

# 비선형 계통의 뉴로-퍼지 동정과 이의 고장 진단 시스템에의 적용

## Neuro-Fuzzy Identification for Non-linear System and Its Application to Fault Diagnosis

°김정수\*, 송명현\*\*, 이기상\*\*\*, 김성호\*

\*군산대학교 제어계측공학과(Tel : +82-654-469-4706; E-mail : maple@mouse.kunsan.ac.kr)

\*\*순천대학교 전기공학과

\*\*\*단국대학교 전기공학과

### 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. ANFIS(Adaptive Neuro-Fuzzy Inference System) which contains multiple linear models as consequent part is used to model non linear systems. Generally, the linear parameters in ANFIS can be effectively utilized to fault diagnosis. In this paper, we proposes an FDI system for non linear systems using ANFIS. The proposed diagnostic system consists of two ANFISs 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

### 1. 서론

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 해석기법은 근본적으로 계통에 대한 정확한 수학적 모델을 요구하므로 불확실

성을 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 고장 진단 분야에 적극적으로 도입되고 있는 신경망 기반 진단기법을 들 수 있다. 신경망 기반 진단기법은 비선형성이 강한 고장 데이터가 주어질 경우, 다양한 학습기법에 의해 이를 효과적으로 매핑할 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.

본 연구에서는 비선형 계통의 모델링에 광범위하게 사용되고 있는 ANFIS(Adaptive Neuro-Fuzzy Inference System)을 기반으로 하는 고장진단 시스템을 제안한다. 제안된 진단 시스템은 정상동작 데이터에 의해 학습된 ANFIS를 각기 병렬 및 직·병렬 모드로 동시에 동작시킴으로써 이들로부터 얻어지는 ANFIS 내부의 선형 파라미터 및 출력간의 잔차를 이용하여 고장의 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 신경망 기반 고장 진단 시스템의 구조는 그림 1과 같다. 여기서 NN1과 NN2는 정상동작시의 프로세스 입·출력 데이터 및 이의 지연된 신호들에 의해 학습된 ANFIS로서 동일한 내부구조 및 파라미터를

갖는다. 또한 NN1은 ANFIS를 직·병렬모드로 동작시킨 것이며 NN2는 병렬모드로 동작시킨 것이다. 또한  $P_s$ 부는 ANFIS 후건부 파라미터의 하중화(weighted sum)을 추출하는 기능을 한다. 일반적으로 정상동작 데이터에 의해 학습된 ANFIS는 병렬모드로 사용될 경우(NN2) 고장의 발생과는 무관하게 프로세스의 정상 동작을 표현하게 된다.

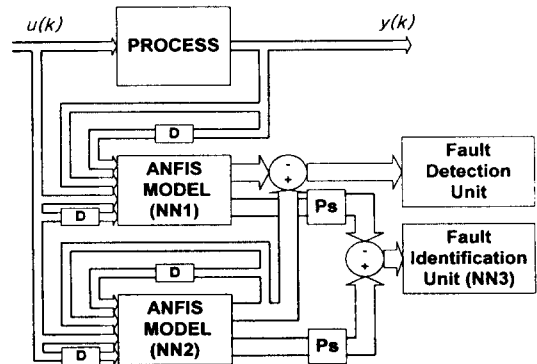


그림 1. 제안된 고장진단 시스템의 구조

Fig.1. Structure of proposed fault diagnosis system

그러나 실제 프로세스의 입·출력 데이터 및 이의 지연된 신호에 의해 구동되는 직·병렬모드의 ANFIS(NN1)는 고장으로 인한 변동된 프로세스의 출력을 추종하며 이는 ANFIS의 후건부 선형 파라미터의 변동을 초래한다. 따라서 고장의 검출은 각기 구동되는 ANFIS의 출력편차를 이용하여 수행될 수 있으며 고장의 진단은 NN1 및 NN2로부터 추출되는 하중화된 파라미터들간의 잔차를 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)(NN3)을 도입하였다.

## 2.1 ANFIS 모델의 기본 구조

최근 뉴로-퍼지기법에 의한 모델링에 대하여 많은 연구가 진행되어 왔다[3-4]. 이는 비선형 계통의 모델링 및 제어에 효과적으로 사용되고 있는 퍼지 추론 메커니즘 및 비퍼지화 과정을 학습기능을 갖는 신경망으로 구현하고자 한 것으로 Takagi-Sugeno-Kang 모델을 들 수 있다. 다음과 같이 표현되는 두 개의 퍼지 IF-THEN 규칙을 갖는 일계 TSK 모델에 대해 고찰하면 다음과 같다[3].

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

$$f_2 = p_2x + q_2y + r_2$$

그림 2 및 3은 TSK 모델의 추론 메커니즘 및 이의 신경망 구현을 나타낸 것으로 특히 그림 3과 같은 뉴로-퍼지 모델을 ANFIS(Adaptive Neuro-Fuzzy Inference System)이라 한다. ANFIS에서 layer 1, 4는 동정될 파라미터를 갖고 있으며 layer 2, 3, 5에는 동정될 파라미터가 없다. 파라미터의 동정은 두 단계를 거쳐 수행된다. layer 1의 비선형 파라미터는 신호의 backward pass시 조정되며 layer 4의 선형파라미터는 신호의 forward pass시 조절된다.




그림 2. TSK 퍼지 모델의 추론 메커니즘

Fig. 2. Inference mechanism of TSK fuzzy model




그림 3. TSK 퍼지모델의 신경망 표현

Fig. 3. Neural representation of TSK fuzzy model

각 층의 동작에 대해서 살펴보면 다음과 같다.

**Layer 1:** 이 층의 모든 노드  $i$ 는 다음과 같은 출력을 갖는 adaptive 노드이다.

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

여기서  $x(y)$ 는 노드  $i$ 에 연결된 입력이고  $A_i(B_{i-2})$ 는 각 노드에 관련된 퍼지 집합이다. 출력  $O_{1,i}$ 는 퍼지 집합 A, B의 소속 정도를 나타내고 이의 함수 형태는 다음과 같다.

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

여기서  $(a_i, b_i, c_i)$ 를 전건부 파라미터라 한다.

**Layer 2:** 이 층의 모든 노드는  $\Pi$ 로 표시된 고정된 노드(fixed node)이며 출력은 모든 입력 신호의 곱이다.

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

각 노드의 출력은 규칙의 적합도를 의미한다.

**Layer 3:** 이 층의 모든 노드는 고정 노드이며  $i$ 번째 노드와 관련된 규칙의 정규화된 적합도를 의미한다.

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

**Layer 4:** 이 층의 노드는 다음과 같은 function을 갖는 adaptive node이다.

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

여기서  $\{p_i, q_i, r_i\}$ 는 이 노드의 parameter set로 후건부 파라미터라고 한다(consequent parameter)[1].

**Layer 5:** 모든 입력 신호의 합으로 전체의 출력을 계산한다.

$$O_{5,i} = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (6)$$

ANFIS의 최종 출력을 나타내는 식(6)은 다음과 같이 후건부 파라미터의 선형 조합으로도 표현 될 수 있다.

$$\begin{aligned} f &= \frac{w_1}{w_1 + w_2} f_1 + \frac{w_2}{w_1 + w_2} f_2 \\ &= \frac{w_1(p_1 x + q_1 y + r_1) + w_2(p_2 x + q_2 y + r_2)}{(w_1 p_1 + w_2 p_2)x + (w_1 q_1 + w_2 q_2)y + (w_1 r_1 + w_2 r_2)} \quad (7) \end{aligned}$$

## 2.2 ANFIS의 병렬, 직·병렬 모드 및 잔차 발생

ANFIS의 직·병렬 및 병렬모드의 동작특성을 살펴 보면 다음과 같다. ANFIS의 직·병렬 모드 동작은 프로세스의 출력을 예측하기 위해 이전 프로세서의 출력  $y(k-d)$  및 프로세스의 입력을 사용하며 따라서 ANFIS의 출력은 프로세스의 출력을 추종하는 특성을 갖는다. 이러한 특성은 프로세스에 고장이 발생한 경우에도 나타나며 이는 ANFIS 후건부의 하중화된 선형 파라미터의 변동을 초래한다. 이에 반해 병렬모드로 동작하는 ANFIS는 프로세스의 출력을 예측하기 위해 ANFIS 출력 및 이의 지연된 신호를 사용한다. 따라서 고장의 검출은 각기 구동되는 ANFIS의 출력편차를 이용하여 수행될 수 있으며 고장의 진단은 병렬 및 직·병렬모드로 동작하는 두 개의 ANFIS부터 추출되는 하중화된 파라미터들간의 잔차를 처리

함으로써 수행될 수 있다. 직·병렬 및 병렬모드로 동작하는 ANFIS의 하중화된 잔차는 다음의 식에 의해 구할 수 있다.

$$P = \frac{1}{\sum_{i=1}^n w_i} \sum_{i=1}^n w_i p_{i,n} \quad (8)$$

여기서  $n$ 은 ANFIS의 후건부 선형화 모델의 개수이다. 따라서 고장의 진단을 위해 사용되는 파라미터 잔차는 다음에 의해 구할 수 있다.

$$D = P_{np} - P_{ns} \quad (9)$$

여기서  $P_{np}$ 와  $P_{ns}$ 는 각각 각 병렬모드 및 직·병렬모드로 동작하는 ANFIS의 하중화된 파라미터를 의미한다.

## 2.3 Radial Basis Function Network의 구조

본 연구에서는 직·병렬 및 병렬모드로 동작하는 ANFIS로부터 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 가우시언 함수이다.

$$g_i(\vec{x}) = \phi(\vec{x}, \vec{c}_i, d_i) = \exp\left(-\frac{\sqrt{d_i^2}}{\sigma_i^2}\right) \quad (10)$$

여기서  $\vec{x}$ 는 입력 벡터이고  $\vec{c}_i$ 는  $i$ 번째 기저 함수의 중심이고  $\sigma_i^2$ 는 분산으로 함수 폭을 나타낸다.

은닉층의 출력은 가우시언 함수의 중심과 입력 벡터 사이의 거리에 의해 결정되며 식(11)의 유클리드 거리를 사용한다.

$$d_i = \sqrt{(x - c_i)^2} \quad (11)$$

출력층의 출력은 식(12)와 같이 구할 수 있다.

$$f(x) = \sum_{i=1}^N W_i \cdot g_i(x) \quad (12)$$

여기서  $N$ 은 은닉층 가우시언 함수의 개수이고  $W_i$ 는 은닉층과 출력층간의 결합 강도이다.

### 3. 시뮬레이션

본 연구에서는 제안된 진단기법의 유용성을 확인하기 위하여 그림 4와 같은 two-tank 시스템을 고려하고자 한다.




그림 4. Two-tank 시스템

Fig. 4. Structure of Two-tank system

본 논문에 사용된 Matlab의 Simulink Block diagram은 그림 5와 같다. 또한 직·병렬 및 병렬모드로 동작하는 ANFIS 모델은 그림 6과 같은 계통의 정상운전시의 입·출력 데이터에 의해 학습되었다. 본 연구에서는 시행착오에 의해 학습편차를 최소로 하는 입·출력의 차수(지연된 신호의 개수)를 선정하였다. ANFIS의 학습을 위해 탱크의 입력량(In flow rate)과 이의 한 스텝 이전 값 및 현재의 출력량(Out flow rate)과 이의 한 스텝 이전 값이 학습 입력으로 사용되었다. 또한 각 입력 당 두 개씩 모두 8개의 소속함수를 할당하였으며 따라서 ANFIS 모델은 16개의 Rule(선형화 시스템)을 포함하게 된다. 학습된 ANFIS 모델이 직·병렬 및 병렬모드로 동작할 경우 표 1과 같은 고장이 발생한다면 이에 대한 각 하중화된 파라미터의 잔차는 그림 7과 같다(2초에 고장이 발생).






그림 5. 시뮬레이션을 위한 Simulink Block diagram

Fig. 5. Simulink block diagram for simulation




(a) 입력 데이터




(b) 출력 데이터

그림 6. ANFIS 학습에 사용된 입·출력 데이터


Fig. 6. I/O training data for ANFIS learning



(a) Normal operation



(b) Upper pipe blockage



(c) Upper tank leakage




그림 7. 각 고장에 대한 파라미터 잔차  
Fig. 7. Parameter residuals for each faults

고장의 진단을 위해 고장에 따른 파라미터 잔차를 RBFN을 사용하여 학습시켰으며 이의 학습 출력 패턴은 표 1과 같다. 학습시의 데이터는 그림 8과 같이 정상상태와 각 고장 패턴당 20개씩 모두 100개의 데이터를 사용하였다. 학습완료된 신경망기반 진단시스템의 유용성 확인을 위하여 시뮬레이션을 수행하였다. 그림 9는 upper tank leakage의 크기가 0.8, 0.6, 0.2인 경우에 대한 진단 특성이며 그림 10은 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 대해서도 효율적인 진단이 가능함을 알 수 있다.

#### 4. 결론

본 논문에서는 직·병렬 및 병렬 모드로 동작하는 ANFIS를 사용하여 고장의 검출 및 진단을 수행할 수 있는 시스템을 제안하고 two-tank 시스템에의 적용을 통하여 제안된 시스템의 유용성을 확인하였다. 시뮬레이션 결과 학습된 고장 데이터와 비슷한 크기의 고장이 발생한 경우에도 효과적인 진단이 가능함을 알 수 있었다.




그림 9. 고장의 크기에 따른 upper tank leakage의 진단특성

Fig. 9. Diagnostic characteristics according to different fault magnitudes in upper tank leakage

표 1. 고장 및 출력 패턴

Table 1. Considered fault and its output pattern

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



그림 10. 고장의 크기에 따른 lower pipe blockage의 진단 특성

Fig. 10. Diagnostic characteristic according to different fault magnitudes in lower pipe blockage

#### 참고 문헌

- [1] Isermann, R.(1994). Integration of Fault detection and Diagnosis Methods, IFAC-Symposium SAFEPROESS'94, Espoo, II/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] T. Tsukagi and M. Sugeno. Derivation of fuzzy control rules from human operator's control actions.
- [4] 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.