

ART2 신경회로망을 이용한 선형 시스템의 다중고장진단

Multiple Faults Diagnosis of a Linear System Using ART2 Neural Networks

이 인 수, 신 필 재, 전 기 준
(In Soo Lee, Pil Jae Shin and Gi Joon Jeon)

Abstract : In this paper, we propose a fault diagnosis algorithm to detect and isolate multiple faults in a system. The proposed fault diagnosis algorithm is based on a multiple fault classifier which consists of two ART2 NN(adaptive resonance theory2 neural network) modules and the algorithm is composed of three main parts - parameter estimation, fault detection and isolation. When a change in the system occurs, estimated parameters go through a transition zone in which residuals between the system output and the estimated output cross the threshold, and in this zone, estimated parameters are transferred to the multiple faults classifier for fault isolation. From the computer simulation results, it is verified that when the proposed diagnosis algorithm is performed successfully, it detects and isolates faults in the position control system of a DC motor.

Keywords: Parameter estimation, fault detection, fault isolation, ART2 neural network, multiple faults

I. 서론

현대 산업공정 시스템은 규모가 크고 복잡하므로 시스템의 신뢰성 및 안전성의 유지가 매우 어렵다. 그러므로 생산 시스템의 완전한 자동화 및 무인화를 이루기 위해서는 발생 가능한 각종 오류를 진단할 수 있는 시스템의 개발은 필수적이다[1].

일반적으로 진단시스템은 고장상태를 감지하기 위한 고장감지부(fault detection), 고장을 분류하기 위한 고장분류부(fault isolation) 및 오류의 위치 및 원인을 판별하여 적절하게 처리하기 위한 진단부(fault diagnosis)로 구성이 되는데 기존의 FDI(fault detection and isolation) 방법은 크게 모델에 근거한 방법과 모델에 근거하지 않는 방법으로 분류 할 수 있다. 모델에 근거하지 않는 방법은 대상 시스템의 측정치, 경험 또는 물리적 검토를 기초로 하며, 시스템의 출력값이 제한된 범위를 벗어나는지의 유무로써 고장을 감지해내는 한계치 검사(limit checking), 전문가 시스템 기법[2] 및 신경회로망을 이용한 방법 등이 있다. 전문가 시스템을 이용하는 방법은 명확한 규칙선정이 어렵고 대규모 시스템에의 적용이 어렵다는 문제점이 있다. 신경회로망의 패턴분류 능력을 고장진단 문제에 이용한 방법으로 Sorsa 등 [3] 은 공정 시스템의 고장 진단의 목적으로 여러 가지 신경회로망을 적용하여 비교하였다.

이와는 달리 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[4], 칼만필터나 관측기(observer)를 이용한 이노베이션 검증법[5], 오류감지필터 접근법[6] 등이 있으며, 이 방법들은 대개 추정된 상태와 공칭모델의 상태와의 오차를 이용하여 고장의 발생여부를 판단한다. 그러나 상태추정 접근법의 경우는 시스템의 모델링을 위해서는 지식이 많이 필요하므로 복잡한 시

스템의 진단문제에서는 모델링이 어려우며 고장부위와 상태 변수는 일반적으로 일치되지 않기 때문에 플랜트 및 제어기의 고장분류문제에는 적용이 어렵다는 문제점이 있다[7, 8].

다음으로 파라미터추정에 의한 고장진단 방법은 상태추정 접근법과 비교할 때 적용이 간단하며, 플랜트 및 제어기의 고장분류 문제에 직접 적용이 가능하다는 장점이 있다[9]. 먼저, 파라미터추정에 의한 고장진단 방법 중에서 추정된 파라미터를 이용하여 모델 파라미터와 물리적 파라미터와의 관계로부터 물리적 파라미터의 변화를 계산하여 고장의 종류를 알아내는 간접적인 방법[5, 10, 11]은 일반적으로 모델 파라미터와 물리적 파라미터 사이의 비선형성으로 인해 두 파라미터 사이의 명확한 관계정립이 어려우며 시스템이 복잡하여 많은 물리적 계수들이 존재할 경우에는 고장분류를 위한 결정논리가 매우 복잡해질 수 있다는 단점이 있다[12]. 다음으로 추정된 파라미터를 직접 고장분류에 이용하는 패턴인식에 의한 방법[13]은 추정된 모델과 정상적인 공칭모델과의 오차를 발생시킨 뒤 이 오차를 근거로 고장의 발생유무를 결정하며 미리 구축한 고장모델과 추정된 모델과 비교하여 고장상태를 분류한다. 그러나 고장진단의 성능은 고장모델의 정확도에 의존하는데 실제로 정확한 모든 발생 가능한 고장 모델의 구축은 매우 어렵기 때문에 예기치 않은 고장상태도 자동 분류할 수 있는 수단이 필요하다. 특히, 대부분의 고장진단에 관한 연구에서는 한 시점에 하나의 고장이 일어나는 단일고장(single fault)을 가정하고 있으나 외부로부터의 충격이나 온도상승과 같은 환경변화 혹은 단일 고장의 영향 등으로 인해 여러 부분에서 고장이 발생하는 경우가 일어날 수 있으므로 다중고장의 진단은 중요한 문제이다.

Srinivasan등 [12]은 선형 시스템의 FDI를 위해서 시스템 파라미터 추정을 위한 Hopfield 신경회로망과 고장분류를 위해 자율학습 신경회로망인 ART1 신경회로망을 이용하였으나 고장분류기로 이용한 ART1 신경회로망은 이진화된 패턴만을 분류하므로 이를 분류기로 이용할 경우에는 아날로그패턴의 이진화과정이 필요하다. 그러므로 추정파라미터가 입력패턴인 고장분류문제에는 아날로그패턴을 분류할 수

있는 ART2 신경회로망을 이용하는 것이 적합하다. 또한, 패턴을 분류할 때 하나의 경계인수(vigilance parameter)를 사용하는 기존의 ART2 신경회로망[14, 15]을 추정파라미터에 의한 고장분류문제에 적용할 경우에는 각 시스템 파라미터가 고장의 유형에 따라 변하는 정도의 차이가 있음에도 불구하고 이러한 민감도 차이를 고려한 분류가 어렵다는 문제점이 있다.

이 논문에서는 시스템의 단일고장과 여러 부분에서 동시에 고장이 발생하는 다중고장문제를 함께 고려할 수 있는 진단 알고리듬을 제안한다. 제안한 고장진단 알고리듬은 시스템에서의 다중고장 문제를 해결하기 위해 두개의 ART2 신경회로망 모듈을 이용하여 시스템 파라미터 추정부, 시스템의 고장으로 인해 시스템의 성능이 나빠지는 징후를 조기에 감지하기 위한 고장 감지부 및 고장의 종류를 판별하기 위한 고장분류부로 이루어져 있다. 특히 다중고장 분류기의 각 모듈을 구성하는 ART2 신경회로망은 새로운 고장상태를 자동생성해 나가는 능력을 가진 자율학습 신경회로망이며 고장분류시 고장 유형에 따른 각 시스템 파라미터의 민감도 차이를 충분히 고려하기 위해 여러 개의 경계인수를 적용함으로써 정확한 고장분류가 가능하다는 장점이 있다.

이후 이 논문의 구성은 다음과 같다. 2장에서는 제안한 고장진단 알고리듬의 고장감지와 분류방법에 대해서 설명하며 3장에서는 DC 전동기를 이용한 위치제어 시스템에서의 고장진단 문제에 제안한 알고리듬을 적용하여 성능을 확인하였다. 마지막으로 4장에서는 결론과 앞으로의 연구과제를 제시한다.

II. 제안한 고장감지 및 분류 알고리듬

이 논문에서 제안한 고장진단 알고리듬은 그림 1과 같이 시스템의 파라미터를 추정하고 고장상태를 감지하기 위한 고장감지부분, 고장의 종류를 분류하기 위한 고장분류 부분 및 고장의 정확한 위치와 원인을 결정하는 진단부분으로 이루어져 있으며, 특히 감지부와 분류부를 합쳐서 FDI라고 한다.

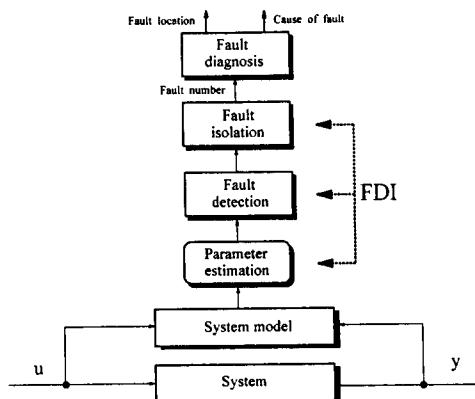


그림 1. 고장진단 알고리듬의 구조.

Fig. 1. Structure of the fault diagnosis algorithm.

1. RLS 알고리듬을 이용한 시스템 파라미터의 추정

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

$$\begin{aligned}
 y(k) &= a_1 y(k-1) + a_2 y(k-2) + \cdots + a_n y(k-n) \\
 &\quad + b_1 u(k-1) + b_2 u(k-2) + \cdots + b_m u(k-m) \\
 &\quad + \varepsilon(k) \\
 &= \theta^T \phi(k) + \varepsilon(k)
 \end{aligned} \tag{1}$$

여기서 $u(k)$, $y(k)$ 는 각각 시스템의 입력과 출력이고, θ 와 $\phi(k)$ 는 각각 시스템 파라미터와 측정벡터이며 $\varepsilon(k)$ 는 백색 가우시안잡음으로서 정규분포 $N(0, \sigma^2)$ 을 따른다고 가정한다. 시스템의 고장과 센서에 존재하는 바이어스를 동시에 고려하면 (1)을 다음과 같이 수정할 수 있다.

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

여기서, $\Delta\theta$ 는 시스템의 고장에 의한 파라미터의 변화이며 $f_s(k)$ 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 고장분류를 위해서는 바이어스를 반드시 고려해야 한다. 이를 위해 최소화 해야 할 성능지수(performance index), 출력오차 및 추정출력을 각각 아래와 같이 정의한다.

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

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

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

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

$$\hat{\theta}_{aug.} = [\hat{a}_1 \hat{a}_2 \cdots \hat{a}_n, \hat{b}_1 \hat{b}_2 \cdots \hat{b}_m, \hat{f}_s]^T \tag{6}$$

$$\begin{aligned}
 \phi_{aug.}(k) &= [y(k-1) y(k-2) \cdots y(k-n), \\
 &\quad u(k-1) u(k-2) \cdots u(k-m), 1]^T
 \end{aligned} \tag{7}$$

와 같으며 (3)을 최소화하는 추정 시스템 파라미터 및 바이어스를 구하기 위한 RLS 알고리듬[16]은 다음과 같다.

$$\hat{\theta}_{aug.}(k+1) = \hat{\theta}_{aug.}(k) + F(k+1)\phi_{aug.}(k+1)e^0(k+1) \tag{8}$$

$$F(k+1) = F(k) - \frac{F(k)\phi_{aug.}(k+1)\phi_{aug.}(k+1)^T F(k)}{1 + \phi_{aug.}(k+1)^T F(k)\phi_{aug.}(k+1)} \tag{9}$$

$$e^0(k+1) = y(k+1) - \phi_{aug.}^T(k+1) \hat{\theta}_{aug.}(k) \tag{10}$$

여기서, $F(k)$ 는 매개변수 추정치의 수렴률을 조정하는 이득행렬이다.

2. 고장감지

이 논문에서는 시스템에서의 고장으로 인해 시스템의 성능이 나빠지는 징후를 감지하기 위해서 문턱값(threshold) 비교 방법을 이용한다. 즉, 실제 시스템의 출력과 RLS 알고리듬에 의해 추정된 출력 사이의 오차를 계산함으로써 윈도우 내에서의 오차가 아래와 같은 조건을 만족하여 설정한 문턱값을 넘으면 고장이 발생된 것으로 인식한다.

$$J_L(k) = \sum_{i=k-L+1}^k e^2(i) > \delta_f \tag{11}$$

여기서, $e(i)$ 는 시스템 출력과 추정 출력과의 오차이고, δ_f 는 고장감지를 위한 문턱값이며 L 은 윈도우 크기이다. 그리고 고장은 일반적으로 시스템이 오랜시간 정상적으로 운행한 후 발생한다고 가정하면 추정파라미터는 시스템 파라미터에 수렴하여 시스템 출력과 추정 출력사이의 오차 e 는 ε 에 근접하여 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 $L-1$ 인 χ^2_{L-1} (chi-square) 분포를 따르며,

$$\bar{J}_L(k) = \sum_{i=k-L+1}^k \frac{e^2(i)}{\sigma^2} \sim \chi^2_{L-1} \quad (12)$$

시스템이 정상일 때 허위고장신호 발생확률의 허용한계를 α 라고 하면

$$\Pr \left(\sum_{i=k-L+1}^k \frac{e^2(i)}{\sigma^2} > \delta^\circ \right) = \alpha \quad (13)$$

이므로 χ^2 분포표를 이용하여 상수 δ° 를 구한 뒤 이로부터 고장감지를 위한 문턱값 $\delta_f = \sigma^2 \delta^\circ$ 를 구할 수 있다. 이와 같이 시스템이 정상적으로 동작함에도 불구하고 고장 발생 신호를 내는 허위고장신호 발생확률을 최대한 줄이는 방향으로 δ_f 를 설정하는 것은 실제 시스템에서의 고장에 의한 시스템 파라미터의 변화는 클것이므로 이로 인한 시스템 출력과 추정 출력과의 오차는 시스템이 정상일 때 잡음만에 의한 오차에 비해서 크다고 볼 수 있기 때문이다. 만일 대상 시스템에서 고장으로 인한 변화가 매우 작을 경우에는 위에서 구한 문턱값 δ_f 가 너무 커서 실제 고장에 의한 변화를 감지하지 못하는 경우가 발생할 수도 있으므로 통계적 방법에 의해서 구한 δ_f 를 기준으로 해서 경험적 요소를 가미하여 문턱값을 적절하게 설정할 필요가 있다.

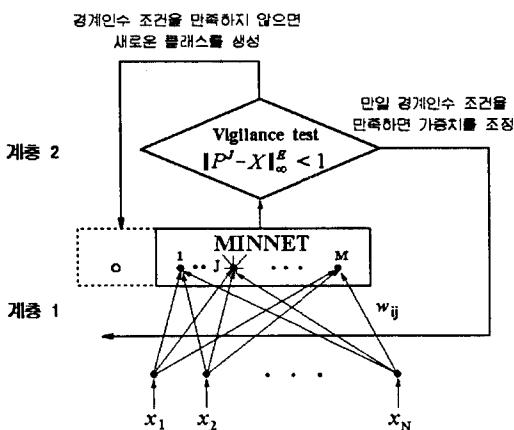


그림 2. 여러 경계인수를 갖는 ART2 신경회로망의 구조도.

Fig. 2. Architecture of the ART2 neural network with uneven vigilance parameters.

시스템의 상태가 (11)을 만족하면 고장이 발생한 경우로서 고장에 관한 정보를 얻기 위해 이득 행렬을 초기화한 뒤 변화된 시스템 파라미터를 추정한다. 한편, 추정된 파라미터가 아래와 같은 식을 만족하여 변화된 시스템 파라미터에 수렴하면 시스템에 발생한 고장의 종류를 알기 위해 추정파라미터를 다중고장 분류기에 전달한다.

$$J_L(k) = \sum_{i=k-L+1}^k e^2(i) < \delta^* \quad (14)$$

여기서, δ^* 는 변화된 시스템 파라미터에 대한 추정 파라미터의 수렴정도를 나타내는 문턱값으로서 낮게 설정할수록 변화된 시스템 파라미터를 잘 추정한다고 볼 수 있으나 이로인해 파라미터 추정시간이 길어지므로 고장분류기에 추정

파라미터의 전달시간이 늦어지며 이로인해 고장 분류시간이 길어지는 반면 높게 설정하면 파라미터의 추정시간을 단축할 수 있으므로 분류시간은 짧아지나 변화된 파라미터에 대한 추정 파라미터의 수렴정도가 낮아지므로 현재의 시스템의 상태와는 다른 고장 클래스로 오분류가 될 가능성이 커진다. 특히 δ^* 는 파라미터의 수렴정도를 결정하는 기준이 되므로 수렴성을 고려하여 결정하며 δ_f 에 비해서는 낮게 설정하는 것이 바람직하다. 또한 원도우 크기 L 은 크면 추정치의 신뢰도는 증가하나 과거의 데이터를 많이 이용하므로 고장에 빠르게 반응하기가 힘들 뿐만 아니라 분류가 늦어지는 문제가 있으나 원도우 크기가 너무 작으면 추정치의 분산이 커지고 추정 파라미터의 신뢰도가 낮아지므로 적절히 설정한다.

고장이 발생하여 시스템 출력과 추정 출력과의 오차가 설정된 문턱값을 넘는 순간부터 (14)를 만족할때까지의 구간이 천이 영역(transition zone)이되며 시스템이 천이영역을 벗어나면 시스템에 발생한 고장 종류를 알아내기 위해서 바이어스 부분을 제외한 추정파라미터를 다중고장 분류기에 전달하며, 센서에 존재하는 바이어스의 크기는 추정된 바이어스 \hat{f}_s 로부터 알 수 있다.

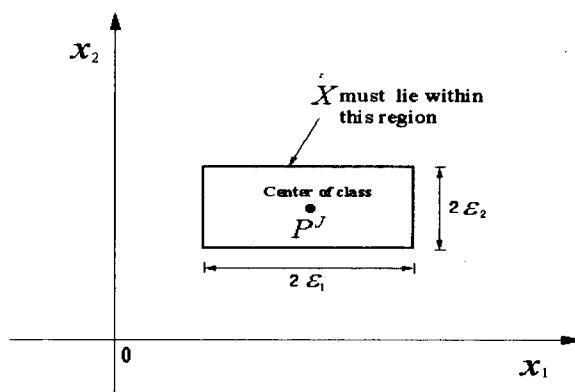


그림 3. $\| P^j - X \|_\infty^E < 1$ 를 만족하는 영역.

Fig. 3. The region that satisfies
 $\| P^j - X \|_\infty^E < 1$.

3. 여러 경계인수를 갖는 ART2 신경회로망의 동작 알고리듬

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 계층 1을 차단시키고 새로운 클래스를 생성시키기 하는 계층 2로 구성된다. 계층 1은 입력층과 출력층을 가지는 이 층(two layer) 신경회로망으로 구성되며 입력층과 출력층 노드들은 학습 패턴들이 기억되는 가중치(weight)로 연결되어 있다. 최초의 입력 패턴이 ART2 신경회로망에 전달되면 출력층에는 생성된 클래스가 없으므로 첫 번째 클래스로 분류하여 입력패턴을 첫 번째 출력노드와 입력노드들과의 가중치로 저장한다. 다음에 다른 패턴이 입력되면 첫 번째 클래스와의 유사성을 검사하여 같은 클래스로 학습하거나 새로운 클래스를 생성시키게 되는데 아래에서는 이미 M개의 클래스가 분류 알고리듬에 의해 생성되어 있다고 가정하고 분류 과정을 기술한다.

새로운 입력 패턴이 신경회로망에 입력되면 이는 가중치를 통해서 출력층의 각 노드에 전달되며, 입력패턴과 각 출력노드와의 거리를 아래와 같이 계산한다.

$$d_j = \|W_j - X\|_{\infty}^E, \quad j = 1, 2, \dots, M \quad (15)$$

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

여기서, W_j 와 w_{ij} 는 각각 j 번째 출력노드에 대한 N 차원의 가중치 벡터 및 i 번째 입력노드와 j 번째 출력노드 사이의 가중치로서 j 번째 클래스를 대표하는 패턴을 저장하고 있으며, X 와 x_i 는 각각 N 차원의 입력벡터 및 i 번째 입력노드의 입력이고 N 은 입력노드 수이다. 그리고 $\|\cdot\|_{\infty}^E$ 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 가중치 행렬이고, ε_i 는 i 번째 입력노드의 입력패턴에 대한 경계인수이며 $|\cdot|$ 는 절대값을 의미한다.

출력노드 중에서 (15)에 의해 계산된 거리가 최소인 노드 만이 활성화되며 입력 패턴과 활성화된 출력노드에 대한 템플리트 패턴과의 유사성은 계층 2에서의 경계인수 조건 검사를 통해서 판별되는데 제안한 ART2 신경회로망에서는 아래와 같은 경계인수 조건을 사용한다.

$$\text{경계인수 조건 : } \|P^j - X\|_{\infty}^E < 1 \quad (16)$$

여기서,

$$p_i^j = y_j \cdot w_{ij} \quad (17)$$

$$y_j = \begin{cases} 1, & \text{for } j = J \\ 0, & \text{otherwise} \end{cases} \quad (18)$$

여기서 P^j 와 p_i^j 는 각각 활성화된 출력노드에 대한 N 차원의 템플리트 패턴 벡터 및 i 번째 입력노드와 J 번째 출력노드 사이의 템플리트 패턴이고 J 는 활성화된 출력노드이며, w_{ij} 는 활성화된 출력노드에 대한 가중치이다. 그리고 (15)과 (16)의 ε_i 는 입력 패턴과 활성화된 출력노드의 템플리트 패턴 간의 일치정도를 판별하기 위한 경계인수들로서 두 패턴을 같은 클래스로 학습할 것인지 새로운 클래스로 분류할 것인지를 결정하는 값이며 입력 패턴인 추정파라미터 중에서 고장으로 인해 많이 변하는 파라미터에 대해서는 ε_i 를 크게 설정하고 적게 변하는 경우에는 작게 설정하므로써 고장 유형에 따른 각 파라미터의 민감도 차이를 충분히 고려한 분류가 가능하다. (15)에서 $N=2$ 이고 x_1 이 x_2 보다 크게 변하는 경우에는 ε_1 을 ε_2 보다 크게 설정하며 이를 2차 평면상에 도시하면 그림 3과 같고 입력 패턴 X 가 (16)을 만족한다는 것은 그림 3에서 사각형 내에 입력 패턴이 포함되는 경우를 의미한다.

만일 입력 패턴이 활성화된 출력노드에 대한 템플리트 패턴과의 경계인수 검사를 통과하면 아래와 같은 가중치 조정식을 이용하여 같은 클래스로 학습한다.

$$w_{ij}^{\text{new}} = \frac{x_i + w_{ij}^{\text{old}} [\text{class}_j^{\text{old}}]}{[\text{class}_j^{\text{old}}] + 1} \quad (19)$$

여기서 w_{ij}^{old} 와 w_{ij}^{new} 는 각각 J 번째 출력노드에서의 조정 전후의 가중치이며, $[\text{class}_j]$ 는 class_j 에 속한 패턴들의 개수이다. 그러나 경계인수 검사를 통과하지 못하면 입력 패턴을 새로운 클래스로 저장한다. ART2 신경회로망의 동작 알고리듬을 요약하면 그림 4의 순서도와 같다.

4. ART2 신경회로망 모듈을 이용한 다중고장 분류기
제안한 다중고장 분류기는 그림 5와 같이 두 개의 ART2

신경회로망 모듈과 최종결정을 위한 조정자(Coordinator)로 구성되는데, 각 모듈은 3절에서 설명한 그림 2의 ART2 신경회로망으로 구성되며 각 모듈 별로 입력된 추정파라미터와 가장 유사한 클래스를 판별하여 조정자에 클래스 번호를 전달한다. 조정자에서는 각 모듈에서 전달된 클래스 번호에 따라 결정논리(decision logic)에 의해 현재의 상태가 어떤 종류의 고장인지를 결정한 뒤 각 모듈에 결정신호를 전달한다.

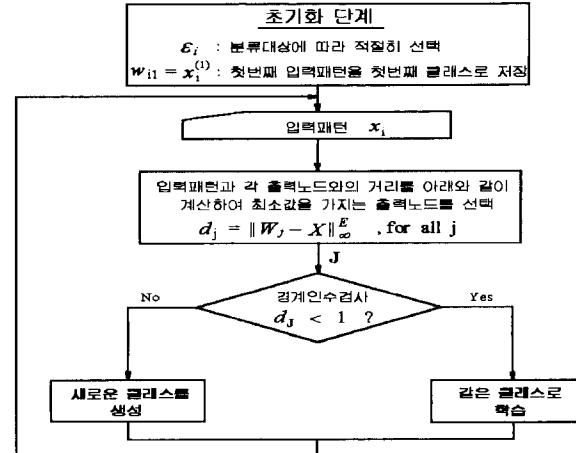


그림 4. 여러 경계인수를 갖는 ART2 신경회로망 학습 알고리듬의 순서도.

Fig. 4. Flowchart of the learning algorithm of the ART2 neural network with uneven vigilance parameters.

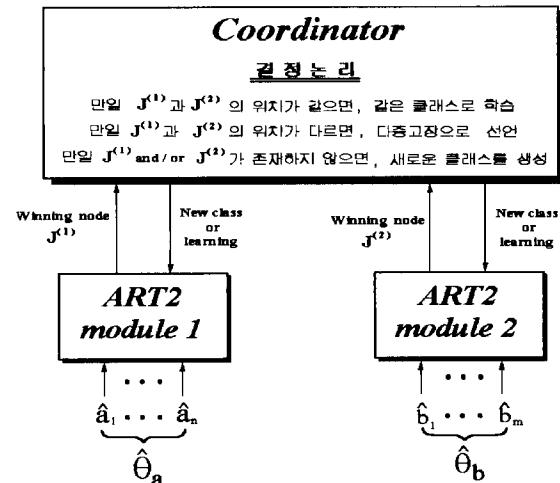


그림 5. ART2 신경회로망 모듈을 이용한 다중고장 분류기.

Fig. 5. Multiple faults classifier based on two ART2 neural network modules.

추정된 파라미터 벡터 $\hat{\theta}_{\text{avg}}$ 는 자기회귀 부분 $\hat{\theta}_a = [\hat{a}_1, \hat{a}_2, \dots, \hat{a}_n]^T$, 이동평균 부분 $\hat{\theta}_b = [\hat{b}_1, \hat{b}_2, \dots, \hat{b}_m]^T$ 과 바이어스 f_s 의 세 부분으로 나눌 수 있는데 $\hat{\theta}_a$ 와 $\hat{\theta}_b$ 는 시스템에 발생한 고장에 대한 정보를 포함하는 파라미터로서 시스템에 발생한 고장분류를 위해서 각각 모듈 1과 모듈 2로 입력된다. 반면 f_s 는 센서의 상태에 관한 정보를 갖고 있는 파라미터이므로 고장분류기에 전달되지 않고 그 값으로부터 센서에 존재하는 바이어스의 크기를 알아낸다. 각 모듈은 독립적으로 경계인수 조건 검사를 통해서

입력된 파라미터와 가장 유사한 클래스를 찾는다. 그러나 각각의 ART2 신경회로망 모듈은 가장 유사한 클래스를 찾더라도 즉시 학습하지 않고 조정자로부터의 최종 결정신호를 기다리며, 조정자는 각 모듈에서 결정한 클래스 번호를 비교하여 최종결정을 한뒤 각 모듈에 전달된 추정파라미터 벡터를 각 모듈에서 결정한 클래스와 같은 클래스로 학습할 것인지, 새로운 클래스로 분류할 것인지 혹은 다중고장으로 선언할 것인지에 관한 세 가지 서로 다른 신호를 각 모듈에 전달하는데 조정자에서의 이러한 결정은 다음과 같은 결정논리에 의해서 이루어진다.

Logic 1 : 만일 $J^{(1)}$ 과 $J^{(2)}$ 가 같은 위치이면, 현재의 입력을 J 번째 클래스로 분류하고 각 모듈에 J 번째 클래스로 학습하라는 신호전달

Logic 2 : 만일 $J^{(1)}$ 과 $J^{(2)}$ 가 다른 위치이면, 현재의 입력을 다중고장으로 선언하고 학습을 하지 않는다

Logic 3 : 만일 $J^{(1)}$ and/or $J^{(2)}$ 가 존재하지 않으면 새로운 클래스를 생성시키라는 신호전달

여기서 $J^{(1)}$ 및 $J^{(2)}$ 는 각각 모듈 1 및 모듈 2에서 경계인수 검사를 통과한 클래스로서 ART2 신경회로망 모듈의 출력노드 번호이다. 다중고장 분류기는 ART2 신경회로망 모듈 1과 모듈 2의 결정단계 및 조정자에 의한 전역(global)결정 단계로 구성되는데 분류 알고리듬은 아래와 같다.

단계 1 : 각 모듈의 경계인수 $\epsilon_i^{(1)}, \epsilon_i^{(2)}$ 설정과 가중치의 초기화 $w_{il} = x_{il}^{(1)}, v_{il} = x_{il}^{(2)}$.

단계 2 : 모듈 1(모듈 2)의 입력총에 각각 새로운 추정파라미터($\hat{\theta}_a, \hat{\theta}_b$)가 입력된다.

단계 3 : 모듈 1(모듈 2)에서는 (15)에 의해 입력패턴과 각 출력노드와의 거리를 계산하여 최소값을 가지는 출력노드를 선정한다.

단계 4 : 각 모듈별로 계층 2에서는 활성화된 출력노드에 대해 (16)의 경계인수조건을 만족하는지를 검사하여 이를 만족하면 클래스 번호 $J^{(1)}$ 및 $J^{(2)}$ 를 조정자에 전달하고, 그렇지 않으면 존재하지 않음을 조정자에 전달한다. 각 모듈은 조정자로부터의 결정 신호가 올 때까지 학습을 하지 않고 기다린다.

단계 5 : 조정자에서는 결정논리를 이용하여 각 모듈에 전달된 입력 패턴을 같은 클래스($J^{(1)}$ 및 $J^{(2)}$)로 학습할 것인지, 새로운 클래스로 분류하여 출력노드를 생성할 것인지 혹은 다중고장으로 선언할 것인지를 결정하여 각 모듈에 결정신호를 전달한다.

단계 6 : 각 모듈은 조정자로부터의 신호에 따라서 다음과 같은 행동을 취한 뒤 단계 2로 간다.

Case 1 : 같은 클래스로 학습하라는 신호가 전달되면 각 모듈의 선택된 출력노드($J^{(1)}, J^{(2)}$)에 대한 가중치를 (19)을 이용하여 수정한다.

Case 2 : 새로운 클래스를 생성하라는 신호가 전달되면 $w_{ij^{(1)}} = x_i^{(1)}, v_{ij^{(2)}} = x_i^{(2)}$ 로 새로운 클래스의 가중치를 설정하고 시스템을 점검하여 고장클래스에 대한 지식을 부여한다.

Case 3 : 다중고장 신호가 전달되면 학습하지 않는다.

III. 컴퓨터 시뮬레이션 결과 및 검토

위치 제어 시스템의 고장상황에 대해 시뮬레이션을 통하여 제안한 고장감지와 분류 방법의 타당성을 살펴본다. 그림 6은 시뮬레이션의 예로 선택한 직류 전동기를 이용한 위치 제어 시스템의 블록선도이다.

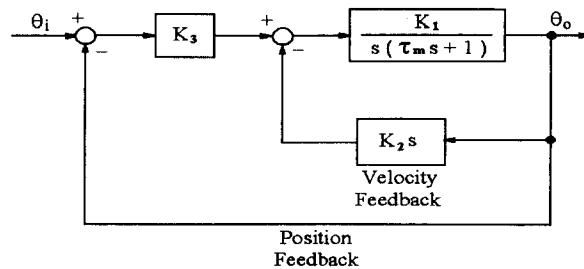


그림 6. 위치 제어 시스템의 블록선도.

Fig. 6. Block diagram of a position control system.

위치제어 시스템의 폐루프 전달함수는 아래와 같다.

$$\frac{\theta_o(s)}{\theta_i(s)} = \frac{K_1 K_3}{\tau_m s^2 + (1 + K_1 K_2)s + K_1 K_3} \quad (20)$$

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

$$K_1 = \frac{1}{n} \left(\frac{K_t}{FR_a + K_b K_t} \right) \quad (21)$$

$$\tau_m = \left(\frac{J_{iner} R_a}{FR_a + K_b K_t} \right) \quad (22)$$

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 부하관성(J_L)의 합 및 점성(viscous) 마찰계수이다. 시뮬레이션에 사용한 전동기의 상수값은 아래와 같다.

$$R_a = 0.88 \Omega, K_b = 1.127 V/(rad/sec)$$

$$K_t = 1.127 Nm/A, F = 0.0082 Nm/(rad/sec)$$

$$J_m = 0.0196 Kgm^2$$

위의 (20)을 표본화 입력 출력 θ_i 와 θ_o 에 대한 이산시간으로 표현하면 다음과 같다.

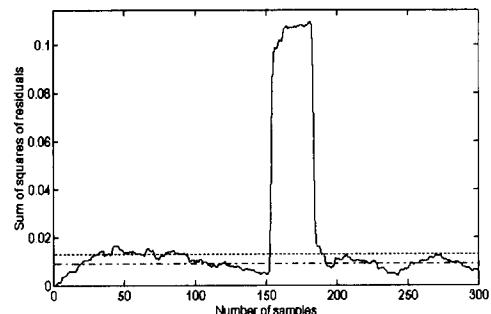
$$\begin{aligned} \theta_o(k+1) &= a_1 \theta_o(k) + a_2 \theta_o(k-1) \\ &\quad + b_1 \theta_i(k) + b_2 \theta_i(k-1) \end{aligned} \quad (23)$$

여기서, a_1, a_2, b_1, b_2 는 모터상수와 표본화 주기의 함수로서 추정해야 할 파라미터들이며 시뮬레이션에 사용된 표본화 주기는 0.05초, 출력 측정잡음은 분산이 $2.56 * 10^{-4}$ 인 백색 잡음으로 하였다. 그리고 시스템 파라미터의 변화가 없음에도 불구하고 잡음만에 의한 허위고장신호 발생률을 최대로 줄이기 위해 $\alpha = 0.005$ (0.5%)로 했으며 (13)으로부터 고장감지를 위한 문턱값 δ_f 를 0.013 으로 설정했으며 여러 번의 시뮬레이션을 통해 δ^* 및 L은 각각 0.009 및 30으로 하였다. 또한 고장의 종류를 분류하기 위한 다중고장 분류기의 각 ART2 신경회로망 모듈의 입력노드는 2개로서 입력패턴은 추정파라미터이며, 각 모듈의 경계인수 파라미터 $\epsilon_1^{(1)}, \epsilon_2^{(1)}, \epsilon_1^{(2)}$ 및 $\epsilon_2^{(2)}$ 는 각각 0.2, 0.2, 0.04 및 0.08로 설정하였다.

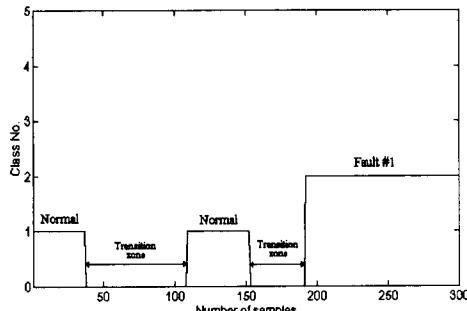
물리적인 계수들의 값을 인위적으로 변화시킴으로써 시스템에서의 예기치 못한 고장상황을 다음과 같은 세 가지의

단일고장과 한 가지의 다중고장으로 설정하였다.

고장 #1 : 속도궤환이득 K_2 가 변화
 고장 #2 : 전기자 저항이 증가
 고장 #3 : 전기자 저항이 감소
 고장 #4 : 고장 #1과 #2가 동시에 발생
 그림 7(a)는 150번째에 속도궤환이 되지 않는($K_2 = 0$) 고장 #1이 발생했을 때 원도우내에서 자승오차의 합의 변화이며 7(b)는 두개의 ART2 신경회로망 모듈로 구성된 다중고장 분류기의 출력 상태를 도시한 것으로서 시스템의 초기 정상상태에서는 비록 천이영역이 발생되지만 생성된 클래스가 없으므로 클래스 1(정상)이 되며, 150번째에 고장 #1이 발생하여 원도우 내의 오차가 문턱값을 넘는 153번째에서 고장이 감지되고 천이영역에 있는 동안에는 ART2 신경회로망에는 입력이 없으므로 분류가 이루어지지 않고 천이영역을 벗어나는 192번째 순간에 추정된 파라미터가 신경회로망에 전달되어 클래스 2(고장 #1)를 생성시킴을 알 수 있다.



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



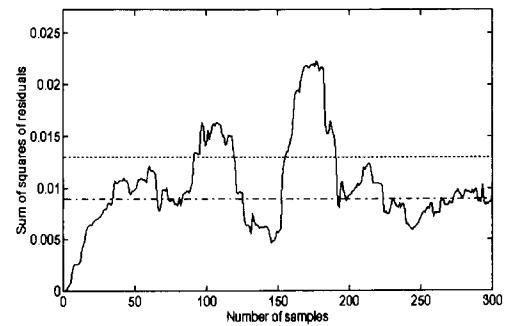
(b) 다중고장 분류기의 출력

그림 7. 고장 #1에 대한 고장감지와 분류 결과.

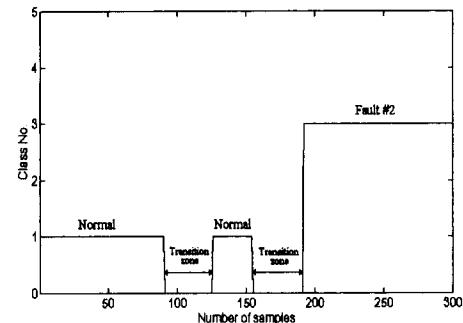
Fig. 7. Results of detection and isolation for fault #1.

고장 #2의 한 경우로서 전기자 저항이 2Ω 으로 증가했을 때의 오차의 변화 및 분류 결과가 그림 8(a)와 (b)에 각각 나타나 있다. 그림 8(b)에 나타난 바와 같이 155번째 순간에 고장이 감지되고 192번째 순간에 다중고장 분류기에 추정된 파라미터가 전달되어서 분류가 이루어지는데 기존의 클래스 1 및 2와의 유사성 검사를 통과하지 못하고 새로운 클래스 3(고장 #2)를 생성시킴을 알 수 있다. 전기자 저항이 0.53Ω 으로 감소하는 고장 #3이 발생했을 때의 고장감지 및 분류결과는 그림 9와 같으며 그림 9(a)와 (b)로 부터 153번째 순간에 고장이 감지되고 190번째 순간에 분류가 이루어지는데 클래스 4(고장 #3)가 생성됨을 알 수 있다. 그림 7, 8 및 그림 9에서 고장발생 전의 고장감지는 잡음에 기인한 것으로서 분류기의 출력으로 부터 시스템은 정상상태임

을 알 수 있다.



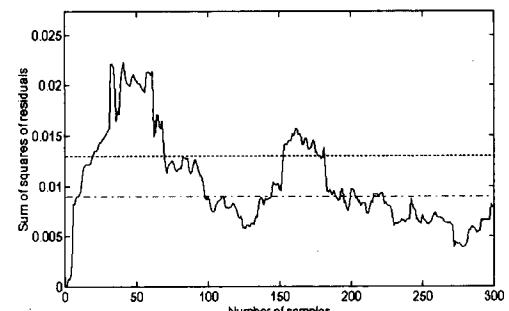
(a) J_L 의 변화와 고장감지(점선 : δ_f , 일점쇄선 : δ^*)



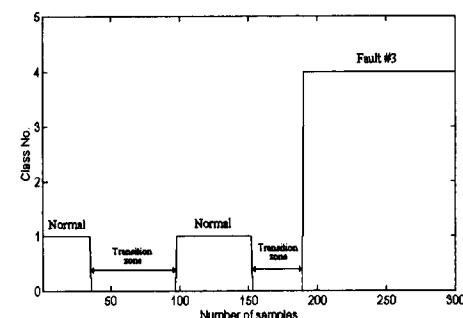
(b) 다중고장 분류기의 출력

그림 8. 고장 #2에 대한 고장감지와 분류 결과.

Fig. 8. Results of detection and isolation for fault #2.



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



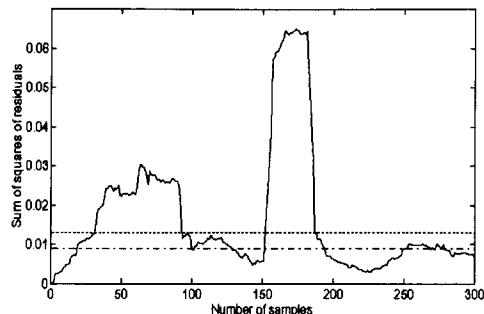
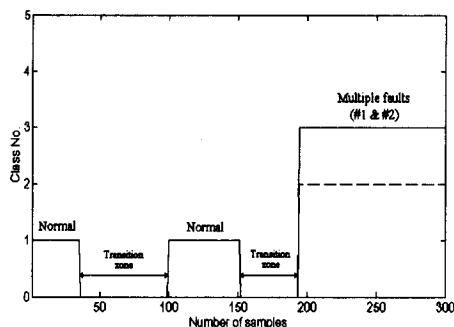
(b) 다중고장 분류기의 출력

그림 9. 고장 #3에 대한 고장감지와 분류 결과.

Fig. 9. Results of detection and isolation for fault #3.

고장 #1과 고장 #2가 동시에 발생하는 다중고장 #4에 대

한 감지 및 분류결과가 그림 10에 나타나 있다. 그림 10(a)는 J_L 의 변화를 보여주는데 고장감지는 152번째에서 이루어졌고 천이영역의 끝은 194번째에서 인식되었음을 알 수 있다. 그림 10(b)는 고장 #4의 분류결과인데 모듈 1과 모듈 2의 출력은 각각 클래스 3와 클래스 2로서 조정자에 의해 다중고장 분류기는 이 고장을 새로운 고장으로 분류하지 않고 고장 #1과 고장 #2가 동시에 발생한 다중고장으로 선언함을 알 수 있다.

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

(b) 다중고장 분류기의 출력(실선 : 모듈1, 점선 : 모듈2)

그림 10. 고장 #4에 대한 고장감지와 분류 결과.
Fig. 10. Results of detection and isolation for fault #4.

다음에는 여러 경계인수를 갖는 ART2 신경회로망과 기존의 ART2 신경회로망[14, 15]의 고장페턴 분류능력을 비교해 보았으며 결과는 표 1과 같다. 표 1에서 $\hat{\theta}_1$ 은 정상상태(클래스 1)일 때 추정파라미터 벡터, $\hat{\theta}_2$, $\hat{\theta}_3$ 과 $\hat{\theta}_4$ 는 각각 속도궤환율이 0, 10, 20으로 변화했을 때의 추정파라미터 벡터로서 고장 #1(클래스 2)으로 분류되어야 한다. 그리고 $\hat{\theta}_5$, $\hat{\theta}_6$ 및 $\hat{\theta}_7$ 은 각각 전기자 저항이 2Ω , 1.76Ω 및 1.52Ω 으로 증가했을 때의 추정파라미터 벡터로서 고장 #2(클래스 3)으로 분류되어야 하며 $\hat{\theta}_8$, $\hat{\theta}_9$ 및 $\hat{\theta}_{10}$ 은 각각 전기자 저항이 0.44Ω , 0.52Ω , 0.60Ω 으로 감소하는 고장 #3가 발생했을 때의 추정파라미터 벡터로서 클래스 4로 분류되어야 한다. 표 1로부터 파라미터 \hat{a}_1 , \hat{a}_2 가 b_1 , b_2 에 비해서 고장에 더욱 민감하게 크게 변함을 알 수 있다. 각 추정파라미터의 민감도 차이를 고려하지 않고 하나의 경계인수를 사용하는 기존의 ART2 신경회로망에 의해 고장페턴을 분류한 결과 $\hat{\theta}_4$ 가 고장 #1으로 분류되지 않고 고장 #2로 잘못 분류됨을 알 수 있다. 이때 경계인수 $\epsilon_i = 0.14$, $i=1, \dots, 4$ 로 설정하였다. 반면 제안한 ART2 신경회로망에서는 각 파라미터의 민감도를 고려하여 경계인수 ϵ_1 , ϵ_2 ,

ϵ_3 및 ϵ_4 를 각각 0.2, 0.2, 0.04 및 0.08로 설정하였으며 이를 적용한 결과 $\hat{\theta}_4$ 가 고장 #1으로 정확하게 분류됨을 알 수 있다.

표 1. 기존의 ART2 신경회로망과 제안한 ART2 신경회로망의 고장페턴 분류.
Table 1. Fault pattern classifications of the conventional ART2 neural network and the proposed ART2 neural network.

고장종류	추정파라미터 (\hat{a}_1 , \hat{a}_2 , b_1 , b_2)	기존의 ART2 신경회로망의 분류결과	제안한 ART2 신경회로망의 분류결과
정상상태 ($K_2 = 62.4$, $R_a = 0.88\Omega$)	$\hat{\theta}_1(1.383, -0.495, 0.059, 0.052)$	클래스 1	클래스 1
고장 #1	$K_2 = 0$ $\hat{\theta}_2(1.826, -0.967, 0.072, 0.068)$	클래스 2	클래스 2
	$K_2 = 10$ $\hat{\theta}_3(1.740, -0.877, 0.069, 0.067)$	클래스 2	클래스 2
	$K_2 = 20$ $\hat{\theta}_4(1.645, -0.778, 0.066, 0.062)$	클래스 3	클래스 2
고장 #2	$R_a = 2\Omega$ $\hat{\theta}_5(1.696, -0.751, 0.025, 0.028)$	클래스 3	클래스 3
	$R_a = 1.76\Omega$ $\hat{\theta}_6(1.620, -0.685, 0.037, 0.030)$	클래스 3	클래스 3
	$R_a = 1.52\Omega$ $\hat{\theta}_7(1.591, -0.661, 0.045, 0.031)$	클래스 3	클래스 3
고장 #3	$R_a = 0.44\Omega$ $\hat{\theta}_8(1.081, -0.238, 0.094, 0.068)$	클래스 4	클래스 4
	$R_a = 0.52\Omega$ $\hat{\theta}_9(1.150, -0.307, 0.086, 0.055)$	클래스 4	클래스 4
	$R_a = 0.60\Omega$ $\hat{\theta}_{10}(1.213, -0.345, 0.083, 0.045)$	클래스 4	클래스 4

IV. 결론

이 논문에서는 시스템의 단일고장 뿐만 아니라 다중고장 문제를 동시에 고려할 수 있는 진단 알고리듬을 제안한다. 제안한 고장진단 알고리듬은 시스템 파라미터 추정부, 시스템의 고장으로 인한 시스템의 성능저하의 징후를 조기에 감지하기 위한 고장감지부와 고장의 종류를 판별하기 위한 고장분류부로 이루어져 있는데 고장분류를 위해 두개의 ART2 신경회로망 모듈로 구성된 다중고장 분류기를 이용한다. 이 알고리듬의 장점으로 다음과 같은 세가지를 들 수 있다. 첫 번째는 고장이 감지되면 RLS 추정알고리듬에 사용된 이득 행렬을 초기화한 뒤 고장발생후의 시스템 파라미터 $\theta(\hat{a}_i, \hat{b}_i)$ 및 센서에 존재하는 바이어스 f_s 를 추정함으로써 좀 더 신속한 파라미터의 추정을 기대할 수 있다. 두 번째는 다중고장 분류기의 각 모듈을 구성하는 여러 경계인수를 갖는 ART2 신경회로망이 새로운 고장상태를 자동생성해나가는 능력을 가진 자율학습 신경회로망이므로 사전에 고장에 관한 정확한 지식이 필요하지 않으며, 고장 유형에 따른 각 시스템 파라미터의 민감도 차이를 고려한 경계인수검사 조건을 이용함으로써 정확한 고장분류가 가능하다. 세 번째로는 다중고장 분류기를 사용함으로써 시스템에 다중고장이 발생할 경우에도 이를 새로운 고장으로 분류하지 않고 기존의 지식을 이용하여 다중고장으로 구분해낼 수 있다. 컴퓨터 시뮬레이션을 통해서 제안한 고장진단 알고리듬이 시스템에서 발생되는 단일고장 뿐만 아니라 다중고장도 정확하게 분류해낼 수 있다. 앞으로 남은 과제

는 고장감지를 위한 문턱값과 고장분류를 위한 경계인수값을 설정함에 있어서 통계학적 방법을 이용한 체계적인 연구와 진단결과를 분석하여 전체 시스템의 운용전략에 반영하여 시스템의 성능을 유지시키는 방법에 대한 연구이다.

참고문헌

- [1] Y. S. Wong, et al., "A review and implementation of contingency management in flexible manufacturing systems," *Int. J. Computer Integrated Manufacturing*, vol. 5, no. 4 & 5, pp. 266-276, 1992.
- [2] R. Doraiswami and J. Jiang, "Performance monitoring in expert control systems," *Automatica*, vol. 25, no. 6, pp. 799-811, 1989.
- [3] T. Sorsa and H. N. Koivo, "Application of artificial neural networks in process fault diagnosis," *Automatica*, vol. 29, no. 4, pp. 843-849, 1993.
- [4] 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.
- [5] R. Patton, P. Frank and R. Clark, *Fault Diagnosis in Dynamic Systems Theory and Application*, Prentice Hall, 1989.
- [6] 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.
- [7] P. Smyth, "Hidden markov models for fault detection in dynamic systems," *Pattern Recognition*, vol. 27, no. 1, pp. 149-164, 1994.
- [8] R. Isermann, "Fault diagnosis of machines via parameter estimation and knowledge processing," *Automatica*, vol. 29, no. 4, pp. 815-835, 1993.
- [9] R. Isermann, "Model based fault detection and diagnosis methods," *Proc. of American Control Conference(ACC)*, pp. 1605-1609, 1995.
- [10] R. Isermann, "Process fault detection based on modeling and estimation methods- a survey," *Automatica*, vol. 20, no. 4, pp. 387-404, 1984.
- [11] R. Isermann and B. Freyermuth, "Process fault diagnosis based on process model knowledge-Part I: Principles for fault diagnosis with parameter estimation," *Journal of Dynamic systems, Measurement, and Control*, vol. 113, pp. 620-626, 1991.
- [12] 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.
- [13] M. M. Polycarpou and A. T. Vemuri, "Learning methodology for failure detection and accommodation," *IEEE Control System Magazine*, pp. 16-24, 1995.
- [14] S. Y. Kung, *Digital Neural Networks*, Prentice Hall, 1993.
- [15] Y. H. Pao, *Adaptive Pattern Recognition and Neural Networks*, Addison-Wesley Publishing Co., 1989.
- [16] L. Ljung and T. Söderström, *Theory and Practice of Recursive Identification*, MIT Press, 1983.



이 인 수

1986년 경북대학교 전자공학(공학사).
1989년 동대학원 졸업(공학석사). 1997년
동대학원 졸업(공학박사). 1997년
~ 현재 상주산업대학교 전자전기공학
과 전임강사. 주요 관심 분야는 시스템
의 고장진단 및 고장허용제어, 지능 제

어, 공장자동화등이다.



신 필 재

1995년 경북대학교 전자공학(공학사).
1997년 동 대학원 졸업(공학석사).
1997년 ~ 현재 LG 전자 연구원. 주요
관심분야는 지능제어 및 고장진단이다.

전 기 준

제어·자동화·시스템공학회 논문지 제 2권 제 1호 참조.