

신경회로망을 이용한 원전 PWR 증기발생기의 고장진단

Fault Diagnosis for the Nuclear PWR Steam Generator Using Neural Network

이인수* · 유철종 · 김경연**

In Soo Lee · Chul Jong Yoo · Kyung Youn Kim

* : 상주대학교 전자전기공학부 교수

** : 제주대학교 전자공학과 교수

* : School of Electronic and Electrical Engineering, Sangju National University

** : Department of Electronic Engineering, Cheju National University

요약

원자력 발전소는 안정성 및 신뢰성 확보가 가장 중요하므로 고장의 감지 및 진단 시스템의 개발은 원전 자체가 구축하고 있는 다중의 하드웨어 중첩도(hardware redundancy)에도 불구하고 가장 중요한 문제로 취급되고 있다. 본 논문에서는 원전 PWR 증기발생기에서 발생한 고장을 진단하기 위한 알고리듬의 개발을 위해 시스템에서 발생한 고장을 감지하고 분류할 수 있는 ART2 신경회로망 기반 고장진단방법을 제안한다. 고장진단시스템은 발생한 고장을 감지하기 위한 고장감지부, 변화된 시스템파라미터를 추정하기 위한 파라미터 추정부 및 발생한 고장의 종류를 알아내기 위한 고장분류부로 구성된다. 고장분류부는 여러 경계인수를 갖는 ART2(adaptive resonance theory 2) 신경회로망을 이용한 고장분류기로 구성된다. 제안한 고장진단 알고리듬을 증기발생기의 고장진단문제에 적용하여 성능을 확인하였다.

Abstract

As it is the most important to make sure security and reliability for nuclear power plant, it's considered the most crucial issues to develop a fault detective and diagnostic system in spite of multiple hardware redundancy in itself. To develop an algorithm for a fault diagnosis in the nuclear PWR steam generator, this paper proposes a method based on ART2(adaptive resonance theory 2) neural network that senses and classifies troubles occurred in the system. The fault diagnosis system consists of fault detective part to sense occurred troubles, parameter estimation part to identify changed system parameters and fault classification part to understand types of troubles occurred. The fault classification part is composed of a fault classifier that uses ART2 neural network. The performance of the proposed fault diagnosis algorithm was corroborated by applying in the steam generator.

Key words : Fault detection, fault isolation, parameter estimation, ART2 NN, nuclear PWR steam generator

1. 서 론

현대 산업시스템은 규모가 크고 복합적이며 많은 공정이 자동화되면서 시스템의 신뢰성 및 안전성의 유지에 대한 관심이 고조되고 있다. 이는 시스템의 규모가 커짐에 따라 고장의 요인과 발생빈도가 증가하고, 어느 한 소규모 공정의 정지나 오동작은 전체 공정의 운전 중단사태를 야기함으로써 생산성의 저하를 초래할 뿐만 아니라 심지어는 사람의 생명까지도 위협할 정도로 파급 효과가 매우 크기 때문이다. 특히 원자력 발전소는 안정성 및 신뢰성 확보가 가장 중요하므로 고장을 조기에 감지하고 이를 분류하기 위한 고장진단시스템의 개발은 필수적이다[1].

기존의 고장진단방법중에서 모델에 근거한 방법은 시스템의 수학적모델에 의한 해석적인 기법을 기초로 하는 것으로

서 상태추정 접근법과 파라미터추정 접근법으로 나눌 수 있다. 먼저 상태추정 접근법으로는 parity검사, Kalman filter 판측기를 이용한 이노베이션 검증법, 오류감지필터 접근법 등이 있으나 상태추정 접근법의 경우는 복잡한 시스템의 진단문제에서는 정확한 모델링이 어렵다는 문제점이 있다[2].

반면, 파라미터추정에 의한 고장진단 방법은 상태추정 접근법과 비교할 때 적용이 간단하며 플랜트 및 제어기의 고장 분류 문제에 직접 적용이 가능하다는 장점이 있다[2, 3]. 먼저 추정된 파라미터를 이용하여 모델 파라미터와 물리적 파라미터와의 관계로부터 물리적 파라미터의 변화를 계산하여 고장의 종류를 알아내는 간접적인 방법[4]은 모델 파라미터와 물리적 파라미터 사이의 비선형성으로 인해 두 파라미터 사이의 명확한 관계정립이 어렵다는 단점이 있다. 다음으로 추정된 파라미터를 직접 고장분류에 이용하는 패턴인식에 의한 방법[5]에서는 미리 구축한 고장모델과 추정된 모델과 비교하여 고장상태를 분류한다. 또한 추정된 파라미터와 다중 신경회로망을 이용하여 고장상태를 분류하는 방법[6]을 들

수 있다. 그러나 이 두 방법에서는 모든 발생 가능한 고장모델의 구축은 매우 어렵기 때문에 예기치 않은 고장상태도자동 분류할 수 있는 방법이 필요하다.

Srinivasan 등[7]은 신경회로망을 이용한 선형시스템의 고장진단방법을 연구하였으며, 이 방법에서는 Hopfield 신경회로망을 이용하여 시스템파라미터를 추정하였고 자율학습 신경회로망인 ART1 신경회로망으로 고장분류를 수행하였다. 그러나 추정파라미터가 입력패턴이므로 아날로그패턴을 분류할 수 있는 ART2 신경회로망을 이용하는 것이 적합하다.

본 논문에서는 원전 PWR 증기발생기를 입출력표현식으로 모델링하고, 증기발생기에서 발생한 고장을 진단하기 위한 ART2 신경회로망 기반 고장진단방법을 제시한다. 제시한 고장진단시스템은 발생한 고장을 감지하기 위한 고장감지부, 변화된 시스템 파라미터를 추정하기 위한 파라미터 추정부 및 발생한 고장의 종류를 알아내기 위한 고장분류부로 구성된다. 고장분류부는 여러 경계인수를 갖는 ART2 신경회로망을 이용한 고장분류기[8, 9]로 구성된다. ART2 신경회로망을 고장분류에 이용하므로 새로운 고장이 발생할 경우에도 분류가 가능하다. 또한 파라미터 추정시 센서에 존재하는 바이어스와 시스템 파라미터를 분리 추정하므로 센서의 고장을 알아낼 수 있을 뿐만 아니라 시스템 파라미터를 정확하게 추정할 수 있다. 제안한 고장진단 알고리듬을 증기발생기의 고장진단 문제에 적용하여 성능을 확인하였다.

2. 원전 PWR 증기발생기

2.1 증기발생기

본 논문에서 제안한 고장진단시스템의 성능을 검증하기 위해 영광 3/4호기의 증기발생기를 이산시간 입출력 모델로 모델링하고 실제 운전데이터를 적용하였다.

(1) 영광 3/4호기 증기발생기 및 운전 데이터

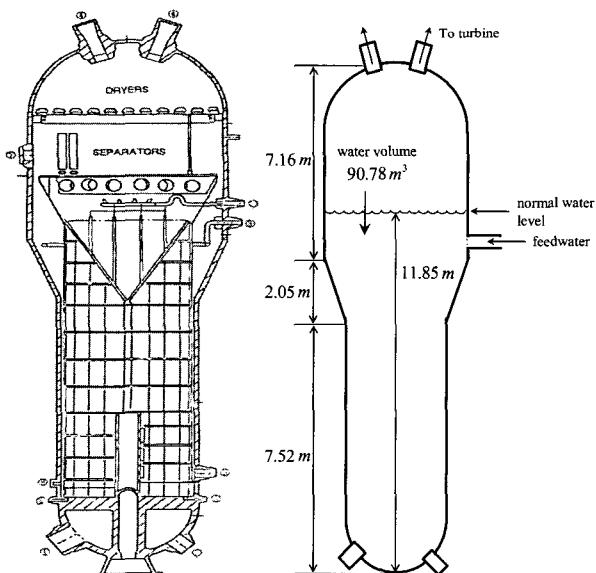


그림 1. 원전 PWR 증기발생기의 기하학적 구조

실제 영광 3/4호기 원전 PWR 증기발생기의 기하학적 구조는 그림 1과 같다. 영광 3/4호기의 경우 한국중공업자료의

design spec에 따르면, 증기발생기의 전체 체적(증기와 물)은 223.0 m^3 이고 물의 체적은 90.78 m^3 이며, 표준 수위(normal water level)는 11.85 m 를 유지한다. 그리고 증기발생기의 전체 높이는 16.73 m 이다.

여기서 수위 측정센서의 고장검출 및 진단문제를 간략화하기 위해, 증기발생기내의 물의 체적과 증기발생기의 전체 체적을 고려하여 증기발생기를 가상의 원통형 실린더로 간주한 모델을 유도하고자 한다. 우선 전체 체적을 고려했을 때의 반경을 구해보면,

$$V_{tot} = \pi \times r_{tot}^2 \times 16.73 \text{ m} = 223.0 \text{ m}^3 \quad (1)$$

에서 반경은 $r_{tot} \approx 2.06 \text{ m}$ 가 된다. 그리고 물의 체적을 고려했을 때의 반경을 구해보면,

$$V_{wat} = \pi \times r_{wat}^2 \times 11.85 \text{ m} = 90.78 \text{ m}^3 \quad (2)$$

에서 반경은 $r_{wat} \approx 1.56 \text{ m}$ 가 된다.

이 두 개의 반경의 평균 즉, $r = 1.81 \text{ m}$ 를 증기발생기의 반경으로 간주한다. 따라서 향후 고장검출 및 진단에 사용될 증기발생기 모델의 기하학적 구조는 그림 2와 같은 가상의 원통형 실린더로 나타낼 수 있다.

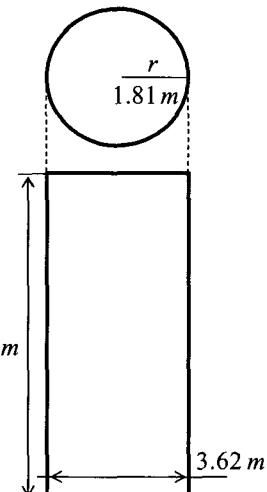
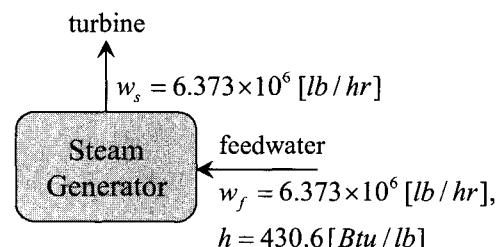


그림 2. 가상의 원통형 실린더 증기발생기의 기하학적 구조

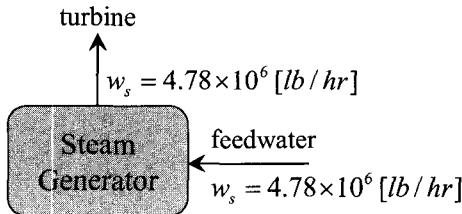
영광 3/4호기의 경우, 한국중공업자료의 design spec에 따르면 각 출력에 따른 입출력 데이터는 아래와 같다.

(가) 정격출력 power가 100%일 때



정격출력 power가 100%일 때, 2차측에서 증기발생기로 유입되는 급수의 유량과 증기발생기에서 터빈으로 유출되는 증기의 유량은 $w = 6.373 \times 10^6 [\text{lb}/\text{hr}]$ 로 같다.

(나) 정격출력 power가 75%일 때



정격출력 power가 75%일 때, 2차측에서 증기발생기로 유입되는 급수의 유량과 증기발생기에서 터빈으로 유출되는 증기의 유량은 $w = 4.78 \times 10^6 [\text{lb}/\text{hr}]$ 로 같다. 그리고 정격출력 power가 100%이거나 75%이거나 표준 수위(normal water level)는 변화가 거의 없고 11.85 m로 일정하게 유지된다.

(2) 증기발생기의 입출력형 모델링

유체 시스템의 수학적 모델은 일반적으로 비선형이다. 그러나 비선형 시스템의 작동이 정상적인 동작점 부근에 있다면 그 시스템은 동작점 부근에서 선형화될 수 있고 수학적인 모델도 선형화 될 수 있다.

그림 3과 같은 수위 시스템의 수학적 모델은 저항과 커페시턴스의 개념을 도입함으로써 시스템의 동적 특성을 간단한 입출력형 전달함수로 표현할 수 있다[10].

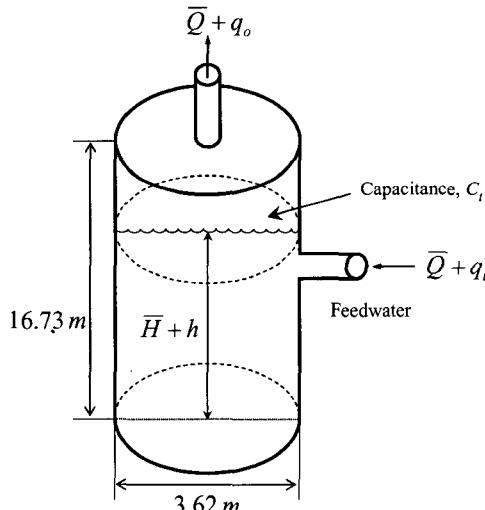


그림 3. 증기발생기의 수위 제어 시스템

이 해석에서 밸브를 통해 나오는 액체의 유출을 난류라고 가정한다. 그리고 다음과 같이 정의하자.

\bar{H} : 정상상태 수두(변화가 일어나기 전), m

h : 정상상태 값으로부터 수두의 작은 변화, m

\bar{Q} : 정상상태 유량(아무 변화도 일어나기 전), m^3/s

q_i : 정상상태 값으로부터 유입 유량의 미소변화, m^3/s

q_o : 정상상태 값으로부터 유출 유량의 미소변화, m^3/s

시간 dt 동안 탱크에 저장된 액체의 변화는 같은 시간 dt 동안 탱크에 유입된 순 유입량과 같다. 따라서

$$C_t dh = (q_i - q_o) dt \quad (3)$$

여기서 C_t 는 탱크의 커페시턴스로 수두의 단위변화를 야기하기 위해 필요한 저장 액체의 변화로 정의한다. 즉,

$$C_t = \frac{\text{저장액체의 변화, } \text{m}^3}{\text{수두의 변화, } \text{m}} \quad (4)$$

따라서 탱크의 커페시턴스는 탱크의 단면적과 같다.

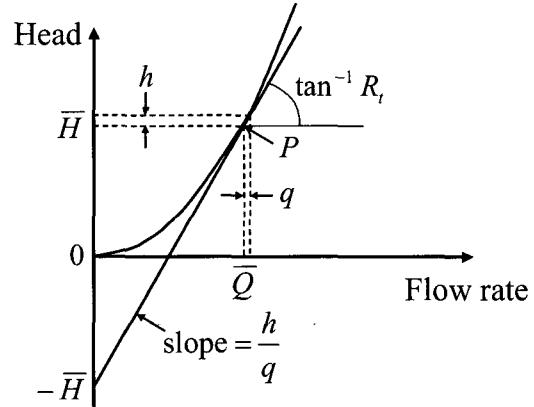


그림 4. 수두와 유량과의 관계 곡선

작동 조건이 거의 변하지 않는다면, 즉, 작동시간동안 수두와 유량의 변화가 작다면 저항 R_t 의 값은 전체 작동 시간동안 거의 상수로 취급할 수 있을 것이다. 여기서 관에서 액체 흐름에 대한 저항 R_t 는 유량의 단위 변화를 야기하는데 필요한 수위차의 변화로 정의한다. 즉,

$$R_t = \frac{\text{수위차의 변화, } \text{m}}{\text{유량의 변화, } \text{m}^3/\text{s}} = \frac{dH}{dQ} \quad (5)$$

본 시스템에서 h 와 q_o 가 각각 정상상태 수두와 정상상태 유출유량으로부터 작게 변화한다고 정의한다. 따라서

$$dH = h, dQ = q_o \quad (6)$$

그러면, 저항 R_t 는 그림 4의 작동점 P 에서 곡선의 기울기와 같으며 다음과 같이 쓸 수 있다.

$$R_t = \frac{dH}{dQ} = \frac{h}{q_o} \quad (7)$$

이 식을 식 (3)에 대입하여 정리하면

$$R_t C_t \frac{dh}{dt} + h = R_t q_i \quad (8)$$

를 얻는다. $R_t C_t$ 는 시간의 차원을 가지며 시스템의 시정수라는 것에 주목하자. 식 (8)은 q_i 를 입력, h 를 시스템의 출력으로 생각했을 때 아래와 같이 입출력형 전달함수를 얻을 수 있다.

$$\frac{h(s)}{q_i(s)} = \frac{R_t}{R_t C_t s + 1} \quad (9)$$

3. 입출력 모델기반 고장진단기법

본 논문에서 제시한 고장진단기법의 구성은 그림 5와 같이 시스템에서 고장으로 변화된 시스템 파라미터 및 센서에

존재하는 바이어스를 추정하기 위한 파라미터추정부, 고장상태를 감지하기 위한 고장감지부 및 발생한 고장의 종류를 분류하기 위한 고장분류 부분으로 이루어져 있으며, 고장분류를 위해서는 ART 신경회로망을 이용한다.

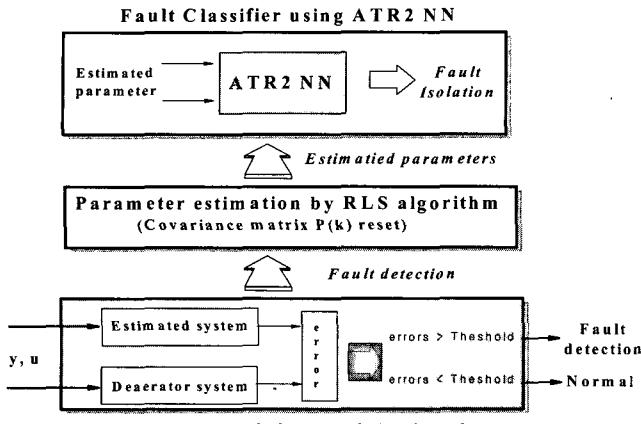


그림 5. 증기발생기 고장진단 시스템 구조도

3.1 시스템 파라미터의 추정부

본 논문에서는 고장진단을 위한 대상 시스템은 아래와 같은 ARMA(autoregressive moving-average) 모델식으로 표현된다고 가정한다.

$$\begin{aligned} y(k) &= a_1 y(k-1) + \cdots + a_n y(k-n) \\ &\quad + b_1 u(k-1) + \cdots + b_m u(k-m) + \varepsilon(k) \\ &= \theta^T \phi(k) + \varepsilon(k) \end{aligned} \quad (10)$$

여기서 $u(k)$, $y(k)$ 는 각각 시스템의 입력과 출력, θ 와 $\phi(k)$ 는 각각 시스템 파라미터와 측정벡터이며 $\varepsilon(k)$ 는 백색 잡음이라고 가정한다. 시스템의 고장과 센서의 바이어스를 동시에 고려하면 시스템모델은 다음과 같이 수정할 수 있다.

$$y(k) = \theta_f^T \phi(k) + f_s + \varepsilon(k) \quad (11)$$

여기서 θ_f^T 로서 시스템의 고장으로 인해 변화된 시스템 파라미터벡터이며, f_s 는 센서에 존재하는 바이어스로서 오프셋 형태의 덧셈형으로 가정한다. 바이어스를 고려한 최소화해야 할 성능지수, 출력오차와 추정출력을 각각 아래와 같이 정의 한다.

$$J(k) = \sum_{i=1}^k e^2(i) \quad (12)$$

$$e(k) = y(k) - \hat{y}(k) \quad (13)$$

$$\hat{y}(k) = \theta_{aug.}^T \phi_{aug.}(k) \quad (14)$$

여기서 $\theta_{aug.}$ 와 $\phi_{aug.}(k)$ 는 각각 시스템 파라미터와 센서에서 발생된 바이어스를 분리 추정하기 위해 확장시킨 파라미터벡터 및 확장시킨 측정벡터로서

$$\theta_{aug.} = [\hat{a}_1 \cdots \hat{a}_n, \hat{b}_1 \cdots \hat{b}_m, f_s]^T \quad (15)$$

$$\phi_{aug.}(k) = [y(k-1) \cdots y(k-n), u(k-1) \cdots u(k-m), 1]^T \quad (16)$$

와 같으며 식 (12)를 최소화하는 추정시스템 파라미터와

센서 바이어스를 구하기 위한 RLS 알고리듬[11]은 다음과 같다.

$$\theta_{aug.}(k+1) = \theta_{aug.}(k) + F(k+1) \phi_{aug.}(k+1) e^0(k+1) \quad (17)$$

$$F(k+1) = F(k) - \frac{F(k) \phi_{aug.}(k+1) \phi_{aug.}(k+1)^T F(k)}{1 + \phi_{aug.}(k+1)^T F(k) \phi_{aug.}(k+1)} \quad (18)$$

$$e^0(k+1) = y(k+1) - \phi_{aug.}^T(k+1) \theta_{aug.}(k) \quad (19)$$

여기서 $F(k)$ 는 파라미터 추정치의 수렴률을 조정하는 공분산행렬이며, e^0 는 시스템출력과 추정출력사이의 오차이다.

3.2 고장감지부

본 연구에서는 시스템에서 발생한 고장을 감지하기 위해 문턱값 비교방법을 이용한다. 즉, 실제 시스템 출력과 추정 출력 사이의 오차를 계산하여 윈도우 내에서의 오차가 다음과 같은 조건을 만족하면 고장이 발생된 것으로 인식한다.

$$J_L(k) = \sum_{i=k-L+1}^k e^2(i) > \delta_f \quad (20)$$

여기서 $e(i) = y(i) - \hat{y}(i)$ 는 시스템 출력과 추정 출력사이의 오차이고, L 은 윈도우 크기이고 δ_f 는 고장감지를 위한 문턱값이다.

추정 파라미터가 시스템 파라미터에 근접하면 시스템 출력과 추정 출력사이의 오차는 시스템 잡음과 거의 같은 성질을 가지며[12], 시스템 출력과 추정 출력사이의 오차 e 는 정규분포 $N(0, \sigma^2)$ 를 따른다. 그러므로 윈도우 내에서 L 개의 정규화된 자승오차의 합 \bar{J}_L 은 아래와 같이 자유도(degree of freedom)가 L 인 χ_L^2 (chi-square)분포를 따르게 된다.

$$\bar{J}_L(k) = \sum_{i=k-L+1}^k \frac{e^2(i)}{\sigma^2} \sim \chi_L^2 \quad (21)$$

본 논문에서는 잡음 만에 의한 허위고장신호 발생확률을 줄이는 방향으로 문턱값 δ_f 를 설정한다. 시스템이 정상일 때 허위고장신호 발생확률의 허용한계를 α 라고 하면

$$\Pr(\bar{J}_L(k) \geq \delta_f) = \alpha \quad (22)$$

이므로 χ^2 분포표로부터 상수 δ_f 를 구한 뒤 이로부터 고장감지를 위한 문턱값 $\delta_f = \sigma^2 \delta_f$ 를 구한다. 그러나 구한 δ_f 가 너무 커서 실제 고장에 의한 변화를 감지하지 못하는 경우가 발생할 수도 있으므로 경험적 요소를 가미하여 문턱값을 적절하게 선정할 필요가 있다.

시스템의 현재 상태가 식 (20)을 만족하면 고장이 발생한 경우로서, 시스템에서 발생한 고장 종류를 알아내기 위해 공분산행렬을 초기화한 뒤 변화된 시스템 파라미터를 추정하다가 추정된 파라미터가 아래 식을 만족하여 변화된 시스템 파라미터에 수렴하면 시스템에 발생한 고장의 종류를 알기 위해 추정 파라미터를 다음 절에서 설명할 ART2 신경회로망에 전달한다.

$$J_L(k) = \sum_{i=k-L+1}^k e^2(i) < \delta^* \quad (23)$$

여기서 δ^* 는 변화된 시스템 파라미터에 대한 추정 파라미터의 수렴정도를 나타내는 문턱값으로서, 높게 설정하면 파라

미터 추정시간은 단축시킬 수 있으나, 변화된 파라미터에 대한 추정 파라미터의 수렴정도가 낮아지므로 현재의 시스템의 상태와는 다른 고장 클래스로 잘못 분류 할 가능성이 커진다. 이에 반해서, 낮게 설정할수록 변화된 시스템 파라미터를 잘 추정한다고 볼 수 있으나 추정시간이 길어지므로 분류기에 추정 파라미터의 전달이 늦어지고 이로 인해서 고장 분류 시간이 길어진다. 그러므로 δ^* 는 파라미터의 수렴성을 고려하여 결정하며, 고장감지를 위한 문턱값에 비해서는 낮게 설정하는 것이 바람직하다. 또한 원도우 크기 L 이 크면 추정치의 신뢰도는 증가하나, 과거의 데이터를 많이 이용하므로 써 고장에 빠르게 반응하기가 힘들뿐만 아니라 분류가 늦어진다. 반면에 원도우 크기가 너무 작으면 추정치의 분산이 커지고, 추정 파라미터의 신뢰도가 낮아지므로 적절히 선정한다. 그리고 센서에 존재하는 바이어스의 크기는 추정된 바이어스 f_s 로부터 직접 알 수 있다.

3.3 ART2 신경회로망 고장분류기

ART2 신경회로망은 이미 학습된 패턴과 입력패턴간의 일치정도를 검사하기 위한 경계인수 검사를 통해 유사하면 같은 클래스로 학습하고, 그렇지 않으면 새로운 클래스를 생성시키는 증가 분류 알고리듬에 의해 패턴을 분류함으로써 추가 학습이 가능하다는 장점이 있다. 이러한 ART2 신경회로망의 특징은 예상하지 않은 새로운 고장정보의 구축과 분류에 있어서 효과적으로 이용될 수 있으므로 이를 고장분류기로 사용한다면 새로운 고장이 발생했을 때 이를 효과적으로 분류할 수 있다. 본 절에서는 하나의 경계인수를 사용하는 기준의 ART2 신경회로망의 단점을 보완한 여러 경계인수를 갖는 ART2 신경회로망[8]을 추정 파라미터에 의한 고장분류문제에 적용한다.

여러 경계인수를 갖는 ART2 신경회로망은 그림 6과 같이 패턴을 저장하기 위한 계층 1과 경계인수검사를 통해 이미 저장된 패턴과 유사성이 없는 패턴이 입력될 경우 새로운 클래스를 생성시키기 하는 계층 2로 구성된다. 최초의 입력 패턴이 ART2 신경회로망에 전달되면 첫 번째 클래스로 분류하여 입력패턴을 첫 번째 출력노드와 입력노드들간의 가중치로 저장한다.

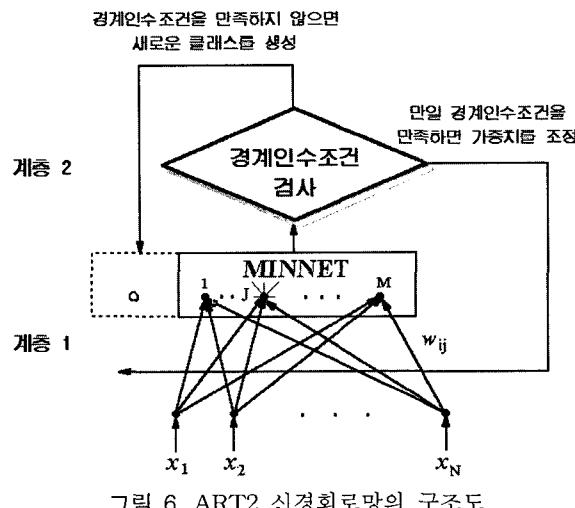


그림 6. ART2 신경회로망의 구조도

새로운 입력패턴이 신경회로망에 전달되면 입력패턴과 각 출력노드와의 거리를 아래와 같이 계산한다.

$$d_j = \| W_j - X \|^E_\infty \quad (24)$$

$$\hat{=} \max_i | \frac{1}{\varepsilon_i} (w_{ij} - x_i) |$$

여기서 W_j 와 w_{ij} 는 각각 j번째 출력노드에 대한 N차원의 가중치벡터 및 i번 째 입력노드와 j번째 출력노드 사이의 가중치이며, X 와 x_i 는 각각 N차의 입력벡터 및 i번 째 입력이고 N은 입력노드 수이다. 또한 $i=1, 2, \dots, N$ 및 $j=1, 2, \dots, M$ 이다. $\| \cdot \| ^E_\infty$ 는 가중치가 부여된 무한대 노음이며 $E = \text{diag}(\frac{1}{\varepsilon_1}, \frac{1}{\varepsilon_2}, \dots, \frac{1}{\varepsilon_N})$ 로서 $N \times N$ 차원의 대각 가중치행렬이고, ε_i 는 i번 째 입력노드의 입력패턴에 대한 경계인수이다.

출력노드중에서 식 (24)에 의해 계산된 거리가 최소인 노드만이 활성화되며, 입력패턴과 활성화된 출력노드에 대한 템플리트패턴과의 유사성은 계층 2에서의 경계인수조건 검사를 통해서 판별되는데 여러 경계인수를 갖는 ART2 신경회로망에서는 아래와 같은 경계인수 조건을 사용한다.

$$\| W_j - X \|^E_\infty < 1 \quad (25)$$

여기서 W_j 는 계산된 거리가 최소인 J 번째 출력노드에 관한 N차원의 저장패턴벡터로서 신경회로망의 가중치이다.

만일 입력패턴이 경계인수 검사를 통과하면 입력패턴을 선택된 클래스로 분류하고 아래와 같은 가중치 조정식을 이용하여 선택된 클래스의 가중치를 조정한다.

$$W_J^{\text{new}} = \frac{X + W_J^{\text{old}} [\text{class}_J^{\text{old}}]}{[\text{class}_J^{\text{old}}] + 1} \quad (26)$$

여기서 W_J^{old} 와 W_J^{new} 는 각각 J 번째 출력 노드에서의 조정 전후의 가중치이며, $[\text{class}_J]$ 는 class_J 에 속한 패턴들의 개수이다. 그러나 경계인수 검사를 통과하지 못하면 아래와 같이 입력패턴을 새로운 클래스로 저장한다.

$$W_{M+1} = X \quad (27)$$

여기서 W_{M+1} 은 새롭게 추가된 $M+1$ 번째 출력노드와 입력노드 사이의 가중치벡터로서 경계인수 조건검사를 통과하지 못한 입력패턴을 저장한다.

4. 시뮬레이션결과 및 고찰

증기발생기의 고장상황에 대한 시뮬레이션을 통하여 제안한 고장진단방법의 타당성을 살펴본다. 증기발생기의 폐루프 전달함수는 아래와 같다.

$$\frac{\theta_O(s)}{\theta_i(s)} = \frac{R_t}{R_t C s + 1} \quad (28)$$

여기서 R_t 는 저항의 정의로부터 $R_t = \frac{h}{q_i}$ 로 구해지며, h 는 수두의 변화량, q_i 는 유입량이고 C 는 아래와 같이 구해진다.

$$C = 2 \times \sqrt{r^2 - (\bar{H} - r)^2} \times L \quad (29)$$

여기서 \bar{Q} 와 \bar{H} 는 각각 정상상태 유입량 및 수두높이이다. 시뮬레이션에 사용한 각 상수 값(power 100% 일 때)은 아래와 같으며

$$\bar{Q} = 802.998 \text{ Kg/sec}, \bar{H} = 11.85 \text{ m}$$

$$r = 1.81 \text{ m}, L = 16.73 \text{ m}$$

Power가 75%로 감소했을 때는 아래와 같다.

$$\bar{Q} = 602.249 \text{ kg/sec}, \bar{H} = 11.85 \text{ m}$$

식 (28)을 표본화 입출력 θ_i 와 θ_o 에 대한 이산시간으로 표현하면 다음과 같다.

$$\theta_o(k+1) = a_1 \theta_o(k) + b_1 \theta_i(k) + \epsilon(k) \quad (30)$$

여기서 a_1, b_1 은 추정해야 할 파라미터들로서 ART2 신경회로망 고장분류기의 입력이며, 표본화주기는 0.1초로 하였다. $\alpha = 0.01$ (1%)이고, 고장감지를 위한 문턱값 δ_f 를 구하면 0.001이다. 여러 번의 시뮬레이션을 통해서 δ^* 및 L은 각각 0.0009 및 30으로 설정하였고 고장분류를 위한 ART2 신경회로망의 경계인수 ϵ_1 와 ϵ_2 를 각각 0.03과 0.003으로 설정하였다. 아래와 같이 수위 측정센서에 바이어스가 존재하는 센서고장과 Power가 75% 감소한 경우에 대한 시뮬레이션을 수행하였으며, 고장은 이산적으로 발생한다고 가정하였다.

고장 #1 : Power 100%, 시스템은 정상이지만 센서에 바이어스존재 ($f_s = 1.2$)

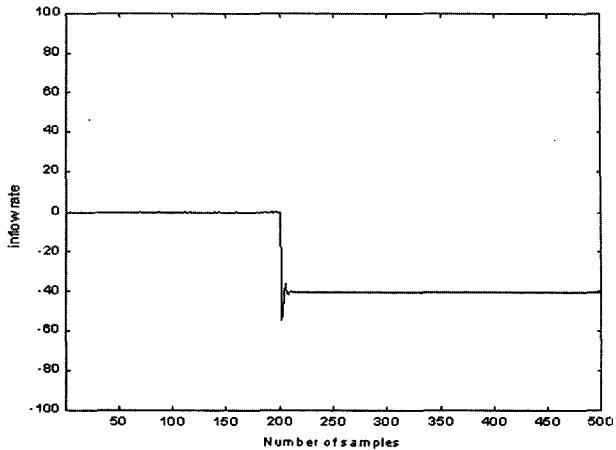
고장 #2 : Power가 75%로 감소하고 센서에 바이어스존재 ($f_s = -1.2$)

고장 #3 : Power가 75%로 감소하고 센서에 바이어스존재

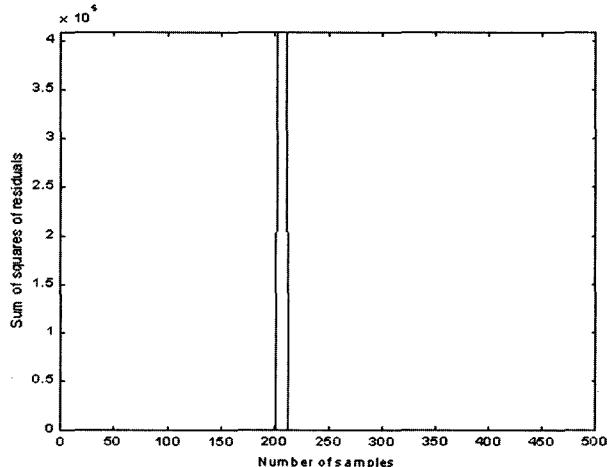
$$f_s = \begin{cases} 1.2 & (200 \leq k < 300) \\ 1.7 & (300 \leq k) \end{cases}$$

그림 7은 고장 #1이 200번째 순간(20초)에 발생된 경우로서 그림 (a)는 유입량의 변화를 도시하고 있으며, 그림 (b)로부터 200번째 순간에 고장이 감지되었음을 알 수 있다. 또한, 그림 7(c)와 (d)는 시스템 파라미터의 실제값과 추정값을 도시한 것으로서 실제값을 잘 추정하고 있음을 알 수 있다. 그리고 그림 (e)의 추정 바이어스량 \hat{f}_s 으로부터 센서에 1.2의 바이어스가 존재함을 알 수 있으며, 그림 (f)로부터 ART2 신경회로망 고장분류기에 의해 시스템의 상태가 정상(고장클래스 #1)으로 선언됨을 알 수 있다. 그림 8은 고장 #2가 발생된 경우로서 200번째 순간에 power가 75%로 감소하고 200번째 순간에 바이어스가 발생되었는데 200번째에 고장이 감지되고, 그림 8(c)와 (d)의 시스템파라미터 추정값으로부터 Power의 감소로 인해 시스템파라미터가 변했음을 알 수 있다. 그림 (e)의 결과로부터 센서에 -1.2의 바이어스가 존재함을 알 수 있으며, 신경회로망의 출력을 도시한 그림 (f)로부터 ART2 신경회로망 고장분류기는 일치되는 고장모델이 없음을 선언하고 이를 정상상태클래스가 아닌 새로운 고장클래스 #2(Power가 75%로 감소)로 분류함을 알 수 있다. 그림 9는 고장 #2에 대한 고장클래스 #2가 추가된 뒤 고장 #3이 발생된 경우로서 그림 (a)로부터 200번째 순간과 300번째에 고장이 감지되고, 그림 (b)의 결과로부터 센서에 200번째에서 300번째까지는 1.2의 바이어스, 300번째부터는 1.7의 바이어스가 존재함을 알 수 있다. 반면, 그림 9(c)에 도시된 바와

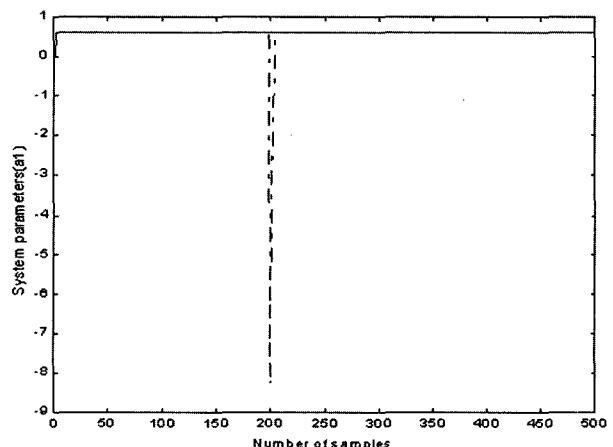
같이 ART2 신경회로망 고장분류기는 시스템의 상태를 기준에 발생한 고장클래스 #2로 분류함을 알 수 있다.



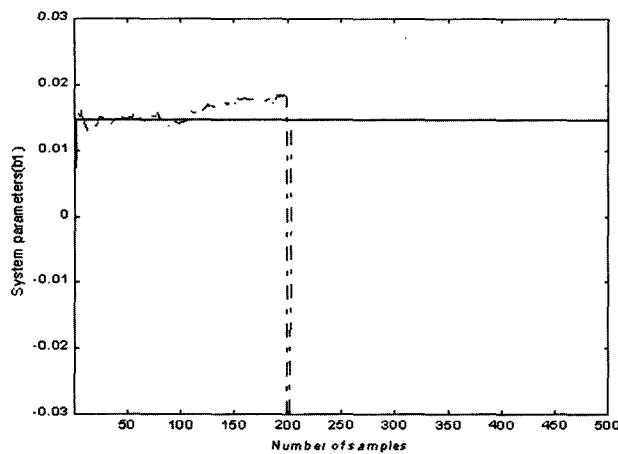
(a) 센서 바이어스 존재시 유입량(제어기 사용)



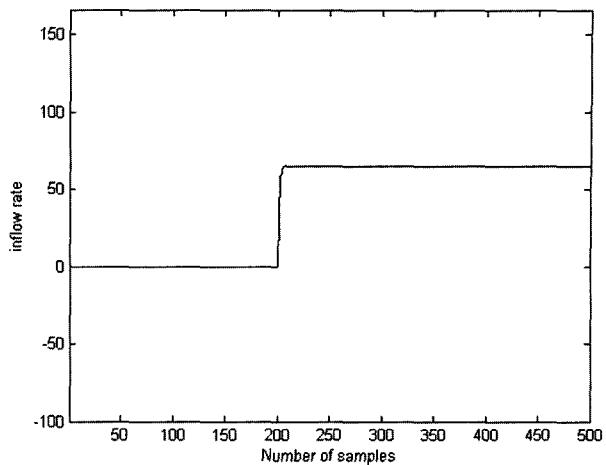
(b) J_L 변화와 고장감지(점선: δ_f , 일점쇄선: δ^*)



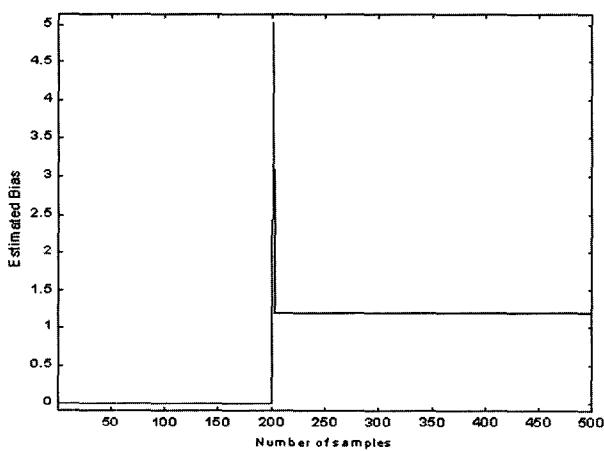
(c) 시스템파라미터(a_1) (실선: 실제값, 일점쇄선: 추정값)



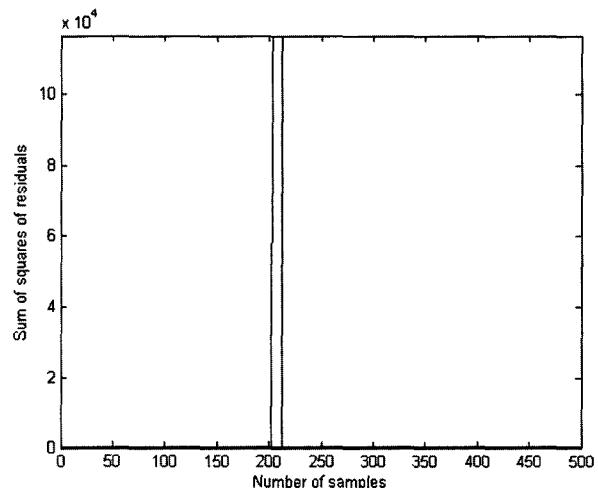
(d) 시스템파라미터(b_1) (실선: 실제값, 일점쇄선: 추정값)



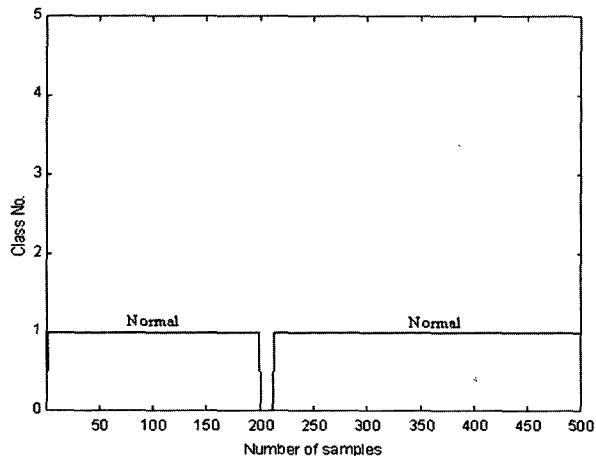
(a) 센서 바이어스 존재시 유입량(제어기 사용)



(e) 추정 센서 바이어스(\hat{f}_s)

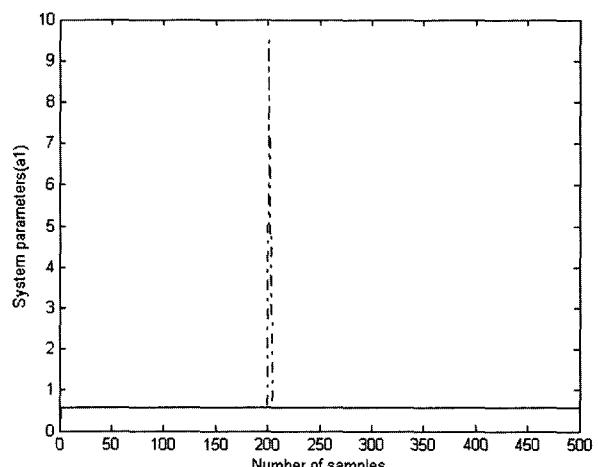


(b) J_L 변화와 고장감지(점선: δ_f , 일점쇄선: δ^*)

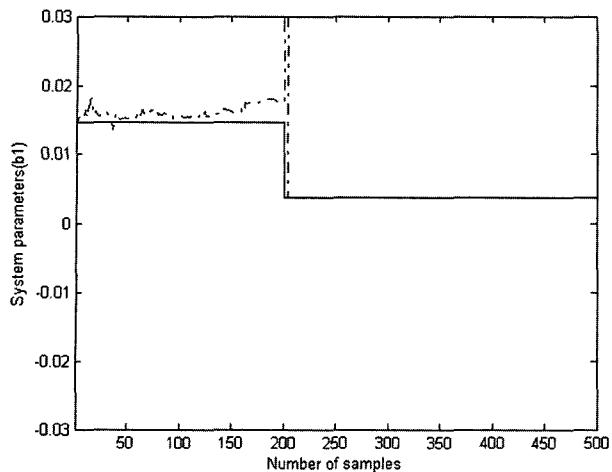


(f) ART2 신경회로망에 의한 고장분류결과

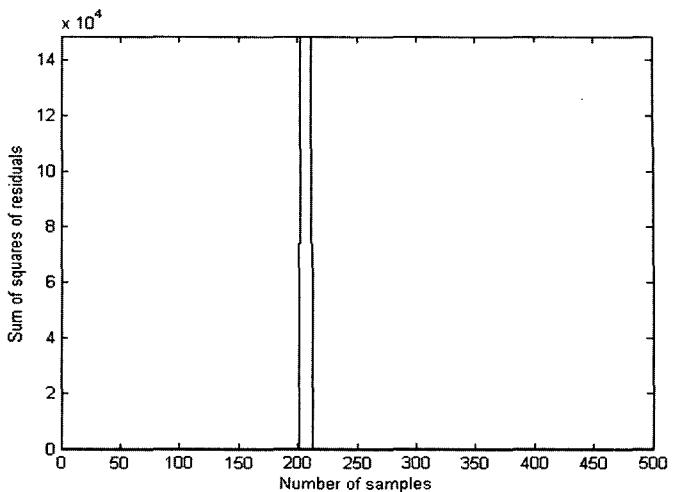
그림 7. 고장 #1에 대한 고장감지와 분류결과



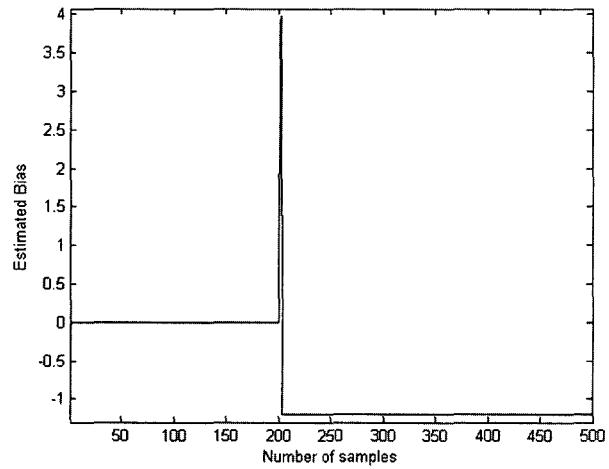
(c) 시스템파라미터(a_1) (실선: 실제값, 일점쇄선: 추정값)



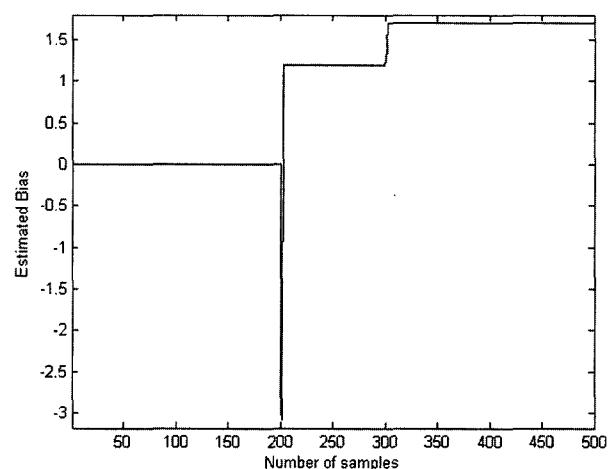
(d) 시스템파라미터(b_1) (실선: 실제값, 일점쇄선: 추정값)



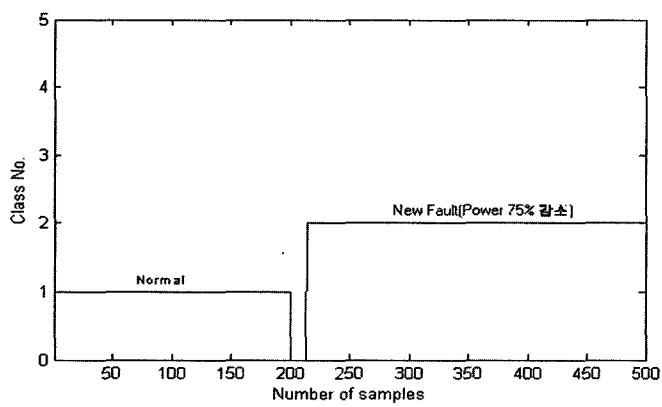
(a) J_L 변화와 고장감지(점선: δ_f , 일점쇄선: δ^*)



(e) 추정 센서 바이어스(\tilde{f}_s)

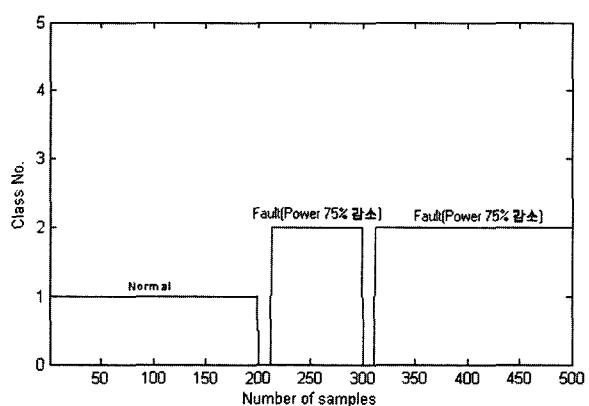


(b) 추정 센서 바이어스(\tilde{f}_s)



(f) ART2 신경회로망에 의한 고장분류결과

그림 8. 고장 #2에 대한 고장감지와 분류결과



(c) ART2 신경회로망에 의한 고장분류결과

그림 9. 고장 #3에 대한 고장감지와 분류결과

5. 결 론

본 논문에서는 원전 증기발생기의 고장진단방법으로서 시스템에 새로운 고장이 발생하거나 센서에 고장이 존재하는 경우 이를 감지하고 분류할 수 있는 ART2 신경회로망을 이용한 고장진단 알고리듬을 제안하였다. 제안한 알고리듬은 고장감지부, 시스템 파라미터 추정부와 고장분류부로 이루어져 있다. 고장의 분류를 위해서 여러 경계인수를 갖는 ART2 신경회로망을 이용한 고장분류기를 사용하였으며, ART2 신경회로망은 자율학습 신경회로망이므로 예상하지 못한 고장이 발생할 경우에도 새로운 고장정보의 자동 구축과 분류가 가능했다. 파라미터 추정부에서는 추정 파라미터벡터와 측정 벡터를 확장시켜 변화된 시스템 파라미터와 센서에 존재하는 바이어스를 함께 추정하므로써, 센서의 고장을 진단할 수 있었다. 또한 원전 증기발생기를 입출력표현식으로 모델링하였으며, 컴퓨터 시뮬레이션을 통해서 본 논문에서 제시한 고장진단 알고리듬이 원전 증기발생기에서 발생되는 고장을 정확하게 진단함을 알 수 있었다.

참 고 문 헌

- [1] J. J. Gertler, "Survey of model-based failure detection and isolation in complex plants," *IEEE Contr. Syst. Mag.*, vol. 8, pp. 3-11, 1988.
- [2] P. Smyth, "Hidden markov models for fault detection in dynamic systems," *Pattern Recognition*, vol. 27, no. 1, pp. 149-164, 1994.
- [3] R. Isermann, "Model based fault detection and diagnosis methods," *Proc. ACC*, pp. 1605-1609, 1995.
- [4] R. Patton, P. Frank and R. Clark, *Fault Diagnosis in Dynamic Systems Theory and Application*, Prentice Hall, 1989.
- [5] M. M. Polycarpou and A. T. Vemuri, "Learning methodology for failure detection and accommodation," *IEEE Contr. Syst. Mag.*, pp. 16-24, 1995.
- [6] X. Q. Liu, H. Y. Zhang, J. Liu and J. Yang, "Fault detection and diagnosis of permanent-magnet DC motor based on parameter estimation and neural network", *IEEE Trans. Ind. Electron.*, vol. 47, no. 5, pp. 1021-1030, 2000.
- [7] A. Srinivasan and C. Batur, "Hopfield /ART-1 neural network-based fault detection and isolation," *IEEE Trans. Neural Networks*, vol. 5, no. 6, pp. 890-899, 1994.
- [8] 이인수, 신필재, 전기준, "ART2 신경회로망을 이용한 선형시스템의 다중고장진단", *제어·자동화·시스템공학 논문지*, vol. 3, no. 3, pp. 244-251, 1997.
- [9] 이인수, 전기준, "선형시스템의 모델기반 고장감지와 분류", *대한전자공학회논문집*, vol. 35-S, no. 1, pp. 68-79, 1998.
- [10] X.G. Ma, and Z.H. Chen, "Heat recovery from the starting vessel of a once-through boiler system," *Applied Thermal Engineering*, vol. 18, 179-186, 1998.
- [11] L. Ljung and T. Söderström, *Theory and*

Practice of Recursive Identification, MIT Press, 1983.

- [12] J. D. Cryer, *Time Series Analysis*, Duxbury Press, 1986.

저 자 소 개



이인수(In Soo Lee)

1963년 : 4월 16일생
1986년 : 경북대학교 전자·공학(공학사).
1989년 : 동대학원 졸업(공학석사).
1997년 : 동대학원 졸업(공학박사).
1997년 ~ 현재 : 상주대학교 전자전기공학부
부교수.

관심분야 : 시스템의 고장진단 및 고장하용제어, 지능제어 및 응용, 지능형센서시스템 등이다.



유철종(Chul Jong Yoo)

1996년 2월 : 상주대학교 전자공학과 졸업
(공학사)
2005년 8월 : 상주대학교 산업대학원 전자
전기공학과 졸업 (공학석사)
1991년 6월 ~ 현재 : 경상북도 김천교도소
직업훈련교사

관심분야 : 신경회로망, 고장진단 등이다.



김경연(Kyung Youn Kim)

1990.3 ~ 현재 : 제주대학교 공과대학 전자
공학과 교수
1994. 8 ~ 1995. 9 : Department of Electrical
Engineering, University of Maryland
at Baltimore County (UMBC, U.S.A.) :
(Postdoctoral Fellow.)

2001.12 ~ 2002. 2 : Department of Applied Physics,
University of Kuopio (Finland) :
(Visiting Professor)
2004. 2 ~ 2005. 2 : Department of Biomedical Engineering,
Rensselaer Polytechnic Institute (RPI,
U.S.A) (Visiting Professor)