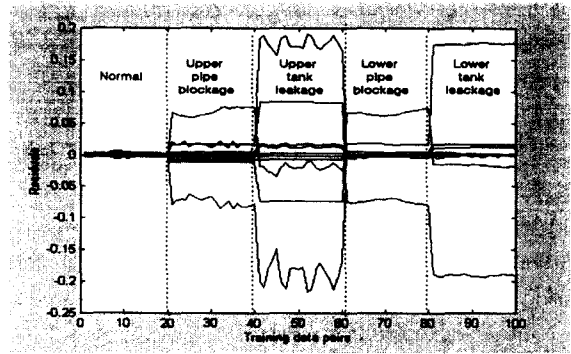


그림 10 RBFN의 학습을 위한 고장 데이터  
Fig. 10 Training Fault data for RBFN learning

제안된 진단시스템의 유용성 확인을 위하여 시뮬레이션을 수행하였으며 그 결과는 그림 11, 12와 같다.




그림 11 고장의 크기에 따른 upper tank leakage의 진단특성  
Fig. 11 Diagnostic characteristics according to different fault magnitudes in upper tank leakage




그림 12 고장의 크기에 따른 lower pipe blockage의 진단 특성  
Fig. 12 Diagnostic characteristic according to different fault magnitudes in lower pipe blockage

그림 11은 upper tank의 leakage의 크기가  $c_{n1}=0.8$ 인 경우의 데이터로 학습시킨 진단 시스템의 응답 특성을 나타내며 그림으로부터 알 수 있듯이 0.8 및 0.6 크기의 고장에 대해서는 고장의 진단이 가능함을 알 수 있다. 그러나 고장 크기가 0.2일 경우는 정상으로 판단하게 되며 이 크기의 고장은 퍼지-신경망으로부터 추출되는 하중화 파라미터 잔차의 크기가 정상의 경우와 구별이 힘든 경우에 해당한다. 본 연구에서 제안된 진단시스템의 경우, 고장의 검출은 병렬 및 직병렬 모드로 동작하는 각각의 퍼지-신경망 출력 잔차의 임계치 검사에 의해 수행된다. 본 시뮬레이션에서의 정상 운전시의 출력  $F_1, F_2$ 는 각각 0.9이며 고장의 검출을 위한 임계치는 정상상태값의  $\pm 5\%$ 로 설정하였다. 따라서  $c_{n1}=0.2$ 인 경우에는 병렬 및 직병렬 모드로 동작하는 퍼지-신경망의 출력 잔차의 크기는 임계치를 초과하여 고장의 검출이 가능하나 파라미터 잔차에 의해 학습된 RBFN의 보간능력의 한계로 크기  $c_{n1}=0.2$ 의 tank leakage를 정상으로 판별하게 된다. 이는 제안된 진단시스템에서 miss alarm 이 발생한 경우에 해당한다. 또한 그림 12는 lower pipe blockage의 크기가 서로 다를 경우의 진단 특성이다. 그림으로부터 알 수 있듯이 학습시 사용된 고장 패턴에 대해서는 정확한 진단이 가능하며 또한 고장 크기가 다른 경우의 데이터에 대해서 tank leakage의 경우와는 달리 효율적인 고장의 진단이 가능함을 알 수 있다.

#### 4. 결 론

본 논문에서는 비선형 계통에 효과적으로 적용될 수 있는 신경망기반 고장진단 시스템을 제안하였다. 제안된 시스템은 비선형 계통의 모델링에 적극적으로 도입되고 있는 퍼지-신경망과 탁월한 분류기능을 갖는 RBFN으로 구성된다. 고장의 검출은 정상운전 데이터에 의해 학습된 동일한 두 개의 퍼지-신경망을 각기 병렬 및 직.병렬 모드로 동작시키고 이들의 출력간 잔차에 근거하여 수행된다. 또한 고장의 진단은 두 가지 모드로 동작하는 퍼지-신경망의 후건부 선형모델의 하중화 선형 파라미터의 잔차를 RBFN의 학습을 통하여 수행된다. 제안된 진단기법의 유용성 확인을 위해 비선형 특성을 갖는 two-tank 시스템에 적용하여 보았다. 시뮬레이션 결과 학습시 사용된 고장과 비슷한 크기의 고장에 대하여 효과적인 고장의 검출 및 진단이 가능함을 알 수 있었다.

#### 참 고 문 헌

[1] Isermann, R.(1994). Integration of Fault detection and Diagnosis Methods, IFAC-Symposium SAFEPROESS'94, Espoo, pp. 597-612.  
 [2] Chow,E.Y. ,A.S.Willsky (1984). Analytical Redundancy and the Design of Robust Detection Systems, IEEE Transaction on Automatic Control, AC-29,7, 603-614  
 [3] Isermann, R.(1998), Closed Loop Fault Diagnosis Based on A Nonlinear Process Model and Automatic Fuzzy Rule Generation, IFAC-Symposium SAFEPRO

CESS'97, UK, pp.359-364

[4] T. Tsukagi and M. Sugeno. Derivation of fuzzy control rules from human operator's control actions.  
 [5] J.-S. R. Jang, " ANFIS: Adaptive-Network-based Fuzzy Inference Systems," *IEEE Trans. on Systems, Man, and Cybernetics*, vol. 23, pp. 665-685, May 1993.

### 저 자 소 개



#### 김 성 호 (金星鎬)

1962년 1월 27일생. 1984년 고려대 공대 전기공학과 졸업. 1986년 동 대학원 전기공학과 졸업(석사). 1991년 동 대학원 전기공학과 졸업(공학). 현재 군산대 공대 제어계측공학과 부교수



#### 김 정 수 (金正壽)

1976년 3월 30일 생. 1998년 군산대학교 제어계측공학과 졸업. 현재 동 대학원 전자공학과 석사과정  
 E-mail: maple@mouse.kunsan.ac.kr




#### 박 태 홍 (朴太洪)

1962년 12월 22일생. 1985년 고려대 공대 전기공학과 졸업. 1985년~1988년 해군사관학교 교수부 교관. 1990년 고려대 대학원 전기공학과 졸업(석사). 1995년 동 대학원 졸업(공학). 1995년~1996년 일본 OMRON 중앙연구소

Fuzzy추진 연구실 Dost-Doc. 현재 고려대 정보통신연구소

Tel : (02) 927-3268

E-mail : thpak@elec.korea.ac.kr



#### 이 중 렬 (李鐘烈)

1957년 7월 21일 생. 1981년 고려대학교 전기공학과 졸업 1986년 동 대학원 전기공학과 졸업(석사). 현재 대구공업대학 전기과 조교수

Tel : (053) 650-3891

E-mail : jylee@pyunji.taegutech.ac.kr



#### 박 귀 태 (朴貴泰)

1947년 10월 25일생. 1975년 고려대 공대 전기공학과. 1977년 동 대학원 전기공학과(석사). 1981년 동 대학원 전기공학과 졸업(공학). 현재 고려대 공대 전파공학과 교수

Tel : (02) 3290-3218

E-mail : gtpark@elec.korea.ac.kr