

선형시스템의 모델기반 고장감지와 분류

(Model-Based Fault Detection and Isolation of a Linear System)

李仁秀*, 全琪準**

(In Soo Lee and Gi Joon Jeon)

요 약

본 논문에서는 선형시스템의 고장을 감지하고 분류하기 위한 모델기반 고장진단 알고리즘을 제안한다. 제안한 고장진단 알고리즘은 ART2 신경회로망을 이용한 고장분류기(FCART2)와 고장모델을 이용한 고장분류기(FCFM)로 구성된 혼합고장분류기(HFC)를 근간으로 하며, 파라미터 추정부, 고장감지부 및 고장분류부로 이루어져 있다. 시스템에 변화가 발생하면 시스템의 출력과 추정출력 사이의 오차가 문턱값을 넘는 천이영역이 생기고, 이 영역에서 추정된 파라미터를 고장 분류를 위해 FCART2에 전달한다. 반면에 FCFM은 고장이 감지되면 고장모델을 이용하여 통계적 기법으로 고장을 분류한다. 컴퓨터 시뮬레이션 결과로부터 제안한 진단 알고리즘이 DC 전동기를 이용한 위치제어 시스템에서의 고장감지 및 분류문제에 잘 적용됨을 알 수 있다.

Abstract

In this paper, we propose a model-based FDI(fault detection and isolation) algorithm to detect and isolate fault in a linear system. The proposed algorithm is based on an HFC(hybrid fault classifier) which consists of an FCART2(fault classifier by ART2 neural network) and an FCFM(fault classifier by fault models) which operate in parallel to isolate faults. The proposed algorithm is functionally composed of three main parts-parameter estimation, fault detection, and isolation. When a change in the system occurs, the estimated parameters go through a transition zone in which errors between the system output and the estimated output cross a predetermined threshold, and in this zone the estimated parameters are transferred to the FCART2 for fault isolation. On the other hand, once a fault in the system is detected, the FCFM statistically isolates the fault by using the error between each fault model output and the system output. From the computer simulation results, it is verified that the proposed model-based FDI algorithm can be performed successfully to detect and isolate faults in a position control system of a DC motor.

* 正會員, 尙州産業大學校 電子電氣工學科
(Dept. of Electronic and Elec. Eng., Sangju National Polytechnic University)

** 正會員, 慶北大學校 電子·電氣工學部, 制御計測新技術研究센터

(School of Electronic and Elec. Eng., Kyungpook National University, Eng. Research Center for Advanced Control and Instrumentation of SNU by KOSEF)

接受日字: 1997年8月18日, 수정완료일: 1997年11月19日

I. 서론

현대 산업공정 시스템은 규모가 크고 복잡하므로 시스템의 신뢰성 및 안전성의 유지가 매우 어렵다. 그러므로 생산성 향상과 안전성 확보를 위해서는 발생 가능한 각종 오류를 진단할 수 있는 시스템의 개발은 필수적이다.

일반적으로 고장감지 및 진단은 시스템에서의 오동작 여부를 판단하기 위한 고장감지(detection)단계, 고

장을 분류하기 위한 고장분류(isolation)단계 및 고장의 정도를 결정하는 고장식별(identification)단계로 이루어진다. 특히 고장감지와 분류과정 만을 포함할 경우 이를 시스템의 FDI(fault detection and isolation)문제라고 한다. 기존의 FDI 방법 중에서 모델에 근거한 방법은 시스템의 수학적 모델에 의해 제공되는 해석적인 기법을 기초로 하는 것으로서 상태추정 접근법과 파라미터추정 접근법으로 나눌 수 있다. 먼저 상태추정 접근법으로는 패리티(parity) 검사^[1], 칼만필터나 관측기(observer)를 이용한 이노베이션 검증법^[2], 오류감지필터 접근법^[3] 등이 있으며, 이 방법들은 대개 추정된 상태와 공칭모델의 상태와의 오차로부터 고장의 발생여부를 판단한다. Wagner 등^[4]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.

다음으로 파라미터추정에 의한 고장진단 방법은 상태추정 접근법과 비교할 때 적용이 간단하며, 플랜트 및 제어기의 고장분류 문제에 직접 적용이 가능하다는 장점이 있다^[5, 6]. 먼저, 파라미터추정에 의한 고장진단 방법 중에서 추정된 파라미터를 이용하여 모델 파라미터와 물리적 파라미터와의 관계로부터 물리적 파라미터의 변화를 계산하여 고장의 종류를 알아내는 간접적인 방법^[2, 7]을 들 수 있다. 그러나, 모델 파라미터와 물리적 파라미터 사이의 비선형성으로 인해 두 파라미터 사이의 명확한 관계정립이 어렵다^[8]. 다음으로 추정된 파라미터를 직접 고장분류에 이용하는 방법^[9]은 추정된 모델과 정상적인 공칭모델과의 오차로부터 고장의 발생 유무를 결정하며, 미리 구축한 고장모델과 추정된 모델을 비교하여 고장상태를 분류한다. 그러나 사전에 발생 가능한 모든 고장을 예측하여 고장모델로 구축한다는 것은 매우 어렵기 때문에 예기치 않은 고장상태도 자동 분류할 수 있는 수단이 필요하다.

마지막으로 고장분류를 위해 자율학습 신경회로망인 ART(adaptive resonance theory) 신경회로망을 이용하는 방법^[8, 10]을 들 수 있다. 이 방법들은 고장분류를 위해서 자율학습 신경회로망을 이용하므로 발생

가능한 모든 고장의 종류를 알아야 하는 기존의 연구들과는 달리 예기치 않은 새로운 고장상태도 자동 분류할 수 있다는 장점이 있다. 특히, 이 등^[10]은 패턴을 분류할 때 하나의 경계인수(vigilance parameter)를 사용하는 기존의 ART2 신경회로망^[11, 12]의 단점을 보완한 여러 경계인수를 갖는 ART2 신경회로망을 제안하였으며, 이를 고장분류에 이용함으로써 보다 정확한 고장분류가 이루어지도록 한 바 있다. 그러나, 지금까지 살펴본 시스템 파라미터 추정에 의한 고장진단 기법들은 변화된 시스템 파라미터의 추정치를 이용하여 고장을 분류하므로 파라미터 추정에 걸리는 시간으로 인해 고장의 분류가 지연될 수 있다는 문제점이 있다.

본 논문에서는 시스템에 새로운 고장이 발생하거나 센서에 고장이 존재하는 경우, 이를 감지하고 분류할 수 있는 모델기반 고장감지와 분류 알고리즘을 제안한다. 이 알고리즘은 시스템 파라미터 추정부, 시스템의 고장을 감지하기 위한 고장감지부 및 고장의 종류를 판별하기 위한 고장분류부로 이루어져 있다. 고장분류부에서는, 여러 경계인수를 갖는 ART2 신경회로망을 이용한 고장분류기(FCART2 : fault classifier by ART2 neural network)와 고장모델을 이용한 고장분류기(FCFM : fault classifier by fault models)를 병렬로 결합한 혼합고장분류기(HFC : hybrid fault classifier)를 제시한다. FCART2와 FCFM으로 구성된 HFC는 새로운 고장의 분류뿐만 아니라, 이미 고장모델로 구축된 고장이 발생할 경우에는 고장 분류 시간을 단축시킬 수 있다. 또한 새로운 고장이 발생할 경우에도 FCART2의 정보로부터 FCFM에 쉽게 고장모델을 추가할 수 있다. 그리고, 고장감지부에서는 가장 신속하고 계산량이 적은 문턱값 비교방법^[8]을 이용하며, 통계적 분석을 통해서 문턱값을 적절하게 설정하는 방법을 제시한다. 파라미터 추정부에서는 센서에 존재하는 바이어스의 영향으로 인해 실제 시스템 파라미터와는 다르게 파라미터가 추정되는 것을 방지하기 위해서, 추정 파라미터벡터와 측정벡터를 확장시켜 변화된 시스템 파라미터와 센서에 존재하는 바이어스를 함께 추정한다.

이후 본 논문의 구성은 다음과 같다. II장에서는 제안한 모델기반 고장감지와 분류방법에 대해서 설명하며, III장에서는 DC 전동기를 이용한 위치제어 시스템에서의 고장진단 문제에 제안한 알고리즘을 적용하여

성능을 확인하였다. 마지막으로 IV장에서는 결론과 앞으로의 연구과제를 제시한다.

II. 제안한 모델기반 고장검지와 분류 알고리즘

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




그림 1. 고장검지 및 분류 알고리즘의 구조
Fig. 1. Structure of the fault detection and isolation algorithm.

1. 시스템 파라미터의 추정

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

$$y(k) = \theta^T \phi(k-1) + \varepsilon(k) \quad (1)$$

여기서

$$\theta = [a_1 \dots a_n, b_1 \dots b_m]^T$$

$$\phi(k-1)^T = [y(k-1) \dots y(k-n), u(k-1) \dots u(k-m)]$$

이고, $u(k)$, $y(k)$ 는 각각 시스템의 입력과 출력이고, θ 와 $\phi(k-1)$ 는 각각 시스템 파라미터와 측정벡터이며 $\varepsilon(k)$ 는 백색잡음이라고 가정한다. 시스템의 고장과 센서에 존재하는 바이어스를 동시에 고려하면 (1)을 다음과 같이 수정할 수 있다.

$$y(k) = (\theta^T + \Delta\theta^T) \phi(k-1) + f_s + \varepsilon(k) \quad (2)$$

여기서 $\Delta\theta$ 는 시스템에 발생한 고장에 의한 파라미터의 변화량이며, f_s 는 센서에 존재하는 바이어스로서 오프셋 형태의 덧셈형으로 가정한다.

시스템 파라미터를 추정할 때 바이어스를 고려하지 않으면, 이의 영향으로 인해 실제 시스템의 상태와는 다르게 파라미터를 추정하므로 정확한 시스템의 고장 분류를 위해서는 바이어스를 반드시 고려해야 한다. 이를 위해 최소화 해야할 성능지수(performance index), 출력오차 및 추정출력을 각각 아래와 같이 정의한다.

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

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

$$\hat{y}(k) = \hat{\theta}_{aug.}^T(k-1) \phi_{aug.}(k-1) \quad (5)$$

여기서 $\hat{\theta}_{aug.}$ 는 시스템 파라미터와 바이어스를 추정하기 위해 확장시킨 파라미터 벡터이며 $\phi_{aug.}(k-1)$ 는 확장시킨 측정벡터로서

$$\hat{\theta}_{aug.}(k-1) = [\hat{a}_1 \dots \hat{a}_n, \hat{b}_1 \dots \hat{b}_m, \hat{f}_s]^T \quad (6)$$

$$\phi_{aug.}(k-1) = [y(k-1) \dots y(k-n), u(k-1) \dots u(k-m), 1]^T \quad (7)$$

와 같으며, (3)을 최소화하는 추정 시스템 파라미터 및 바이어스를 구하기 위한 RLS 알고리즘^[13]은 다음과 같다.

$$\hat{\theta}_{aug.}(k) = \hat{\theta}_{aug.}(k-1) + L(k) e^0(k) \quad (8)$$

$$e^0(k) = y(k) - \phi_{aug.}^T(k-1) \hat{\theta}_{aug.}(k-1) \quad (9)$$

$$L(k) = \frac{P(k-1)\phi_{aug.}(k-1)}{1 + \phi_{aug.}(k-1)^T P(k-1)\phi_{aug.}(k-1)} \quad (10)$$

$$P(k) = P(k-1) - \frac{P(k-1)\phi_{aug.}(k-1)\phi_{aug.}(k-1)^T P(k-1)}{1 + \phi_{aug.}(k-1)^T P(k-1)\phi_{aug.}(k-1)} \quad (11)$$

여기서 $P(k)$ 는 파라미터 추정치의 수렴률을 조정하는 공분산행렬이다.

2. 고장검지

시스템이나 센서에 고장이 발생하였을 때 이를 빠르게 감지하는 것은 매우 중요하며, 고장검지 방법은 정확하고 계산량이 적어야 한다. 그러므로 본 논문에서는 시스템의 고장으로 인해 시스템의 성능이 나빠지는 징후를 감지하기 위해서 문턱값(threshold)비교 방법을 이용한다. 즉, 실제 시스템의 출력과 RLS 알고리즘에 의해 추정된 출력 사이의 오차를 계산하며, 원

도우내에서의 오차가 아래와 같은 조건을 만족하여 설정한 문턱값을 넘으면 고장이 발생된 것으로 인식한다.

$$J_L(k) = \sum_{i=k-L+1}^k e^2(i) > \delta_f \quad (12)$$

여기서 $e(i)$ 는 시스템 출력과 추정 출력과의 오차이고 δ_f 는 고장감지를 위한 문턱값이며 L 은 윈도우 크기이다. 시스템이 오랜 시간 정상적으로 운행된 후 고장이 발생한다고 가정하면, 추정파라미터는 시스템 파라미터에 수렴하여 시스템 출력과 추정 출력사이의 오차는 시스템 잡음과 거의 같은 성질을 가진다^[14]. 따라서, 시스템 출력과 추정 출력사이의 오차 e 는 정규분포 $N(0, \sigma^2)$ 을 따르며 σ^2 는 알 수 있다고 가정한다. 그러므로 윈도우 내에서의 L 개의 정규화된 자승오차 $\frac{e^2(i)}{\sigma^2}$ 의 합은 아래와 같이 자유도(degree of freedom)가 L 인 χ_L^2 (chi-square)분포를 따르게 된다.

$$\bar{J}_L(k) = \sum_{i=k-L+1}^k \frac{e^2(i)}{\sigma^2} \sim \chi_L^2 \quad (13)$$

대부분의 시스템에서 고장에 의한 시스템 파라미터의 변화는 클 것이므로, 이로 인한 시스템 출력과 추정 출력과의 오차는 시스템이 정상일 때 잡음만에 의한 오차에 비해서 클 것이다. 그러므로 본 논문에서는 고장감지를 위한 문턱값 δ_f 를 시스템이 정상적으로 동작함에도 불구하고 고장 발생신호를 내는 허위고장 신호 발생확률을 최대한 줄이는 방향으로 설정한다. 즉, 시스템이 정상일 때 허위고장신호(false alarm) 발생확률의 허용한계를 α 라고 하면

$$\Pr \left(\sum_{i=k-L+1}^k \frac{e^2(i)}{\sigma^2} > \delta^\circ \right) = \alpha \quad (14)$$

이므로 χ^2 분포표로부터 상수 δ° 를 구한 뒤 이로부터 고장감지를 위한 문턱값 $\delta_f = \sigma^2 \delta^\circ$ 를 구한다. 그러나, 고장으로 인한 시스템 파라미터 변화가 작은 시스템의 경우에는 δ_f 가 너무 커서 실제 고장에 의한 변화를 감지하지 못하는 경우가 발생할 수도 있으므로, 통계적 방법에 의해서 구한 δ_f 를 기준으로 경험적 요소를 가미하여 문턱값을 적절하게 선정할 필요가 있다.

시스템의 상태가 (12)를 만족하면 고장이 발생한 경우로서, 고장에 관한 정보를 얻기 위해 공분산행렬을 초기화한 뒤 변화된 시스템 파라미터를 추정한다.

한편, 추정된 파라미터가 아래 식을 만족하여 변화된 시스템 파라미터에 수렴하면, 시스템에 발생한 고장의 종류를 알기 위해 추정 파라미터를 다음절에서 설명할 FCART2에 전달한다.

$$J_L(k) = \sum_{i=k-L+1}^k e^2(i) < \delta^* \quad (15)$$

여기서 δ^* 는 변화된 시스템 파라미터에 대한 추정 파라미터의 수렴정도를 나타내는 문턱값으로서, 높게 설정하면 파라미터 추정시간은 단축시킬 수 있으나, 변화된 파라미터에 대한 추정 파라미터의 수렴정도가 낮아지므로 현재의 시스템의 상태와는 다른 고장 클래스로 잘못 분류할 가능성이 커진다. 이에 반해서, 낮게 설정할수록 변화된 시스템 파라미터를 잘 추정한다고 볼 수 있으나 추정시간이 길어지므로 분류기에 추정 파라미터의 전달이 늦어지고 이로 인해서 고장 분류시간이 길어진다. 그러므로 δ^* 는 파라미터의 수렴성을 고려하여 결정하며, 고장감지를 위한 문턱값에 비해서는 낮게 설정하는 것이 바람직하다. 또한 윈도우 크기 L 이 크면 추정치의 신뢰도는 증가하나, 과거의 데이터를 많이 이용하므로써 고장에 빠르게 반응하기가 힘들뿐만 아니라 분류가 늦어진다. 반면에 윈도우 크기가 너무 작으면 추정치의 분산이 커지고 추정 파라미터의 신뢰도가 낮아지므로 적절히 선정한다.

고장이 발생하여 시스템 출력과 추정 출력과의 오차가 설정된 문턱값을 넘는 순간부터 (15)를 만족할 때까지의 구간이 천이 영역(transition zone)이 되며, 시스템이 천이영역을 벗어나면 시스템에 발생한 고장 종류를 알아내기 위해서 바이어스 부분을 제외한 추정 파라미터를 FCART2에 전달하며, 센서에 존재하는 바이어스의 크기는 추정된 바이어스 \hat{f}_s 로부터 알 수 있다.

3. 고장분류

1) ART2 신경회로망을 이용한 고장분류기

이 절에서는 예기치 않은 새로운 고장이 발생할 경우에도 이를 분류하기 위해, 여러 경계인수를 갖는 ART2 신경회로망^[10]으로 구성된 FCART2를 제시한다. 여러 경계인수를 갖는 ART2 신경회로망은 그림 2와 같이 저장된 패턴과 유사한 입력에 대하여 반응을 하고 안정된 내부표현을 유지하기 위한 계층 1과 저장된 패턴과 유사성이 없는 패턴이 입력될 경우 새로운 클래스를 생성시키게 하는 계층 2로 구성된다.

계층 1은 입력층과 출력층을 가지는 두 층(two layer) 신경회로망으로 구성되며, 입력층과 출력층 노드들은 학습 패턴들이 기억되는 가중치로 연결되어 있다. 이러한 ART2 신경회로망의 특징은 예견되지 않은 새로운 고장정보의 구축과 분류에 있어서 효과적으로 이용될 수 있다. 최초의 입력 패턴이 ART2 신경회로망에 전달되면 첫 번째 클래스로 분류하여 입력패턴을 첫 번째 출력노드와 입력노드들과의 가중치로 저장한다.




그림 2. ART2 신경회로망의 구조도
Fig. 2. Architecture of the ART2 neural network.

여러 경계인수를 갖는 ART2 신경회로망의 구조는 그림 2에 도시한바와 같이 기존의 ART2 신경회로망과 같으나, 기존의 ART2 신경회로망에서 패턴을 분류할 때 하나의 경계인수를 사용함으로써 고장에 대한 각 시스템 파라미터의 민감도 차이를 고려하기 어려운 문제점을 보완하기 위해 새로운 거리측정 및 경계인수 조건을 사용한다. 즉, 새로운 패턴이 신경회로망에 입력되면, 입력패턴과 각 출력노드와의 거리를 아래와 같이 계산한다.

$$d_j = \| W_j - X \|_E$$

$$\cong \max_i \left| \frac{1}{\epsilon_i} (w_{ij} - x_i) \right|,$$

$$i=1, 2, \dots, N, \quad j=1, 2, \dots, M \quad (16)$$

여기서 W_j 와 w_{ij} 는 각각 j 번째 출력노드에 대한 N 차원의 가중치벡터 및 i 번째 입력노드와 j 번째 출력노드 사이의 가중치이며, X 와 x_i 는 각각 N 차원의 입력벡터 및 i 번째 입력이고 N 은 입력노드 수이다. $\| \cdot \|_E$ 는 가중치가 부여된 무한대 노름이며 $E = \text{diag} \left(\frac{1}{\epsilon_1} \quad \frac{1}{\epsilon_2} \quad \dots \quad \frac{1}{\epsilon_N} \right)$ 로서 $N \times N$ 차원의 대

각 가중치행렬이고, ϵ_i 는 i 번째 입력노드의 입력패턴에 대한 경계인수이며 $|\cdot|$ 는 절대값을 의미한다.

출력노드중에서 (16)에 의해 계산된 거리가 최소인 노드만이 활성화되며, 입력패턴과 활성화된 출력노드에 대한 템플릿패턴과의 유사성은 계층 2에서의 경계인수조건 검사를 통해서 판별되는데 여러경계인수를 갖는 ART2 신경회로망에서는 아래와 같은 경계인수 조건을 사용한다.

$$\text{경계인수조건} : \| W_j - X \|_E < 1 \quad (17)$$

여기서 W_j 는 활성화된 j 번째 출력노드에 관한 N 차원의 템플릿패턴벡터이며, J 는 활성화된 출력노드이다.

식 (16)과 (17)에서 ϵ_i 는 입력패턴과 활성화된 출력노드의 템플릿패턴간의 일치 정도를 판별하기 위한 경계인수들로서, 두 패턴을 같은 클래스로 학습할 것인지 새로운 클래스로 분류할 것인지를 결정하는 값이다. 입력패턴인 추정 파라미터중에서 고장으로 인해 많이 변하는 파라미터에 대해서는 ϵ_i 를 크게 설정하고 적게 변하는 경우에는 작게 설정하므로써 고장유형에 따른 각 파라미터의 민감도 차이를 충분히 고려한 분류가 가능하다. 만일 입력패턴이 경계인수 검사를 통과하면 아래와 같은 가중치 조정식을 이용하여 같은 클래스로 학습한다.

$$W_j^{\text{new}} = \frac{X + W_j^{\text{old}} [\text{class}_j^{\text{old}}]}{[\text{class}_j^{\text{old}}] + 1} \quad (18)$$

여기서 W_j^{old} 와 W_j^{new} 는 각각 j 번째 출력 노드에서의 조정 전후의 가중치이며, $[\text{class}_j]$ 는 클래스 i 에 속한 패턴들의 개수이다. 그러나 경계인수 검사를 통과하지 못하면 입력패턴을 새로운 클래스로 저장한다.

2) 고장모델을 이용한 고장분류기

고장에 의해 변화된 시스템 파라미터의 추정치를 이용하여 고장을 분류하는 고장진단기법들은 파라미터 추정에 걸리는 시간으로 인해 고장의 분류가 지연될 수 있음을 문제점으로 지적한 바 있다. 이에 대한 해결책으로 고장모델을 미리 구축한 뒤 시스템의 출력과 가장 유사한 출력을 발생시키는 고장모델을 선택하는 방법을 고려하면, 분류를 위해서 시스템 파라미터를 추정할 필요가 없으므로 고장감지후 고장분류까지의 시간을 단축시킬 수 있다. 그러므로 본 절에서는 고장 분류시간의 단축을 위해서 고장모델을 이용한 고장분

류기(FCFM)를 제안한다.

FCFM은 FCART2에 저장된 각 고장클래스의 정보로부터 구축된 고장모델부분, 시스템 출력과 각 고장모델 출력과의 오차를 발생시키고 통계적 분석(statistical analysis)을 하는 부분과 최종 결정을 내리는 부분으로 이루어져 있다.

k 번째까지의 순차적인 시스템 출력 Y^* 와 이에 대한 가설 H_i, H_j 의 로그 공산비 Λ_{ji} 를 다음과 같이 정의한다.

$$Y^* = \{ y(i) : i=1, \dots, k \} \quad (19)$$

$$\Lambda_{ji}(k) = \ln \frac{p[Y^*|H_j]}{p[Y^*|H_i]} \quad (20)$$

여기서 $p[Y^*|H_i], p[Y^*|H_j]$ 는 각각 가설 H_i, H_j 에 대한 Y^* 의 공산함수(likelihood function)이다. 그리고 H_j 는 현재의 시스템 상태가 j 번째 고장모델에 해당한다는 가설로서 j 번째 고장모델은 아래와 같이 ARMA 모델로 구성한다.

$$\hat{y}_j(k) = \partial_j^T \phi(k-1) \quad (21)$$

$$\partial_j^T = [\hat{a}'_1 \ \hat{a}'_2 \ \dots \ \hat{a}'_n, \ \hat{b}'_1 \ \hat{b}'_2 \ \dots \ \hat{b}'_m] \quad (22)$$

여기서 $\hat{y}_j(k)$ 과 $y(k)$ 는 각각 j 번째 고장모델의 출력과 시스템 출력이고 ∂_j^T 는 j 번째 고장모델의 파라미터벡터로서 FCART2의 j 번째 고장클래스에 저장된 추정 파라미터이며, $\phi(k-1)$ 는 시스템의 추정벡터이다. 그리고 $j=1, \dots, M$ 이며, M 은 구축된 고장모델의 수이다. 식 (20)은 다음과 같은 순환식으로 표현될 수 있으며^[15]

$$\Lambda_{ji}(k) = \ln \frac{p[y(k)|Y^{k-1}, H_j]}{p[y(k)|Y^{k-1}, H_i]} + \Lambda_{ji}(k-1) \quad (23)$$

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

$$e_j(k) = y(k) - \hat{y}_j(k) \quad (24)$$

의 확률밀도함수를 아래와 같은 가우스분포 함수로 가정한다.

$$p[e_j(k)|Y^{k-1}, H_j] = \frac{1}{\sqrt{2\pi\sigma}} \exp\left(-\frac{e_j^2(k)}{2\sigma^2}\right) \quad (25)$$

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

$$p[y(k)|Y^{k-1}, H_j] = \frac{1}{\sqrt{2\pi\sigma}} \exp - \frac{(y(k) - \hat{y}_j(k))^2}{2\sigma^2} \quad (26)$$

고장분류를 위해 공산함수와 공산비를 이용한 다중 순차적 가설 검증법^[16] 중에서 Armitage 검증법을 이용할 수 있다. 그러나 Armitage 검증법은 각 가설에 대한 실제 시스템 출력의 공산함수를 계산하고, 이로부터 각 가설 사이의 로그 공산비를 구해서 기존의 가설 중에서 시스템의 상태와 가장 유사한 가설을 결정하는 상대적인 유사도 검사기법이므로 고장모델로 구축되지 않은 새로운 고장이 발생하면, 이미 구축된 고장모델중에서 가장 유사한 고장모델을 선택하므로써 잘못 분류할 수가 있다.

그러므로 본 논문에서는 고장모델로 구축되지 않은 새로운 고장이 발생하면 일치되는 가설이 없다는 결정을 할 수 있도록 시스템 출력과 각 고장모델 출력 사이의 오차를 고려하여 절대적인 유사도를 검사하는 부분을 첨가했으며, 고장감지 후 FCFM에서의 고장분류 과정은 아래와 같다.

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

단계 2 : 각 가설에 대한 로그 공산비 $\Lambda_{ji}(k)$ 와 시스템 출력과 각 고장모델 출력사이의 오차제곱합

$\sum_{l=k_f+1}^k (y(l) - \hat{y}_j(l))^2$ 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

$$\Lambda_{ji}(k_f + n_f) \geq T_{ji}, \quad \forall i = 1, \dots, M, i \neq j \quad (27)$$

$$\sum_{l=k_f+1}^{k_f+n_f} (y(l) - \hat{y}_j(l))^2 \leq r \quad (28)$$

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

위 3단계 FCFM의 고장분류 과정에서 k_f 는 고장

감지 시간, n_f 는 고장이 감지된 뒤 FCFM이 동작하는 윈도우의 크기로서 FCFM의 역할이 분류시간을 단축시키는 것이므로 2절에서 언급한 이동 윈도우 크기 L 보다 작게 설정하며, 고장이 감지된 뒤 $k_f + n_f$ 순간에 유사도 검사를 하여 분류가 이루어진다. 그리고 T_{ji} 는 문턱값으로서 아래와 같이 결정된다.

$$T_{ji} = \ln \frac{1 - \sum_{l \neq j} \tilde{e}(l, i)}{\tilde{e}(j, i)} \quad (29)$$

여기서 $\tilde{e}(j, i)$ 는 오차확률로서 H_j 가 시스템상태와 일치하는 가설일 때 H_j 를 잘못 결정할 조건부확률이며, $1 - \sum_{l \neq j} \tilde{e}(l, i)$ 는 H_j 가 시스템상태와 일치하는 가설일 때 H_j 를 결정할 조건부확률이다. $j=i$ 인 경우를 제외한 모든 i, j 에 대해 동일한 오차확률로 정하면, 모든 T_{ji} 는 같은 값이 된다.

식 (27)은 각 가설 사이의 로그 공산비를 구해서 동작중인 시스템의 상태와 가장 유사한 가설을 결정하는 상대적인 유사도 검사조건이며, (28)은 가장 유사하다고 결정된 가설에 대한 절대 유사도 검사조건이다. 여기서 주목할 점은 새로운 고장이 발생할 때, 유사한 고장모델이 없음에도 불구하고 (27)의 상대적인 관계를 만족하는 고장모델이 존재할 수 있으므로 이러한 경우를 방지하기 위해서는 반드시 (28)이 필요하며, 절대유사도 검사를 위한 상수 r 은 아래와 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.

$$\sum_{l=k_f+1}^{k_f+n_f} \frac{(y(l) - \hat{y}_J(l))^2}{\sigma^2} \sim \chi^2_{n_f} \quad (30)$$

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

$$\Pr \left(\sum_{l=k_f+1}^{k_f+n_f} \frac{(y(l) - \hat{y}_J(l))^2}{\sigma^2} \leq \bar{\delta} \right) = \alpha \quad (31)$$

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

3) 혼합고장분류기

예기치 않은 새로운 고장이 발생할 때 이를 분류하기 위해 FCART2, 고장분류시간의 단축을 위해서 FCFM을 제안했다. 그런데 새로운 고장의 분류와 분류시간의 단축은 분류기에 관련된 하나의 문제이므로, 두 문제를 하나의 분류기로 해결하기 위해 그림 3과 같이 FCART2와 FCFM을 함께 사용한 혼합고장분류기(HFC)를 구성한다.

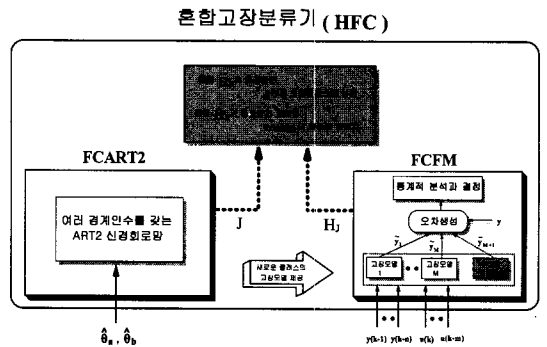


그림 3. 제안한 혼합고장분류기
Fig. 3. Proposed hybrid fault classifier(HFC).

HFC에서 FCART2는 변화된 시스템 파라미터를 추정된 뒤 이미 저장된 각 고장클래스의 추정 파라미터와 유사도를 검사하여 고장을 분류하지만, FCFM은 고장이 감지되는 순간부터 미리 설정한 윈도우 끝에서 각 고장클래스의 추정 파라미터로부터 구축한 고장모델의 출력과 시스템 출력사이의 유사도를 검사하여 분류를 한다. HFC에서의 최종 분류는 아래의 결정논리에 의해 이루어진다.

Logic 1 : 만일 FCFM에서 분류 알고리즘을 만족하는 고장모델 J 가 존재하면, J 번째 고장으로 분류한다.

Logic 2 : 만일 FCFM의 분류 결과가 존재하지 않으면, FCART2의 분류결과를 따른다.

HFC의 장점으로서는 두 가지를 들 수 있다. 첫 번째는, 이미 고장모델로 구축된 고장이 발생할 경우에는 FCART2만을 이용하는 경우에 비해서 매우 빠르게 고장의 분류가 가능하다. 두 번째는, 예기치 않은 새로운 고장이 발생할 경우에도 이의 분류가 가능하며,

FCART2의 정보로부터 쉽게 FCFM에 고장모델을 추가할 수 있다.

Ⅲ. 컴퓨터 시뮬레이션 결과 및 검토

위치 제어 시스템의 고장상황에 대해 시뮬레이션을 통하여 제안한 고장검지와 분류 방법의 타당성을 살펴본다. 그림 4는 시뮬레이션의 예로 선택한 직류 전동기를 이용한 위치 제어 시스템의 블록선도이다.

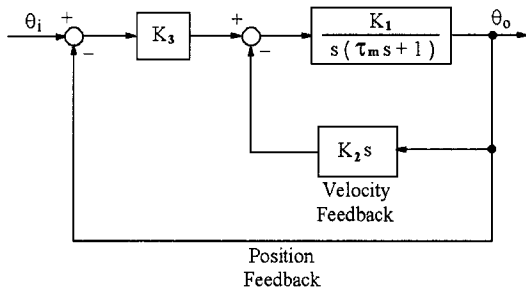


그림 4. 위치 제어 시스템의 블록선도
Fig. 4. Block diagram of a position control system.

위치제어 시스템의 페루프 전달함수는 아래와 같다.

$$\frac{\theta_o(s)}{\theta_i(s)} = \frac{K_1 K_3}{\tau_m s^2 + (1 + K_1 K_2)s + K_1 K_3} \quad (32)$$

여기서 K_1 , K_2 및 K_3 들은 구형파 기준입력 θ_i 에 대해서 시스템의 응답이 오버슈트없이 정상상태오차가 0이 되도록 적절하게 선택하였으며, K_1 및 τ_m 은 아래와 같다.

$$K_1 = \frac{1}{n} \left(\frac{K_t}{FR_a + K_b K_t} \right) \quad (33)$$

$$\tau_m = \left(\frac{J_{iner} R_a}{FR_a + K_b K_t} \right) \quad (34)$$

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.

$$\begin{aligned} R_a &= 0.88 \Omega, & K_b &= 1.127 \text{ V/(rad/sec)} \\ K_t &= 1.127 \text{ Nm/A}, & F &= 0.0082 \text{ Nm/(rad/sec)} \\ J_m &= 0.0196 \text{ Kg}m^2 \end{aligned}$$

식 (32)를 표본화 입출력 θ_i 와 θ_o 에 대한 2차 이산시간으로 표현하면 다음과 같다.

$$\theta_o(k+1) = a_1 \theta_o(k) + a_2 \theta_o(k-1) + b_1 \theta_i(k) + b_2 \theta_i(k-1) \quad (35)$$

여기서 a_1, a_2, b_1, b_2 는 모터상수와 표본화 주기의 함수로서 추정해야할 파라미터들이며, 시뮬레이션에 사용된 표본화 주기는 0.05초, 출력 측정잡음은 분산이 2.56×10^{-4} 인 백색잡음으로 하였다. 그리고 시스템이 정상적으로 동작함에도 불구하고 잡음만에 의한 허위 고장신호 발생확률을 최대로 줄이기 위해 $\alpha = 0.01$ (1%)로 했으며, (14)로부터 고장검지를 위한 문턱값 δ_f 를 구하면 0.013이다. 여러 번의 시뮬레이션을 통해서 δ^* 및 L 은 각각 0.009 및 30으로 하였다. 제안한 고장검지 및 분류 알고리즘의 고장분류 성능을 알아보기 위해서 FCART2만을 고장 분류에 이용하는 방법 1과 혼합고장분류기(HFC)를 이용하는 방법 2를 비교하였으며, FCART2의 입력노드는 4개로 입력패턴은 추정파라미터이며, 경계인수 파라미터 $\epsilon_1, \epsilon_2, \epsilon_3$ 및 ϵ_4 는 각각 0.2, 0.2, 0.02 및 0.02로 설정하였다. 그리고 FCFM에서 r, n_f 및 $\tilde{\epsilon}(j, i)$ 는 각각 0.004, 10, 0.01로 하였으며, T_{ji} 는 4.57이다.

물리적인 계수들의 값을 인위적으로 변화시킴으로써 시스템에서의 예기치 못한 고장상황을 다음과 같이 설정하였다.

- 고장 #1 : 속도계환이 되지 않았을 때 ($K_2 = 0$)
- 고장 #2 : 전기자 저항이 증가
- 고장 #3 : 전기자 저항이 감소
- 고장 #4 : 고장 #2와 센서에 0.1의 바이어스가 존재

아래의 결과는 이미 고장 #1, 고장 #2($R_a = 1.76 \Omega$ 으로 증가) 및 고장 #3($R_a = 0.44 \Omega$ 으로 감소)가 발생하여 정상상태를 포함한 네 가지 고장클래스가 FCART2에 자동 생성되었으며, FCART2에 새로운 고장클래스가 생성될 때마다 FCFM에 고장모델을 추가하는 과정을 거침으로써 네 가지 고장모델이 구축된 뒤 분류성능을 알아본 것이다. 그림 5(a)는 150번째에 고장 #1이 발생했을 때 윈도우내에서 자승오차합의 변화이며, 5(b)는 FCART2만을 이용한 방법 1에 의한 분류결과를 도시한 것으로서 153번째에서 고장이 감지되고 천이영역에 있는 동안에는 ART2 신경회로망에는 입력이 없으므로 분류가 이루어지지 않고 천이영역

을 벗어나는 201번째 순간에 추정된 파라미터가 신경 회로망에 전달되어 클래스 2(고장 #1)로 선언함을 알 수 있다. 5(c)는 HFC를 이용하는 방법 2에 의한 분류결과로서 163번째 순간에 클래스 2로 분류함을 알 수 있다. 고장 #2의 한 경우로서 전기자 저항이 1.86Ω 으로 증가했을 때의 오차의 변화 및 분류 결과가 그림 6(a), (b) 및 (c)에 각각 나타나 있다. 그림 6(b)에 나타난 바와 같이 152번째 순간에 고장이 감지되고 203번째 순간에 방법 1에 의해 클래스 3(고

장 #2)로 결정되었으나, HFC를 사용할 경우에는 6(c)와 같이 162번째에 클래스 3으로 분류가 이루어짐을 알 수 있다. 전기자 저항이 0.51Ω 으로 감소하는 고장 #3이 발생했을 때의 고장감지 및 분류결과는 그림 7과 같으며, 그림 7(a)와 (b)로 부터 153번째 순간에 고장이 감지되고 197번째 순간에 클래스 4(고장 #3)로 분류됨을 알 수 있으며, 그림 7(c)로부터 HFC를 사용할 경우에는 163번째에 분류가 이루어짐을 알 수 있다.

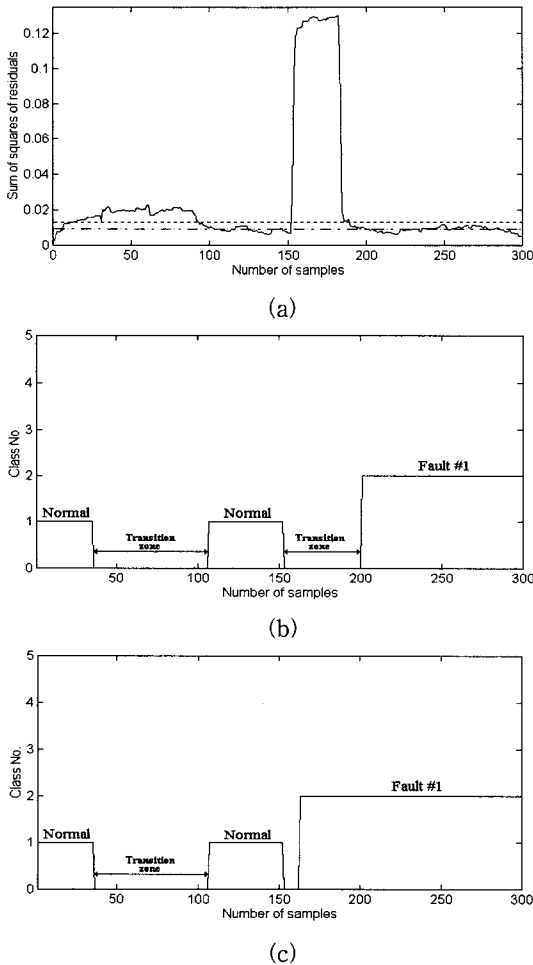


그림 5. 고장 #1에 대한 고장감지와 분류결과
 (a) J_L 변화와 고장감지(점선: δ_r , 일점쇄선: δ^*)
 (b) 방법 1에 의한 분류결과
 (c) 방법 2에 의한 분류결과

Fig. 5. Results of detection and isolation for fault #1. (a) Change of J_L and fault detection (dashed line : δ_r , dashdot line: δ^*) (b) Classification result by method 1 (c) Classification result by method 2

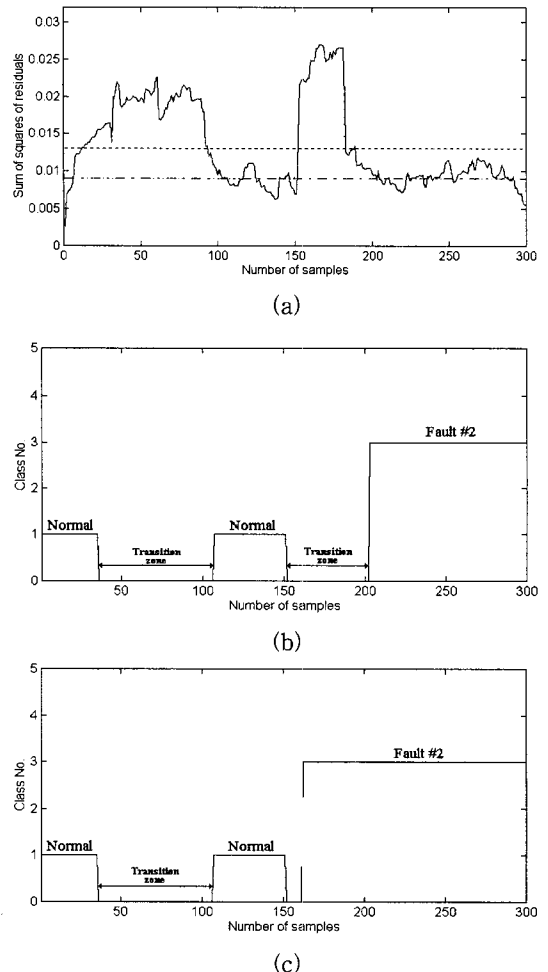




그림 6. 고장 #2에 대한 고장감지와 분류결과
 (a) J_L 변화와 고장감지(점선: δ_r , 일점쇄선: δ^*) (b) 방법 1에 의한 분류결과 (c) 방법 2에 의한 분류결과

Fig. 6. Results of detection and isolation for fault #2. (a) Change of J_L and fault detection (dashed line : δ_r , dashdot line: δ^*) (b) Classification result by method 1 (c) Classification result by method 2


그림 5, 6 및 그림 7에서 고장발생 전의 고장감지는 잡음에 기인한 것으로서 분류기의 출력으로부터 시스템은 정상상태임을 알 수 있다. 이상의 결과를 종합하면, 고장모델로 구축된 고장이 발생될 경우는 HFC를 이용하는 방법 2가 FCART2만을 이용하는 방법 1에 비해서 고장감지 후 매우 빠르게 분류가 이루어짐을 알 수 있다.



(a)



(b)




(c)

그림 7. 고장 #3에 대한 고장감지와 분류결과


(a) J_L 변화와 고장감지(점선: δ_f , 일점쇄선: δ^*) (b) 방법 1에 의한 분류결과 (c) 방법 2에 의한 분류결과

Fig. 7. Results of detection and isolation for fault #3.


(a) Change of J_L and fault detection (dashed line : δ_f , dashdot line: δ^*) (b) Classification result by method 1 (c) Classification result by method 2




(a)



(b)



(c)



(d)

그림 8. 고장 #4에 대한 고장감지와 분류결과

(a) J_L 변화와 고장감지(점선: δ_f , 일점쇄선: δ^*) (b) 센서고장 추정결과 (c) 방법 1에 의한 분류결과 (d) 방법 2에 의한 분류결과

Fig. 8. Results of detection and isolation for fault #4.

(a) Change of J_L and fault detection (dashed line : δ_f , dashdot line: δ^*) (b) Result of the estimated sensor fault (c) Classification result by method 1 (d) Classification result by method 2

다음으로, 전기자 저항이 2.0Ω 으로 증가하는 시스템 고장 #2 뿐만 아니라 센서에 바이어스가 존재하는 고장 #4가 발생했을 때의 결과를 살펴보면, 그림 8(a), (b), (c) 및 (d)에 나타난 바와 같이 150번째에 고장이 감지되고, 199번째 순간에 고장클래스 3으로 분류됨을 알 수 있으며, 바이어스 추정량으로부터 센서에는 0.1의 바이어스가 존재함을 알 수 있다. 즉, 시스템에는 고장 #2와 센서 고장이 동시에 존재함을 의미한다. 센서에 바이어스가 존재하는 경우에는 FCFM에는 일치되는 고장모델이 없으므로 HFC의 출력은 FCART2의 결정을 따름을 알 수 있다.

IV. 결 론

본 논문에서는 시스템에 새로운 고장이 발생하거나 센서에 고장이 존재하는 경우, 이를 감지하고 분류할 수 있는 모델기반 고장진단 알고리즘을 제안하였다. 이 알고리즘은 고장감지부, 시스템 파라미터 추정부와 고장분류부로 이루어져 있으며, 고장감지후 분류시간을 최소화하기 위한 고장분류기의 개발에 역점을 두었다. 이를 위해서 여러 경계인수를 갖는 ART2 신경회로망을 이용한 고장분류기(FCART2)와 고장모델을 이용한 고장분류기(FCFM)를 각각 제안하였으며, 마지막으로 FCART2와 FCFM으로 구성된 혼합고장분류기(HFC)를 제시하였다. HFC를 구성하는 각 부분의 특징으로는 두 가지를 들 수 있다. 첫 번째로 FCFM은 고장으로 인해 변화된 시스템 출력과 각 고장모델의 출력을 비교하여 가장 유사한 고장모델을 결정하므로 변화된 시스템 파라미터를 추정할 필요가 없다. 그러므로 고장모델로 구축된 고장이 발생하면 고장이 감지된 뒤 고장분류가 이루어지기까지의 시간을 많이 단축시킬 수 있었다. 두 번째는 FCART2를 구성하는 여러 경계인수를 갖는 ART2 신경회로망은 자율학습 신경회로망이므로 예상하지 못한 고장이 발생할 경우에도 새로운 고장정보의 자동 구축과 분류가 가능하며, 고장유형에 따른 각 시스템 파라미터의 민감도 차이를 고려한 경계인수검사 조건을 이용함으로써 정확한 고장분류가 가능하다.

그리고, 파라미터 추정부에서는 추정 파라미터벡터와 측정벡터를 확장시켜 변화된 시스템 파라미터와 센서에 존재하는 바이어스 f_s 를 함께 추정하므로써, 센서에 존재하는 바이어스의 영향으로 인해 실제 시스템

파라미터와는 다르게 파라미터가 추정되는 것을 방지할 수 있었으며, 정확한 고장분류가 가능하였다. 컴퓨터 시뮬레이션을 통해서 제안한 고장진단 알고리즘이 시스템에서 발생하는 고장을 빠르고, 정확하게 분류함을 알 수 있다. 앞으로 남은 과제는 FCART2에서 고장분류를 위한 경계인수값을 설정함에 있어서 통계학적 방법을 이용한 체계적인 연구와 FCFM을 신경회로망으로 구현하는 문제이다.

참 고 문 헌

- [1] E. Y. Chow and A. S. Willsky, "Analytical redundancy and the design of robust failure detection systems," *IEEE Trans. Automat. Contr.*, vol. AC-29, no. 7, pp. 603-614, 1984.
- [2] R. Patton, P. Frank and R. Clark, *Fault Diagnosis in Dynamic Systems; Theory and Application*, Prentice Hall, 1989.
- [3] M. A. Massoumnia, "A geometric approach to the synthesis of failure detection filters," *IEEE Trans. Automat. Contr.*, vol. AC-31, no. 9, pp. 839-846, 1986.
- [4] J. Wagner and R. Shoureshi, "A failure isolation strategy for thermofluid system diagnostics," *ASME J. Eng. for industry*, vol. 115, pp. 459-465, 1993.
- [5] P. Smyth, "Hidden markov models for fault detection in dynamic systems," *Pattern Recognition*, vol. 27, no. 1, pp. 149-164, 1994.
- [6] R. Isermann, "Fault diagnosis of machines via parameter estimation and knowledge processing," *Automatica*, vol. 29, no. 4, pp. 815-835, 1993.
- [7] R. Isermann, "Process fault detection based on modeling and estimation methods—a survey," *Automatica*, vol. 20, no. 4, pp. 387-404, 1984.
- [8] 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.
- [9] M. M. Polycarpou and A. T. Vemuri, "Learning methodology for failure detec-

- tion and accommodation," *IEEE Contr. Syst. Mag.*, pp. 16-24, 1995.
- [10] 이인수, 신필재, 전기준, "ART2 신경회로망을 이용한 선형 시스템의 다중고장진단", *제어·자동화·시스템공학회 논문지*, 제 3권, 제 3호, pp. 244-251, 1997년 6월
- [11] S. Y. Kung, *Digital Neural Networks*, Prentice Hall, 1993.
- [12] Y. H. Pao, *Adaptive Pattern Recognition and Neural Networks*, Addison-Wesley, 1989.
- [13] L. Ljung and T. Söderström, *Theory and Practice of Recursive Identification*, MIT Press, 1983.
- [14] J. D. Cryer, *Time Series Analysis*, Duxbury Press, 1986.
- [15] A. P. Sage and J. L. Melsa, *Estimation Theory with Applications to Communications and Control*, McGraw-Hill, 1971.
- [16] 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.

 저 자 소 개



李仁秀(正會員)

1963년 4월 16일생. 1986년 경북대학교 전자공학(공학사). 1989년 동대학원 졸업(공학석사). 1997년 동대학원 졸업(공학박사). 1997년~ 현재 상주산업대학교 전자전기공학과 전임강사. 주요관심분야

는 시스템의 고장진단 및 고장허용제어, 지능제어, 공장자동화등이다

全琪準(正會員) 第 33卷 B編 第 6號 參照