

## 파라미터추정과 통계적방법에 의한 선형시스템의 고장진단

이 인 수

상주대학교 전자전기공학과

(Tel : (0582)530-5324; Fax : (0582)530-5320; E-mail : islee@samback.sangju.ac.kr)

### Fault Diagnosis of Linear Systems Based on Parameter Estimation and Statistical Method

In Soo Lee

Department of Electronic and Electrical Engineering, Sangju National University

(Tel : (0582)530-5324; Fax : (0582)530-5320; E-mail : islee@samback.sangju.ac.kr)

#### Abstract

In this paper we propose an FDI(fault detection and isolation) algorithm to detect and isolate single faults in linear systems. When a change in the system occurs, the errors between the system output and the estimated output cross a threshold, and once a fault in the system is detected, the FCFM statistically isolates the fault by using the error between each neural network based fault model output and the system output.

#### I. 서론

현대 산업공정시스템은 점차적으로 규모가 방대해지고 복잡해질 뿐만 아니라, 많은 공정이 자동화됨에 따라 시스템의 신뢰성 및 안전성 유지에 대한 관심이 고조되고 있다. 이는 시스템의 규모가 커짐에 따라 고장의 요인과 발생빈도가 증가할 뿐만 아니라 고장이 발생하면 생산성의 저하를 초래하며 심지어는 사람의 생명까지도 위협할 정도로 파급효과가 크기 때문이다.

기존의 모델에 근거한 고장감지 및 분류(FDI)방법은 시스템의 수학적 모델에 의해 제공되는 해석적인 기법을 기초로 하는 것으로서 상태추정 접근법과 파라미터추정 접근법으로 나눌 수 있다. Wagner 등[1]은 고장에 대한 가설을 설정하고, 각 가설별로 시스템의 상태를 추정한 뒤 추정출력과 시스템 출력과의 이노베이션으로부터 각 가설에 대한 조건부확률을 구하여 고장을 분류하는 다중 가설 고장분류이론을 제안하였다. 그러나 발생 가능한 모든 고장에 대한 모델을 미리 구축하는 것은 거의 불가능하며, 고장모델이 부정확할 경우에는 잘못 분류할 수 있다.

이에 반해서 파라미터추정에 의한 방법은 상태추정 접근법과 비교할 때 적용이 간단하며, 플랜트 및 제어기의 고장분류 문제에 적용이 가능하다는 장점이 있다[2]. 파라미터추정에 의한 고장진단 방법으로는 먼저, 추정된 파라미터를 이용하여 모델 파라미터와 물리적 파라미터와의 관계로부터 물리적 파라미터의 변화를 계산하여 고장의 종류를 알아내는 간접적인 방법[3]을 들 수 있다. 그러나, 일반적으로 모델 파라미터와 물리적 파라미터 사이의 비 선형성으로 인해 명확한 관계정립이 어렵다[4]. 다음으로 추정된 파라미터를 직접 고장분류에 이용하는 패턴인식에 의한 방법[5]은 추정 모델과 정상적인 공정모델과의 오차를 발생시킨 뒤 이로부터 고장의 발생 유무를 결정하며,

미리 구축한 고장모델과 추정된 모델을 비교하여 고장상태를 분류하므로 고장진단의 성능은 고장모델들의 정확도에 의존하나, 사전에 발생 가능한 모든 고장을 예측하여 고장모델로 구축한다는 것은 매우 어렵다.

본 논문에서는 새로운 고장의 분류문제와 고장분류시간의 단축문제를 동시에 해결할 수 있는 시스템의 고장감지와 분류 알고리듬을 제안한다. 고장분류부에서는 고장모델을 이용한 고장분류기(FCFM : fault classifier by fault models)를 이용하므로써 이미 신경회로망 고장모델로 구축된 고장이 발생할 경우에는 고장분류 시간을 단축시킬 수 있으며, 고장분류시 로그공간비를 구하지 않고 오차량만을 이용하므로 계산량을 줄일 수 있다. 그리고, 고장감지부에서는 문턱값 비교방법을 이용하여, 파라미터 추정부에서는 추정 파라미터벡터와 측정벡터를 확장시켜 고장으로 인해 변화된 시스템 파라미터와 센서에 존재하는 바이어스를 함께 추정한다. 제안한 고장감지와 분류 알고리듬을 DC 전동기를 이용한 위치제어 시스템의 고장진단문제에 적용하여 시뮬레이션 하였다.

#### II. 제안한 고장감지 및 분류 알고리듬

제안한 고장진단 알고리듬은 그림 1과 같이 시스템의 파라미터를 추정하고 고장상태를 감지하기 위한 고장감지부분, 고장의 종류를 분류하기 위한 고장분류부분으로 이루어져 있다.

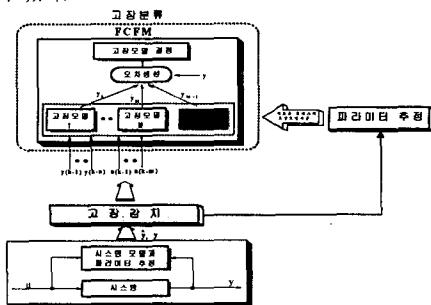


그림 1. 고장감지와 분류 알고리듬의 구조도

##### 1. 시스템 파라미터의 추정과 고장감지

본 논문에서는 고장진단을 위한 대상 시스템은 아래와 같은 ARMA 모델식으로 표현된다고 가정한다.

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

여기서  $u(k)$ ,  $y(k)$ 는 각각 시스템의 입력과 출력,  $\theta$ 와  $\phi(k)$ 는 각각 시스템 파라미터와 측정벡터이며  $\varepsilon(k)$ 는 백색 잡음이라고 가정한다. 시스템의 고장과 바이어스를 동시에 고려하면 식 (1)을 다음과 같이 수정할 수 있다.

$$y(k) = (\theta^T + \Delta\theta^T) \phi(k) + f_s + \varepsilon(k) \quad (2)$$

여기서  $\Delta\theta$ 는 시스템의 고장에 의한 파라미터의 변화이며  $f_s$ 는 센서에 존재하는 바이어스로서 오프셋 형태의 덧셈형으로 가정한다. 바이어스를 고려한 최소화 해야 할 성능지수, 출력오차와 추정출력을 각각 아래와 같이 정의한다.

$$J(k) = \sum_{i=1}^k e^2(i) \quad (3)$$

$$e(i) = y(k) - \hat{y}(k) \quad (4)$$

$$\hat{y}(k) = \theta_{aug.}^T \phi_{aug.}(k) \quad (5)$$

여기서  $\theta_{aug.}$ 는 시스템 파라미터와 바이어스를 추정하기 위해 확장시킨 파라미터 벡터이며  $\phi_{aug.}(k)$ 는 확장시킨 측정벡터로서

$$\theta_{aug.} = [\hat{a}_1 \cdots \hat{a}_n, \hat{b}_1 \cdots \hat{b}_m, \hat{f}_s]^T \quad (6)$$

$\phi_{aug.}(k) = [y(k-1) \cdots y(k-n), u(k-1) \cdots u(k-m), 1]^T$  (7) 와 같으며 (3)을 최소화하는 추정시스템 파라미터와 바이어스를 구하기 위해 순환최소자승 알고리듬[6]을 이용한다.

본 논문에서는 실제 시스템 출력과 추정 출력 사이의 오차를 계산하며, 원도우 내에서의 오차가 다음과 같은 조건을 만족하면 고장이 발생된 것으로 인식한다.

$$J_L(k) = \sum_{i=k-L+1}^k e^2(i) > \delta_f \quad (8)$$

여기서  $e(i)$ 는 시스템 출력과 추정 출력과의 오차이고,  $\delta_f$ 는 고장감지를 위한 문턱값,  $L$ 은 원도우 크기이다. 시스템이 오랜 시간 정상적으로 운행된 후 고장이 발생한다고 가정하면, 고장 발생전의 추정 파라미터는 시스템 파라미터에 수렴하게 되고, 추정 파라미터가 시스템 파라미터에 근접하면 시스템 출력과 추정 출력사이의 오차는 시스템 잡음과 거의 같은 성질을 가진다[7]. 따라서, 시스템 출력과 추정 출력사이의 오차  $e$ 는 정규분포  $N(0, \sigma^2)$ 를 따른다. 그러므로 원도우 내에서의  $L$  개의 정규화된 자승오차  $\frac{e^2(i)}{\sigma^2}$ 의 합은 아래와 같이 자유도(degree of freedom)가  $L$ 인  $\chi_L^2$  (chi-square) 분포를 따르게 된다.

$$\overline{J}_L(k) = \sum_{i=k-L+1}^k \frac{e^2(i)}{\sigma^2} \sim \chi_L^2 \quad (9)$$

고장감지를 위한 문턱값  $\delta_f$ 는 잡음만에 의한 허위고장 신호 발생률과 고장신호를 발생시키지 못하는 확률을 동시에 줄이는 방향으로 설정해야 하나, 대부분의 시스템에서 고장에 의한 시스템 파라미터의 변화는 를 것이므로, 이로 인한 시스템 출력과 추정 출력과의 오차는 시스템이 정상일 때 잡음만에 의한 오차에 비해서 클 것이다. 그러므로 본 논문에서는 고장감지를 위한 문턱값  $\delta_f$ 를 허위고장신호 발생확률을 최대한 줄이는 방향으로 설정한다. 즉, 시스템이 정상일 때 허위고장신호 발생률의 허용한 계를  $\alpha$ 라고 하면

$$\Pr \left( \sum_{i=k-L+1}^k \frac{e^2(i)}{\sigma^2} > \delta_f \right) = \alpha \quad (10)$$

이므로  $\chi^2$  분포표로부터 상수  $\delta_f$ 를 구한 뒤 이로부터 고

장감지를 위한 문턱값  $\delta_f = \sigma^2 \delta^\circ$ 를 구한다. 그러나, 고장으로 인한 시스템의 파라미터 변화가 작은 시스템의 경우에는  $\delta_f$ 가 너무 커서 실제 고장에 의한 변화를 감지하지 못하는 경우가 발생할 수도 있으므로 경험적 요소를 감지하여 문턱값을 적절하게 설정할 필요가 있다.

시스템의 상태가 (8)을 만족하면 고장이 발생한 경우로서, 시스템에서 발생한 고장 종류를 알아내기 위해 다음 절에서 설명할 FCFM에 의해 고장을 분류하며 이와 동시에 고장에 관한 정보를 얻기 위해 공분산행렬을 초기화한 뒤 변화된 시스템 파라미터를 추정한다. 만일 FCFM에 의한 고장분류 결과 만족하는 고장클래스가 존재하지 않으면 시스템파라미터를 계속 추정하다가 추정된 파라미터가 아래 식을 만족하여 변화된 시스템 파라미터에 수렴하면 FCFM의 신경회로망 고장모델에 고장클래스를 추가한다.

$$J_L(k) = \sum_{i=k-L+1}^k e^2(i) < \delta^\circ \quad (11)$$

여기서  $\delta^\circ$ 는 변화된 시스템 파라미터에 대한 추정 파라미터의 수렴정도를 문턱값으로서 파라미터의 수렴정도를 고려하여 결정한다. 그리고, 센서에 존재하는 바이어스의 크기는 추정된 바이어스  $\hat{f}_s$ 로부터 직접 알 수 있다.

## 2. FCFM에 의한 고장분류

FCFM은 신경회로망 고장모델부분, 시스템 출력과 각 가설에 대한 고장모델 출력과의 오차를 발생시키고 통계적 분석(statistical analysis)을 하는 부분 및 최종 결정부분으로 이루어져 있으며, 이미 M개의 고장모델이 구축되어 있다고 가정하고 분류과정을 기술한다.  $k$  번째까지의 순차적인 시스템 출력  $Y^k$ 와 이에 대한 가설  $H_i$ ,  $H_j$ 의 로그공산비는 다음과 같이 정의된다.

$$Y^k = \{y(i) : i=1, \dots, k\} \quad (12)$$

$$\Lambda_{ji}(k) = \ln \frac{p[Y^k | H_j]}{p[Y^k | H_i]} \quad (13)$$

여기서  $p[Y^k | H_i]$ ,  $p[Y^k | H_j]$ 는 각각 가설  $H_i$ ,  $H_j$ 에 대한 공산함수(likelihood function)이다. 그리고  $H_i$ 는 현재의 시스템 상태가  $j$  번째 고장모델과 일치한다는 가설로서 고장모델은 그림 2와 같이 신경회로망으로 구성한다.

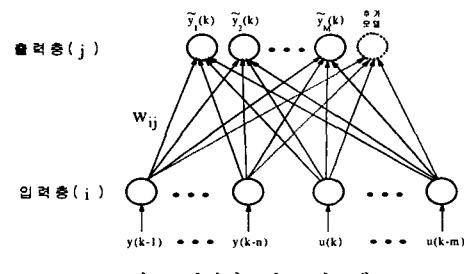


그림 2. 신경회로망 고장모델

신경회로망 고장모델은 그림 2에 도시한 바와 같이 입력층과 출력층으로 구성이 되며, 입력층과 출력층 노드들은 가중치들로 연결되어 있다.  $j$  번째 출력노드에서의 출력은 다음과 같다.

$$\tilde{y}_j(k) = \phi(k-1)^T \cdot W_j \quad (13)$$

$$W_j = [\tilde{a}_1^j \ \tilde{a}_2^j \ \cdots \ \tilde{a}_n^j, \ \tilde{b}_1^j \ \tilde{b}_2^j \ \cdots \ \tilde{b}_m^j]^T \quad (14)$$

여기서  $\tilde{y}_j(k)$  신경회로망의  $j$  번째 출력노드에서의 출력으로서  $j$  번째 가설에 대한 고장모델의 출력을 의미하며,

$W_j$ 는  $j$ 번째 출력노드와 입력노드들 사이의 가중치벡터로서  $j$ 번째 고장모델의 추정파라미터들로 구성된다. 그리고  $\phi(k-1)$ 는 시스템의 측정벡터로서 신경회로망의 입력이며,  $j=1, \dots, M$ 이고  $M$ 은 구축된 고장모델의 수이다. 식 (13)은 다음과 같은 순환식으로 표현될 수 있으며[8]

$$\Lambda_{ji}(k) = \ln \frac{p[y(k) | Y^{k-1}, H_j]}{p[y(k) | Y^{k-1}, H_i]} + \Lambda_{ji}(k-1) \quad (14)$$

각 가설에 대한 로그 공산비를 구하기 위해서는  $p[y(k) | Y^{k-1}, H_j]$ 를 계산해야 한다. 먼저, 실제 시스템 출력과 각 고장모델과의 어려

$$e_j(k) = y_j(k) - \tilde{y}_j(k) \quad (15)$$

의 확률밀도함수를 아래와 같이 가우시안으로 가정한다.

$$p[e_j(k) | Y^{k-1}, H_j] = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{e_j^2(k)}{2\sigma^2}\right) \quad (16)$$

가정으로부터 가설  $H_j$ 에 대한  $y(k)$ 의 확률밀도함수는 아래와 같다.

$$p[y(k) | Y^{k-1}, H_j] = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(y(k) - \tilde{y}_j(k))^2}{2\sigma^2}\right) \quad (17)$$

시스템에 발생한 고장분류를 위해 공산합수와 공산비를 이용한 다중 순차적 가설 검증법 중에서 Armitage 검증법[9]을 이용할 수 있으며 검증과정은 아래와 같다.

단계 1 : 로그 공산비  $\Lambda_{ji}(k)$ , 단,  $i, j = 1, 2, \dots, M$ ,  $i \neq j$ 을 구한다.

단계 2 :  $\Lambda_{ji}(k) \geq T_{ji}$ ,  $\forall j = 1, 2, \dots, M$ ,  $j \neq i$ 를 만족하는  $H_i$ 를 결정한다. 조건을 만족하지 않으면 단계 1로 가서 검증을 계속한다.

$T_{ji}$ 는 문턱값으로서 아래와 같이 결정된다.

$$T_{ji} = \ln \frac{1 - \sum_{l=j}^{k+n_f} \tilde{e}(l, j)}{\tilde{e}(j, i)} \quad (18)$$

여기서  $\tilde{e}(j, i)$ 는 오차확률로서  $H_i$ 가 시스템상태와 일치하는 가설일 때  $H_i$ 를 잘못 결정할 조건부확률이다.

Armitage 검증법은 각 가설 사이의 로그 공산비를 구해서 기준의 가설 중에서 시스템의 상태와 가장 유사한 가설을 결정하는 상대적인 유사도 검사기법이므로 고장모델로 구축되지 않은 새로운 고장이 발생하면 오분류를 행하게 되며 매 순간 로그공산비를 구해야 하므로 계산량이 매우 많다. 그러므로 본 논문에서는 새로운 고장이 발생시에 일치되는 가설이 없다는 결정을 할 수 있도록 시스템 출력과 각 고장모델 출력사이의 오차제곱을 고려하여 절대적인 유사도를 검사하는 부분을 첨가했으며, 로그공산비를 구하지 않고(19)와 같이 오차량만으로 상대유사도 검사가 가능하게 했다. FCFM에서 고장이 감지된 후 고장을 분류하는 과정은 아래와 같다.

단계 1 : 실제 시스템 출력과 입력으로부터 신경회로망 고장모델의 출력  $\tilde{y}_j(k)$ 를 발생시킨다.

단계 2 : 시스템 출력과 각 고장모델 출력(신경회로망의 출력)사이의 오차제곱합  $\sum_{l=k_f+1}^{k+n_f} (y(l) - \tilde{y}_j(l))^2$ 을 구한다.

만일  $k < k_f + n_f$ 이면 단계 1로 간다. 단,  $i, j = 1, 2, \dots, M$ ,  $i \neq j$ ,  $k = k_f + 1, \dots, k_f + n_f$

단계 3 : 다음과 같은 두 조건

$$\sum_{l=k_f+1}^{k+n_f} (y(l) - \tilde{y}_j(l))^2 \leq \sum_{l=k_f+1}^{k+n_f} (y(l) - \tilde{y}_i(l))^2 - 2\sigma^2 T_{ji}$$

$$, \forall i = 1, \dots, M, i \neq j \quad (19)$$

$$\sum_{l=k_f+1}^{k+n_f} (y(l) - \tilde{y}_i(l))^2 \leq r \quad (20)$$

을 동시에 만족하는 가설  $H_i$ ,  $j = 1, 2, \dots, M$ , 가 존제하면 그 가설이 시스템에서 발생한 고장과 일치된 것으로 결정한다. 그렇지 않으면 현재 시스템에서 발생한 고장과 일치된 가설이 없음을 출력한다.

위 3단계 FCFM 고장분류 과정에서  $k_f$ 는 고장감지시간,  $n_f$ 는 고장이 감지된 뒤 FCFM이 동작하는 윈도우의 크기이며,  $T_{ji}$ 는 문턱값으로서 (18)과 같다. 그리고  $r$ 은 절대유사도 검사를 위한 상수로서 다음과 같이 구한다.

현재 시스템의 상태가  $J$ 번째 고장모델에 해당한다고 가정하면,  $J$ 번째 고장모델의 파라미터는  $J$ 번째 고장이 발생되었을 때의 시스템 추정 파라미터로 구성되므로  $J$ 번째 고장모델의 출력과 시스템 출력사이의 오차  $e$ 는 정규분포  $N(0, \sigma^2)$ 을 따른다. 그러므로 윈도우 내에서의

$n_f$ 개의 정규화된 자승오차  $\frac{e^2(i)}{\sigma^2}$ 의 합은 아래와 같이 자유도가  $n_f$ 인  $\chi^2_{n_f}$  분포를 따른다.

$$\sum_{l=k_f+1}^{k+n_f} \frac{(y(l) - \tilde{y}_J(l))^2}{\sigma^2} \sim \chi^2_{n_f} \quad (21)$$

윈도우 내에서의  $n_f$ 개의 정규화된 자승오차  $\frac{e^2(i)}{\sigma^2}$ 의 합이  $\bar{\delta}$  이하가 될 확률을  $\alpha$ 라고 하면

$$\Pr\left(\sum_{l=k_f+1}^{k+n_f} \frac{(y(l) - \tilde{y}_J(l))^2}{\sigma^2} \leq \bar{\delta}\right) = \alpha \quad (22)$$

이므로  $\chi^2$  분포표를 이용하여 상수  $\bar{\delta}$ 를 구한 뒤, 이로부터  $r = \sigma^2 \bar{\delta}$ 을 구한다.

제안한 FCFM은 Armitage 검증법과 비교할 때 세 가지 차이점이 있다. 첫 번째는 FCFM에서는 새로운 고장이 발생하면 절대적인 유사도 검사조건 (20)에 의해 일치되는 가설이 없다는 결정을 할 수 있다. 두 번째는 Armitage 검증법에서는 매 순간마다 각 가설 사이의 로그공산비가 미리 설정한 문턱값을 만족하는지를 검사하지만 제안한 방법에서는 미리 설정한 동작 윈도우의 마지막에서만 유사도검사를 한다. 세 번째는 Armitage 검증법에서는 로그공산비를 구해야 하지만 제안한 방법에서는 오차량만으로 검증이 가능하므로 계산량을 줄일 수 있다.

### III. 컴퓨터 시뮬레이션 결과 및 검토

위치 제어 시스템의 고장상황에 대해 시뮬레이션을 통하여 제안한 고장감지와 분류 방법의 타당성을 살펴본다. 그럼 3은 시뮬레이션의 예로 선택한 직류 전동기를 이용한 위치제어 시스템의 블록선도이다.

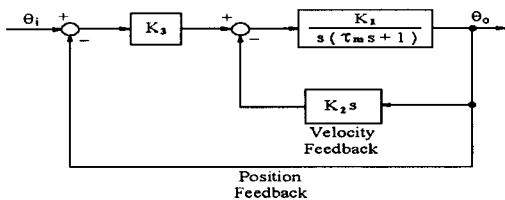


그림 3. 위치제어 시스템의 블록선도

위치제어 시스템의 폐루프 전달함수는 아래와 같다.

$$\frac{\theta_o(s)}{\theta_i(s)} = \frac{K_1 K_3}{\tau_m s^2 + (1 + K_1 K_2)s + K_1 K_3} \quad (23)$$

여기서  $K_1$ ,  $K_2$  및  $K_3$ 들은 구형과 기준입력  $\theta_i$ 에 대해서 시스템의 응답이 오버슈트 없이 정상상태오차가 0이 되도록 적절하게 선택하였으며,  $K_1$  및  $\tau_m$ 은 아래와 같다.

$$K_1 = \frac{1}{n} \left( \frac{K_t}{FR_a + K_b K_t} \right), \quad \tau_m = \left( \frac{J_{iner}, R_a}{FR_a + K_b K_t} \right)$$

여기서  $R_a$ ,  $K_b$  및  $K_t$ 는 모터의 파라미터들로서 각각 전기자 저항, 역 기전력(back emf) 상수 및 토오크 상수이며,  $n$ ,  $J_{iner}$  및  $F$ 는 각각 기어비, 전동기 관성( $J_m$ )과 부하 관성( $J_L$ )의 합 및 점성(viscous) 마찰계수이다. 시뮬레이션에 사용한 전동기의 상수값은 아래와 같다.

$$R_a = 0.88 \Omega, K_b = 1.127 V/(rad/sec), K_t = 1.127 Nm/A \\ F = 0.0082 Nm/(rad/sec), J_m = 0.0196 Kg m^2$$

식 (23)를 표본화 입출력  $\theta_i$ 와  $\theta_o$ 에 대한 2차 이산 시간으로 표현하면 다음과 같다.

$$\theta_o(k+1) = a_1 \theta_o(k) + a_2 \theta_o(k-1) + b_1 \theta_i(k) + b_2 \theta_i(k-1) \quad (24)$$

여기서  $a_1$ ,  $a_2$ ,  $b_1$ ,  $b_2$ 는 추정해야 할 파라미터들이며, 표본화주기는 0.05초, 출력 측정잡음은 분산이  $2.56 * 10^{-4}$ 인 백색잡음으로 하였다.  $\alpha = 0.01$ (1%)이고, (14)로부터 고장감지를 위한 문턱값  $\delta_f$ 를 구하면 0.013이다. 여러 번의 시뮬레이션을 통해서  $\delta^*$  및 L은 각각 0.009 및 30으로 설정하였으며, FCFM에서  $r$ ,  $n_f$  및  $\tilde{e}(j, i)$ 는 각각 0.004, 10, 0.01로 하였고  $T_{ji}$ 는 4.58이다.

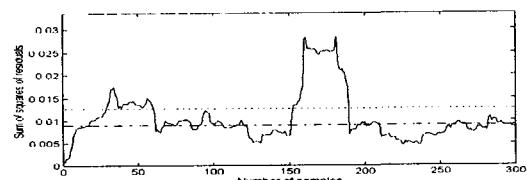
물리적인 계수들의 값을 인위적으로 변화시킴으로써 시스템에서의 고장상황을 다음과 같이 설정하였다.

고장 #1 : 속도궤환이 되지 않았을 때( $K_2 = 0$ )

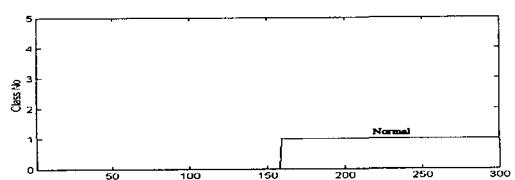
고장 #2 : 전기자 저항이 증가

고장 #3 : 전기자 저항이 감소

그림 4(a)는 이미 고장 #1, 고장 #2( $R_a = 1.76 \Omega$ 으로 증가)가 발생하여 새로운 고장클래스가 생성될 때마다 FCFM에 고장모델을 추가하는 과정을 거침으로써 정상상태를 포함한 세 가지 고장모델이 FCFM에 구축된 뒤 150 번째에 새로운 고장 #3( $R_a = 0.44 \Omega$ 으로 감소)이 발생했을 때의 원도우 내에서 자승오차합의 변화이며, 4(b)는 Armitage 검증법에 의한 분류결과를 도시한 것으로서



(a)  $J_L$  변화와 고장감지(점선:  $\delta_f$ , 일점쇄선:  $\delta^*$ )



(b) Armitage 방법에 의한 분류결과

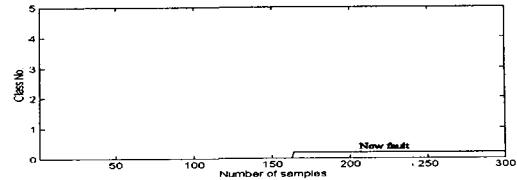


그림 4. 고장 #3에 대한 고장감지와 분류결과

153번째에서 고장이 감지되고 새로운 고장이 발생되었음에도 불구하고 159번째 순간에 클래스 1(정상상태)로 잘못 선언함을 알 수 있다. 4(c)는 제안한 FCFM에 의한 분류결과로서 163번째 순간에 FCFM의 신경회로망 고장모델에는 일치되는 고장모델이 없으므로 새로운 고장으로 인식함을 알 수 있다.

#### IV. 결론

본 논문에서는 새로운 고장의 분류뿐만 아니라 고장분류시간을 단축시킬 수 있는 고장감지와 분류 알고리듬을 제안하였다. 신경회로망 고장모델을 이용한 고장분류기(FCFM)는 고장으로 인해 변화된 시스템 출력과 이미 구축된 각 고장모델의 출력을 비교하여 가장 유사한 고장모델을 결정하므로 변화된 시스템 파라미터를 추정할 필요가 없으며, 고장모델로 구축된 고장이 발생하면 고장분류시간을 많이 단축시킬 수 있었다. 또한 FCFM에서는 예기치 않은 새로운 고장이 발생하면 절대적인 유사도 검사 조건에 의해 일치되는 고장모델이 없다는 결정을 할 수 있었으며, 이로 인해 새로운 고장임에도 불구하고 이미 발생된 고장으로 잘못 분류하는 기존의 방법의 문제점을 보완할 수 있었다. 또한 기존의 방법과 달리 로그공산비를 구하지 않고 오차량만을 이용하므로 계산량을 많이 줄일 수 있었다. 앞으로 남은 과제는 FCFM을 신경회로망으로 구현하는 문제이다.

#### 참고문헌

- [1] J. Wagner and R. Shoureshi, "A failure isolation strategy for thermofluid system diagnostics," *ASME J. Eng. for Industry*, vol. 115, pp. 459-465, 1993.
- [2] R. Isermann, "Model based fault detection and diagnosis methods," *Proc. ACC*, pp. 1605-1609, 1995.
- [3] R. Isermann, "Process fault detection based on modeling and estimation methods-a survey," *Automatica*, vol. 20, no. 4, pp. 387-404, 1984.
- [4] A. Srinivasan and C. Batur, "Hopfield/ART-1 neural network-based fault detection and isolation," *IEEE Trans. Neural Networks*, vol. 5, pp. 890-899, 1994.
- [5] M. M. Polycarpou and A. T. Venuri, "Learning methodology for failure detection and accommodation," *IEEE Contr. Syst. Mag.*, pp. 16-24, 1995.
- [6] L. Ljung and T. Söderström, *Theory and Practice of Recursive Identification*, MIT Press, 1983.
- [7] J. D. Cryer, *Time Series Analysis*, Duxbury Press, 1986.
- [8] A. P. Sage and J. L. Melsa, *Estimation Theory with Applications to Communications and Control*, McGraw-Hill, 1971.
- [9] I. Jouny and F. D. Garber, "M-ary sequential hypothesis tests for automatic target recognition," *IEEE Trans. Aerosp. Electron. Syst.*, vol. 28, pp. 473-483, 1992.