

論文2002-39SC-1-6

신경회로망기반 다중고장모델에 의한 비선형시스템의 고장감지와 분류

(Fault Detection and Isolation of the Nonlinear systems
Using Neural Network-Based Multi-Fault Models)

李仁秀 *

(In Soo Lee)

요 약

본 논문에서는 비선형시스템에서 발생한 고장을 감지하고 분류하기 위한 신경회로망기반 다중고장모델을 이용한 고장감지 및 분류 방법을 제안한다. 시스템에 변화가 발생하면 시스템의 출력과 신경회로망 공칭모델 출력 사이의 오차가 고장감지를 위한 문턱값을 넘고, 고장이 감지되면 각 신경회로망 고장모델 출력과 시스템 출력 사이의 오차를 이용하여 통계적 기법으로 고장을 분류한다. 컴퓨터 시뮬레이션 결과로부터 제안한 고장진단방법이 비선형시스템에서의 고장감지 및 분류문제에 잘 적용됨을 알 수 있다.

Abstract

In this paper, we propose an FDI(fault detection and isolation) method using neural network-based multi-fault models to detect and isolate faults in nonlinear systems. When a change in the system occurs, the errors between the system output and the neural network nominal system output cross a threshold, and once a fault in the system is detected, the fault classifier statistically isolates the fault by using the error between each neural network-based fault model output and the system output. From the computer simulation results, it is verified that the proposed fault diagonal method can be performed successfully to detect and isolate faults in a nonlinear system.

I. 서 론

시스템의 규모가 방대해지고 복잡해질 뿐만 아니라, 많은 공정이 자동화됨에 따라 시스템의 신뢰성 및 안전성 유지에 대한 관심이 고조되고 있으며, 이를 위한 적절한 고장진단기법에 관한 연구가 활발히 이루어지고 있다.

고장진단의 목적은 시스템에서 고장이 발생하면 이를 조기에 감지하고, 고장이 발생한 위치 등에 관한 정보를 운전자에게 제공함으로써 운전자로 하여금 고장

에 대한 적절한 조치를 취하도록 하는데 있다. 일반적으로 고장진단은 시스템에서의 오동작 여부를 판단하기 위한 고장감지(detection)단계, 발생한 고장의 종류를 분류하기 위한 고장분류(isolation)단계 및 고장의 정도를 결정하는 고장식별(identification)단계로 이루어진다. 기존의 고장감지 및 분류(FDI : fault detection and isolation)방법은 크게 모델에 기반한 방법과 모델에 기반하지 않는 방법으로 분류할 수 있다. 먼저, 모델에 기반한 FDI 방법은 시스템의 수학적 모델에 의해 제공되는 해석적인 기법을 기초로 하는 것으로서 상태 추정 접근법^[1]과 파라미터추정 접근법^[2,3]으로 나눌 수 있으며, 고장진단을 위해서는 시스템의 정확한 정량적 모델이 필요하므로 불확실성이 존재하고 비선형성이 강한 시스템에는 적용이 어렵다는 문제점이 있다.

다음으로, 모델에 근거하지 않는 방법은 대상 시스템

* 正會員, 尙州大學校 電子電氣工學部

(School of Electronics and Electrical Engineering, Sangju National University)

接受日字:2001年5月21日, 수정완료일:2001年11月6日

의 측정치, 경험 또는 물리적 검토를 기초로 하며, 시스템의 출력값이 제한된 범위를 벗어나는지의 유무로써 고장을 감지해내는 한계치 검사, 전문가 시스템 기법 및 신경회로망을 이용한 방법^[4~7] 등이 있으며, 최근에는 학습 기능 및 입출력데이터로부터 비선형함수 표현이 가능한 장점이 있는 신경회로망을 고장진단에 이용한 연구결과가 많이 발표되고 있다. 그러나, 신경회로망을 이용한 대부분의 연구에서는 사전에 발생이 가능한 모든 고장을 미리 예측하여 신경회로망 고장모델로 구축하고 고장이 발생하면 미리 구축한 고장모델 중에서 가장 유사한 고장모델을 선택하여 고장을 분류하나 사전에 모든 고장에 대한 모델을 구축하는 것은 매우 어렵다는 단점이 있다^[8]. 특히 사전에 고장모델로 구축하지 않은 예상하지 않은 새로운 고장이 발생할 경우에는 가장 유사한 고장모델을 선택하므로써 잘못된 고장진단을 행한다. 그러므로, 예상되지 않는 고장뿐만 아니라 시스템의 동작 조건에 따라 새로운 고장이 발생할 때에도 이를 분류할 수 있는 수단이 필요하다. 즉, 고장 분류기는 분류되어야 할 입력패턴들을 적응적으로 구별해 내는 것이 필요하며, 이에 대한 해결책으로 자율신경회로망인 ART(adaptive resonance theory) 신경회로망을 이용하는 연구^[9]가 있었으나 추정된 시스템 파라미터로써 고장을 분류하므로 파라미터 추정시간으로 인해 고장분류 시간이 지연된다는 문제점이 있다.

본 논문에서는 비선형시스템에도 적용 가능할 뿐만 아니라 예상하지 않은 새로운 고장이 발생했을 때의 고장분류문제와 고장분류시간의 단축문제를 동시에 해결할 수 있는 신경회로망을 이용한 고장감지와 분류 방법을 제안한다. 고장분류부에서는 신경회로망기반 다중고장모델을 이용한 고장분류기(fault classifier by neural network-based multi-fault models)를 이용하므로써 신경회로망의 특성에 의해 비선형시스템의 진단 문제에 직접 적용이 가능할 뿐만 아니라 이미 신경회로망 고장모델로 구축된 고장이 발생할 경우에는 고장 분류 시간을 단축시킬 수 있으며, 예상하지 않은 새로운 고장이 발생하여도 이를 새로운 고장으로 분류할 수 있다. 그리고, 고장감지부에서도 신경회로망을 고장감지를 위한 공칭모델로 사용함으로써 비선형시스템의 고장감지문제에 적용이 가능하다. 제안한 고장감지와 분류방법을 비선형시스템의 고장진단문제에 적용하여 성능을 알아보았다.

II. 신경회로망을 이용한 고장감지 및 분류 알고리즘

1. 신경회로망

본 논문에서 고장감지를 위한 공칭모델 및 신경회로망기반 다중고장모델 고장분류기를 구성하는 신경회로망의 구조는 그림 1과 같이 다층신경회로망으로서 입력층, 중간층과 출력층으로 이루어져 있다.




그림 1. 다층 신경회로망의 구조도
Fig. 1. Architecture of the multilayer neural network.

신경회로망의 학습방법은 일반적으로 많이 이용되는 역전파(back-propagation) 알고리즘^[10]을 이용하며 신경회로망을 학습시키기 위한 성능함수는 다음과 같다.

$$E = \frac{1}{2} (d(t) - O_1(t))^2 \tag{1}$$

여기서 $d(t)$ 와 $O_1(t)$ 는 각각 목표값과 실제 신경회로망의 출력노드에서의 출력값이며, 아래첨자 1은 신경회로망의 출력노드가 하나임을 의미한다. 출력노드에서의 오차신호는 아래와 같다.

$$\begin{aligned} \delta_1 &= - \frac{\partial E}{\partial net_1} \\ &= (d(t) - O_1(t)) \cdot f'(net_1) \end{aligned} \tag{2}$$

여기서 net_1 는 출력노드의 입력, $f(\cdot)$ 는 시그모이드 함수의 미분이다.

은닉층과 출력층사이의 가중치에 대한 오차함수의 기울기와 가중치는 각각

$$\begin{aligned}\Delta w_{1j} &= -\eta \cdot \frac{\partial E}{\partial w_{1j}} \\ &= \eta \cdot \delta_1 \cdot O_j\end{aligned}\quad (3)$$

$$w_{1j}(t+1) = w_{1j}(t) + \Delta w_{1j} + \alpha \cdot (w_{1j}(t) - w_{1j}(t-1))\quad (4)$$

로 개선이 된다. 여기서 w_{1j} 는 j 번째 은닉노드와 출력노드사이의 가중치, η 는 학습률, α 는 학습속도 개선을 위한 모멘텀 항이며 O_j 는 j 번째 은닉노드에서의 출력값이다. 마찬가지로, j 번째 은닉노드에서의 오차신호 및 입력층과 은닉층사이의 가중치의 조정은 각각 다음과 같다.

$$\begin{aligned}\delta_j &= -\frac{\partial E}{\partial O_j} \cdot \frac{\partial O_j}{\partial net_j} \\ &= \delta_1 \cdot w_{1j} \cdot f'(net_j)\end{aligned}\quad (5)$$

$$\begin{aligned}\Delta w_{ji} &= -\eta \cdot \frac{\partial E}{\partial w_{ji}} \\ &= \eta \cdot \delta_j \cdot O_i\end{aligned}\quad (6)$$

$$w_{ji}(t+1) = w_{ji}(t) + \Delta w_{ji} + \alpha \cdot (w_{ji}(t) - w_{ji}(t-1))\quad (7)$$

여기서 w_{ji} 는 i 번째 입력노드와 j 번째 은닉노드사이의 가중치이며, O_i 는 i 번째 입력노드에서의 출력값이다.

2. 고장감지

본 논문에서는 고장진단을 위한 대상 시스템은 아래와 같은 이산시간 비선형시스템으로 가정한다.

$$\begin{aligned}y(k+1) &= g[y(k), y(k-1), \dots, y(k-n+1), \\ &u(k), u(k-1), \dots, u(k-m+1)] + \epsilon(k)\end{aligned}\quad (8)$$

여기서 $u(k)$, $y(k)$ 는 각각 시스템의 입력과 출력, $g(\cdot)$ 의 비선형함수이며, $\epsilon(k)$ 는 백색 잡음이라고 가정한다. 일반적으로 시스템의 고장은 이득, 저항값, 캐패시턴스 등과 같은 물리적 파라미터의 변화 혹은 기계적인 마모 등에 기인하며, 이러한 파라미터들의 변화는 시스템 모델 파라미터를 변화시키므로 고장으로 인한 비선형시스템은 아래와 같이 표현할 수 있다.

$$\begin{aligned}y(k+1) &= g_f[y(k), y(k-1), \dots, y(k-n+1), \\ &u(k), u(k-1), \dots, u(k-m+1)] + \epsilon(k)\end{aligned}\quad (9)$$

여기서 $g_f(\cdot)$ 는 비선형함수로서 고장으로 인해 파라미터가 변한 시스템이다. 시스템에 고장이 발생하면 (9)

의 관계가 성립하므로 변화된 비선형시스템 $g_f(\cdot)$ 를 추정하여 이를 분류에 이용한다면 고장의 원인을 알 수 있다. 이를 위해서 본 논문에서는 고장이 발생하면 변화된 비선형시스템 $g_f(\cdot)$ 를 직접 추정하지 않고, 변화된 시스템과 가장 유사한 신경회로망 고장모델을 결정하므로써 고장을 분류한다. 또한, 이 연구에서는 고장을 분류하기 위해 시스템의 입력력 신호를 이용하므로 입력력 신호를 얻을 수 없는 시스템의 완전파괴와 같은 고장은 고려하지 않는다.

최소화 해야할 성능지수, 시스템 출력과 신경회로망 공칭모델 출력사이의 오차를 각각 아래와 같이 정의하며 식 (10)을 최소화하는 방향으로 신경회로망을 학습하여 고장감지를 위한 공칭모델을 구축한다.

$$J_n(k) = \sum_{i=1}^k e_n^2(i)\quad (10)$$

$$e_n(k) = y(k) - y_n(k)\quad (11)$$

여기서 y_n 은 신경회로망 공칭모델의 출력이며 $e_n(k)$ 는 시스템 출력과 공칭모델 출력과의 오차이다.

본 논문에서는 실제 시스템 출력과 신경회로망 공칭모델 출력 사이의 오차를 계산하여 윈도우 내에서의 오차가 다음과 같은 조건을 만족하면 고장이 발생된 것으로 인식한다.

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

여기서 δ_f 는 고장감지를 위한 문턱값, L 은 윈도우 크기이다. 공칭모델이 충분히 학습되었다면 시스템 출력과 공칭모델 출력사이의 오차는 시스템 잡음과 거의 같은 성질을 가진다^[11]. 따라서, 오차 e_n 은 정규분포 $N(0, \sigma^2)$ 를 따르며, 윈도우 내에서의 L 개의 정규화된 자승오차 $\frac{e_n^2(i)}{\sigma^2}$ 의 합은 아래와 같이 자유도 (degree of freedom)가 L 인 χ_L^2 (chi-square) 분포를 따르게 된다.

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

고장감지를 위한 문턱값 δ_f 는 잡음만에 의한 허위고장 신호 발생확률과 고장신호를 발생시키지 못하는 확률을 동시에 줄이는 방향으로 설정해야 하나, 대부분의

시스템에서 고장에 의한 시스템 파라미터의 변화는 클 것이므로, 이로 인한 시스템 출력과 신경회로망 공칭모델 출력과의 오차는 시스템이 정상일 때 잡음만에 의한 오차에 비해서 클 것이다. 그러므로 본 논문에서는 고장감지를 위한 문턱값 δ_f 를 허위고장신호 발생확률을 최대한 줄이는 방향으로 설정한다. 즉, 시스템이 정상일 때 허위고장신호 발생확률의 허용한계를 α 라고 하면

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

이므로 χ^2 분포표로부터 상수 δ° 를 구한 뒤 이로부터 고장감지를 위한 문턱값 $\delta_f = \sigma^2 \delta^\circ$ 를 구한다. 또한 윈도우 크기 L 은 크면 추정치의 신뢰도는 증가하나, 과거의 데이터를 많이 이용하므로써 고장에 빠르게 반응하기가 힘들뿐만 아니라 분류가 늦어지는 문제가 있다. 반면에 윈도우 크기가 너무 작으면 추정치의 분산이 커지고, 추정 파라미터의 신뢰도가 낮아지므로 적절히 선정한다.

3. 신경회로망기반 다중고장모델을 이용한 고장분류
 신경회로망기반 다중고장모델 고장분류기는 그림 2와 같이 신경회로망 고장모델모듈부분, 시스템 출력과 각 가설에 대한 고장모델 출력과의 오차를 발생시키고 통계적 분석(statistical analysis)을 하는 부분 및 최종 결정부분으로 이루어져 있다. 고장모델들은 미리 구축하는 것이 아니라 고장분류기의 최종 결정부에서 새로운 고장이 발생된 것으로 인식되면 입출력데이터를 이용하여 새로운 고장에 대한 신경회로망 고장모델을 학습시켜서 이를 고장모델모듈부분에 추가하는 과정을 거치는데 이미 이러한 과정을 거쳐서 M 개의 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.

$$Y^k = \{ y(i) : i=1, \dots, k \} \quad (15)$$

$$\Lambda_{ji}(k) = \ln \frac{p[Y^k | H_j]}{p[Y^k | H_i]} \quad (16)$$

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_j 는 현재의 시스템 상태가 j 번째 고장모델과 일치한다는 가설로서 고장모델은 그림 2와 같이 신경회로망

으로 구성한다.




그림 2. 신경회로망기반 다중고장모델을 이용한 고장 분류기

Fig. 2. Fault classifier by neural network-based multi-fault models.

식 (16)은 다음과 같은 순환식으로 표현될 수 있으며^[12]

$$\Lambda_{ji}(k) = \ln \frac{p[y(k) | Y^{k-1}, H_j]}{p[y(k) | Y^{k-1}, H_i]} + \Lambda_{ji}(k-1) \quad (17)$$

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

$$e_j(k) = y_j(k) - \tilde{y}_j(k) \quad (18)$$

의 확률밀도함수를 아래와 같이 가우시안으로 가정한다. 여기서 $\tilde{y}_j(k)$ 는 j 번째 신경회로망 고장모델의 출력으로서 j 번째 가설에 대한 고장모델의 출력을 의미한다.

$$p[e_j(k) | Y^{k-1}, H_j] = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{e_j^2(k)}{2\sigma^2}\right) \quad (19)$$

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

$$p[y(k) | Y^{k-1}, H_j] = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(y(k) - \tilde{y}_j(k))^2}{2\sigma^2}\right) \quad (20)$$

시스템에 발생한 고장분류를 위해 공산함수와 공산비를 이용한 다중 순차적 가설 검증법 중에서 Armitage 검증법^[13]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 : $\Lambda_{ji}(k) \geq T_{ji}, \forall i = 1, 2, \dots, M, j \neq i$ 를 만족하는 $H_j, j = 1, 2, \dots, M,$ 를 결정한다. 조건을 만족하지 않으면 단계 1로 가서 검증을 계속한다. T_{ji} 는 문턱값으로서 아래와 같이 결정된다.

$$T_{ji} = \ln \frac{1 - \sum_{l=k_j} \hat{e}(l, j)}{\hat{e}(j, i)} \quad (21)$$

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

Armitage 검증법은 각 가설 사이의 로그 공산비를 구해서 기존의 가설 중에서 시스템의 상태와 가장 유사한 가설을 결정하는 상대적인 유사도 검사기법이므로 고장모델로 구축되지 않은 새로운 고장이 발생하면 기존의 고장모델 중에서 가장 유사한 것을 선택하는 오 분류를 행하게 된다. 그러므로 본 논문에서는 새로운 고장이 발생 시에 일치되는 가설이 없다는 결정을 할 수 있도록 시스템 출력과 각 고장모델 출력사이의 오차제곱을 고려하여 절대적인 유사도를 검사하는 부분을 첨가했다. 제안한 신경회로망기반 다중고장모델 고장분류기에서 고장이 감지된 후 고장을 분류하는 과정은 아래와 같다.

단계 1 : 실제 시스템 출력과 입력으로부터 신경회로망 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 $\sum_{l=k_j+1}^k (y(l) - \hat{y}_j(l))^2$ 을 구한다. 만일 $k < k_j + n_j$ 이면 단계 1로 간다. 단, $i, j = 1, 2, \dots, M, i \neq j, k = k_j + 1, \dots, k_j + n_j$

단계 3 : 다음과 같은 두 조건

$$\Lambda_{ji}(k_j + n_j) \geq T_{ji}, \forall i = 1, \dots, M, i \neq j \quad (22)$$

$$\sum_{l=k_j+1}^{k_j+n_j} (y(l) - \hat{y}_j(l))^2 \leq r \quad (23)$$

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 발생

한 고장과 일치된 가설이 없음을 출력한다.

고장분류기에서 새로운 고장상황으로 결정되면 입출력데이터를 이용하여 새로운 고장에 대한 신경회로망 고장모델을 학습시켜서 이를 고장모델모듈부분에 추가한다. 위 3단계 신경회로망기반 다중고장모델 고장분류기의 고장분류 과정에서 k_j 는 고장감지 시간, n_j 는 고장이 감지된 뒤 고장분류기가 동작하는 윈도우의 크기이며, T_{ji} 는 문턱값으로서 (21)과 같다. 그리고 r 은 절대유사도 검사를 위한 상수로서 다음과 같이 구한다.

현재 시스템의 상태가 J 번째 고장모델에 해당한다고 가정하면, J 번째 신경회로망 고장모델은 J 번째 고장이 발생되었을 때의 시스템 입력과 출력데이터로부터 구축되므로 J 번째 고장모델의 출력과 시스템 출력사이의 오차 e 는 정규분포 $N(0, \sigma^2)$ 을 따른다. 그러므로 윈도우 내에서의 n_j 개의 정규화된 자승오차 $\frac{e^2(i)}{\sigma^2}$ 의 합은 아래와 같이 자유도가 n_j 인 $\chi^2_{n_j}$ 분포를 따른다.

$$\sum_{l=k_j+1}^{k_j+n_j} \frac{(y(l) - \hat{y}_j(l))^2}{\sigma^2} \sim \chi^2_{n_j} \quad (24)$$

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

$$\Pr\left(\sum_{l=k_j+1}^{k_j+n_j} \frac{(y(l) - \hat{y}_j(l))^2}{\sigma^2} \leq \bar{\delta}\right) = \alpha \quad (25)$$

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

그림 3에서 그래프 1은 이미 신경회로망 고장모델로 구축된 J 번째 고장이 발생했을 때의 윈도우 내에서의 n_j 개의 정규화된 오차자승 합의 분포로서 $\chi^2_{n_j}$ 분포일 것이다. 그러나 고장모델로 구축되지 않은 새로운 고장이 발생되었을 때는 상대유사도조건인 (22)를 만족하는 가장 유사한 모델이 J 라고 가정할 때 윈도우 내에서의 n_j 개의 정규화된 J 번째 고장모델의 출력과 시스템 출력사이의 오차는 정규분포가 아니며, 오차자승 합의 밀도함수분포도 정확한 $\chi^2_{n_j}$ 분포는 아니지만 전체적으로 $\chi^2_{n_j}$ 와 유사한 분포가 시스템 출력과 J 번째 고장모델 출력과의 오차로 인해 우측으로 이동된 형태로 볼 수 있다. 그림 3에서 A 부분은 새로운 고장이 발생했으나 J 번째 고장모델로 결정하는 영역이고, B 부분은 J 번째

제 고장이 발생했으나 J 번째 고장이 아닌 새로운 고장으로 결정하는 영역이다. 그러므로 α 를 작게 하면 상수 $\bar{\delta}$ 가 왼쪽으로 이동하며, 고장모델로 구축되지 않은 새로운 고장이 발생할 경우에 J 번째 고장이 아니라는 결정을 할 수 있다.




그림 3. 고장모델출력 오차의 χ^2 분포
Fig. 3. χ^2 distribution of the fault model output error.

만일 각 고장모델의 유사성이 아주 작을 경우는 α 를 크게 해도 잘못 분류할 가능성이 줄어들며, 유사성이 클 경우에는 α 를 작게하여 r 을 작게 설정해야 한다. 만일 k_f 순간에 고장이 감지되고, $k_f + n_f$ 순간에 J 번째 고장모델이(22)를 만족했다면

$$\Lambda_{ji}(k_f + n_f) \geq T_{ji} \quad (26)$$

이고, (17)과 (20)으로부터 k_f 순간부터 샘플수 n_f 까지의 로그공산비 $\Lambda_{ji}(k_f + n_f)$ 를 구해보면

$$\begin{aligned} \Lambda_{ji}(k_f + n_f) &= \ln \frac{p[y(k_f + n_f) | Y^{k_f + n_f - 1}, H_j]}{p[y(k_f + n_f) | Y^{k_f + n_f - 1}, H_i]} \\ &+ \Lambda_{ji}(k_f + n_f - 1) = -\frac{1}{2\sigma^2} \sum_{l=k_f+1}^{k_f+n_f} (y(l) - \tilde{y}_j(l))^2 \\ &+ \frac{1}{2\sigma^2} \sum_{l=k_f+1}^{k_f+n_f} (y(l) - \tilde{y}_i(l))^2 \end{aligned} \quad (27)$$

이므로 이를 (26)에 대입하여 정리하면

$$\begin{aligned} \sum_{l=k_f+1}^{k_f+n_f} (y(l) - \tilde{y}_i(l))^2 &\geq 2\sigma^2 T_{ji} \\ &+ \sum_{l=k_f+1}^{k_f+n_f} (y(l) - \tilde{y}_j(l))^2 \end{aligned} \quad (28)$$

$\forall i = 1, \dots, M, i \neq J$

된다. 그러므로 고장이 감지된 뒤 n_f 개의 샘플수 만에

(23)을 만족하는 고장모델이 존재한다는 것은 그 고장모델을 제외한 나머지 고장모델들에 대한 시스템 출력 사이의 오차의 크기는 (28)을 만족함을 의미한다.

III. 시뮬레이션결과 및 고찰

제안한 신경회로망에 의한 고장진단 알고리즘을 아래와 같은 비선형시스템에 적용하여 고장감지 및 분류능력을 알아보았다.

$$\begin{aligned} y(k) &= \cos(3.14 p_1)y(k-1) - 0.7y(k-2) \\ &+ u(k-1) + p_2u(k-2) + \varepsilon(k) \end{aligned} \quad (29)$$

여기서 $u(k)$, $y(k)$ 는 각각 시스템의 입력과 출력, $\varepsilon(k)$ 는 분산 $\sigma^2 = 2.56 \times 10^{-4}$ 인 백색잡음이며 p_1 과 p_2 는 물리적계수로서 공칭값은 아래와 같다.

$$p_1 = 0.56, p_2 = 0.37 \quad (30)$$

또한 입력은

$$u(k) = 0.5 \cos(k) \quad (31)$$

이다. 그리고 시스템이 정상적으로 동작함에도 불구하고 잡음만에 의한 허위고장신호 발생확률을 최대로 줄이기 위해 $\alpha = 0.01$ (1%)로 했으며, (14)로부터 고장 감지를 위한 문턱값 δ_f 를 구하면 0.013이며, 여러 번의 시뮬레이션을 통해서 L 은 30으로 하였다. 고장감지를 위한 신경회로망 공칭모델 및 신경회로망기반 다중 고장모델을 이용한 고장 분류기에서 각 신경회로망 고장모델의 구조는 한 개의 은닉층을 갖는 3단의 구조로서 입력층, 은닉층 및 출력층의 노드수는 각각 4개, 10개 및 1개이며, 입력은 $u(k-1)$, $u(k-2)$, $y(k-1)$, $y(k-2)$ 이다. 그리고 신경회로망의 학습을 위한 학습률 η 와 모멘텀 α 는 각각 0.15 및 0.1로 설정하였다. 또한 고장분류를 위한 계수들인 T_{ji} , r 및 n_f 는 각각 4.58, 0.004 및 10이며 $\tilde{\varepsilon}(i, j)$ 는 0.01로 설정했다.

제안한 고장감지 및 분류 방법의 고장분류성능을 알아보기 위해서 Armitage 검증법을 이용하여 분류하는 방법과 식 (22)와 (23)을 이용하는 제안한 방법을 비교하였으며, 두 방법은 모두 신경회로망기반 고장모델을 이용하며 통계적 분석 및 분류단계에서만 차이가 있다. 물리적인 계수들의 값을 인위적으로 변화시킴으로써


시스템에서의 예기치 못한 고장상황을 다음과 같이 설정하였다.

고장 #1 : P_1 이 감소


고장 #2 : P_1 이 증가

아래의 결과는 이미 고장 #1 ($P_1 = 0.7$ 로 증가)이 발생하여 두 개의 신경회로망 고장모델(고장모델 1은 시스템이 정상상태인 경우, 고장모델 2는 고장 #1에 대한 모델)이 구축된 뒤 테스트한 결과이다. 그림 4은 150번째 순간에 고장 #1의 한 경우인 $P_1 = 0.8$ 로 증가했을


때의 오차의 변화 및 분류 결과이다. 4(a)로부터 152번째 순간에 윈도우 내에서 시스템출력과 공칭모델과의 자승오차합이 고장감지 문턱값을 넘어 고장을 감지하였음을 알 수 있다. 그리고 4(b)는 Armitage 검증법에 의한 분류결과를 도시한 것으로서 현재 시스템에 발생한 고장을 고장 #1으로 분류함을 알 수 있고 4(c)는 제안한 신경회로망기반 다중고장모델을 이용한 고장분류기에 의한 분류결과로서 역시 고장 #1으로 분류함을 알 수 있다.



(a)



(b)




(c)


그림 4. 고장 #1에 대한 고장감지와 분류결과

- (a) J_n 변화와 고장감지(점선: δ_f)
- (b) Armitage 방법에 의한 분류결과
- (c) 제안한 방법에 의한 분류결과


Fig. 4. Results of detection and isolation for fault #1.
 (a) Change of J_n and fault detection(dashed line: δ_f)
 (b) Classification result by Armitage method
 (c) Classification result by Proposed method



(a)



(b)



(c)

그림 5. 고장 #2에 대한 고장감지와 분류결과

- (a) J_n 변화와 고장감지(점선: δ_f)
- (b) Armitage 방법에 의한 분류결과
- (c) 제안한 방법에 의한 분류결과

Fig. 5. Results of detection and isolation for fault #2.
 (a) Change of J_n and fault detection(dashed line: δ_f)
 (b) Classification result by Armitage method
 (c) Classification result by Proposed method

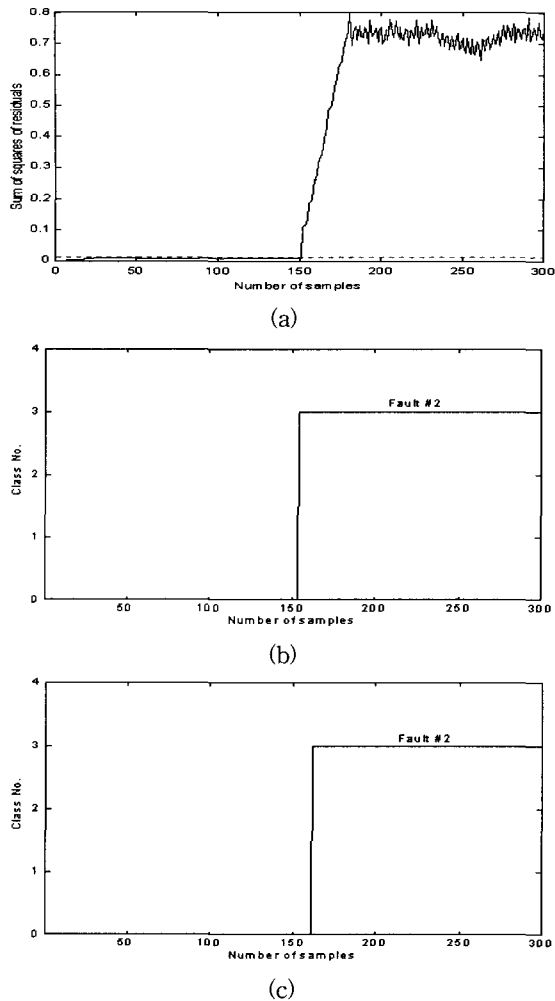


그림 6. 고장 #2에 대한 고장감지와 분류결과
 (a) J_n 변화와 고장감지(점선: δ_f)
 (b) Armitage 방법에 의한 분류결과
 (c) 제안한 방법에 의한 분류결과

Fig. 6. Results of detection and isolation for fault #2.
 (a) Change of J_n and fault detection(dashed line: δ_f)
 (b) Classification result by Armitage method
 (c) Classification result by Proposed method

그림 5(a)는 150번째에 고장모델로 구축되지 않은 새로운 고장 #2($P_1 = 0.4$ 로 감소)가 발생했을 때의 윈도우 내에서 자승오차합의 변화를 도기한 것으로서 152번째 순간에 고장을 감지하였으며, 5(b)로부터 Armitage 검증법을 이용할 경우에는 고장이 발생하지 않은 정상상태로 잘못 선언함을 알 수 있다. 반면 5(c)로부터 제안한 고장분류기의 경우는 이를 절대유사도 검증부에 의

해 일치되는 고장모델이 없음을 선언하고 새로운 고장으로 인식함을 알 수 있다. 그림 6은 고장#2에 대한 신경회로망 고장모델이 추가된 뒤 고장 #2가 다시 발생했을 때의 고장감지 및 분류결과로서 6(b)와 6(c)로부터 시스템에 고장 #2가 발생되었음을 알 수 있다.

IV. 결 론

본 논문에서는 비선형시스템에서의 고장진단 및 예상하지 못한 새로운 고장이 발생했을 때 이를 분류하기 위해 신경회로망을 이용한 고장감지방법과 신경회로망기반 다중고장모델 고장분류기에 의한 고장분류방법을 제안하였다. 제안한 고장진단알고리즘의 특징으로는 먼저, 비선형함수의 묘사가 가능한 신경회로망을 고장감지 및 분류를 위한 고장분류기에 이용함으로써 비선형시스템의 고장진단문제에 직접 적용이 가능하다는 점을 들 수 있다. 다음으로 새로운 고장이 발생할 경우에는 새로운 고장클래스로 분류가 가능하며, 새로운 고장에 대한 고장모델추가가 쉽다. 즉, 새로운 고장에 대한 임출력데이터로부터 신경회로망 고장모델모듈을 구축하여 고장모델부에 단순히 추가만 하면 된다. 마지막으로 고장으로 인해 변화된 시스템 출력과 이미 구축된 각 고장모델의 출력을 비교하여 가장 유사한 고장모델을 결정하므로 변화된 시스템 파라미터를 추정할 필요가 없으며, 이로 인해 고장모델로 구축된 고장이 발생하면 고장이 감지된 뒤 고장분류가 이루어지기까지의 시간을 많이 단축시킬 수 있다는 점이다.

컴퓨터 시뮬레이션을 통해서 제안한 고장진단 알고리즘이 비선형시스템에서 발생하는 고장을 빠르고 정확하게 분류할 뿐만 아니라 예상하지 못한 고장이 발생한 경우에도 이를 새로운 고장으로 분류함을 알 수 있다. 한편, 본 논문에서 제안한 방법은 이산적으로 발생하는 고장의 경우는 효율적이고 빠른 고장진단을 수행할 수 있으나 서서히 연속적으로 변하는 고장의 경우에는 적용이 쉽지 않으므로 이에 대한 지속적인 연구가 필요하다.

참 고 문 헌

[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, "Process fault detection based on modeling and estimation methods—a survey," *Automatica*, Vol. 20, No. 4, pp. 387-404, 1984.
- [3] M. M. Polycarpou and A. T. Vemuri, Learning methodology for failure detection and accommodation,"*IEEE Contr. Syst. Mag.*, pp. 16-24, 1995.
- [4] J. C. Hoskins and D. M. Himmelblau, "Artificial neural network models of knowledge representation in chemical engineering," *Computers Chem. Engng.*, Vol. 12, No. 9, pp. 881-890, 1988.
- [5] V. Venkatasubramanian, R. Vaidyanathan and Y. Yamamoto, "Process fault detection and diagnosis using neural networks—steady state processes," *Computers Chem. Engng.*, Vol. 14, No. 7, pp. 699-712, 1990.
- [6] E. Eryurek and B. R. Upadhyaya, "Sensor validation for power plants using adaptive back propagation neural network," *IEEE Trans. Nuclear Science*, Vol. 37, No. 2, pp. 1040-1047, 1990.
- [7] T. Sorsa, H. N. Koivo and H. Koivisto, "Neural networks in process fault diagnosis," *IEEE Trans. Syst., Man and Cybern.*, Vol. 21, No. 4, pp. 815-825, 1991.
- [8] M. A. Kramer and J. A. Leonard, "Diagnosis using backpropagation neural networks—analysis and criticism," *Computers Chem. Engng.*, Vol. 14, No. 12, pp. 1323-1338, 1990.
- [9] 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.
- [10] D. E. Rumelhart and J. L. McClelland, *Parallel distributed processing: explorations in the microstructure of cognition*. Vol. 1, MIT Press, Reading, MA, 1986.
- [11] J. D. Cryer, *Time Series Analysis*, Duxbury Press, 1986.
- [12] A. P. Sage and J. L. Melsa, *Estimation Theory with Applications to Communications and Control*, McGraw-Hill, 1971.
- [13] 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.

 저자 소개



李仁秀(正會員)

1963년 4월 16일생. 1986년 경북대학교 전자공학(공학사). 1989년 동대학원 졸업(공학석사). 1997년 동대학원 졸업(공학박사). 1997년~현재 상주대학교 전자전기공학부 조교수.

주요관심분야는 시스템의 고장진단 및 고장허용제어, 지능제어, 공장자동화등이다.