

비선형시스템의 고장진단을 위한 신경회로망 기반 통계적접근법

Neural Networks-based Statistical Approach for Fault Diagnosis in Nonlinear Systems

이인수*, 조원철**

In Soo Lee*, Won Chul Cho**

* : 상주대학교 전자전기공학부 교수

** : 경상북도 도립 경도대학 컴퓨터전자과 교수

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

** : Department of Computer Electronic, Kyongdo provincial College

요약

본 논문에서는 비선형시스템에서 발생한 고장을 감지하고 분류하기 위해 신경회로망기반 다중고장모델과 통계적기법에 의한 고장진단 방법을 제안한다. 제안한 알고리듬에서는 시스템의 출력과 신경회로망 공청모델 출력 사이의 오차가 미리 설정한 문턱값을 넘으면 고장을 감지한다. 고장이 감지되면 고장분류기에서는 각 신경회로망 고장모델 출력과 시스템 출력 사이의 오차를 이용하여 통계적 기법으로 고장을 분류한다. 컴퓨터 시뮬레이션 결과로부터 제안한 고장진단방법이 비선형 시스템에서의 고장감지 및 분류문제에 잘 적용됨을 알 수 있다.

Abstract

This paper presents a fault diagnosis method using neural network-based multi-fault models and statistical method to detect and isolate faults in nonlinear systems. In the proposed method, faults are detected when the errors between the system output and the neural network nominal system output cross a predetermined threshold. 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.

Keywords : Fault detection, fault isolation, nonlinear system, neural network, multi-fault models statistical method

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. 이는 시스템의 규모가 커짐에 따라 고장의 요인과 발생빈도가 증가하며 고장이 발생하면 생산성의 저하를 초래할 뿐만 아니라 심지어는 사람의 생명까지도 위협할 정도로 파급효과가 크기 때문이다.

일반적으로 고장진단은 시스템에서의 오동작 여부를 판단하기 위한 고장감지(detection)단계, 발생한 고장의 종류를 알아내기 위한 고장분류(isolation)단계 및 고장의 정도를 결정하는 고장식별(identification)단계로 이루어진다. 기존의 고장감지 및 분류방법은 크게 모델에 기반한 방법과 모델에

기반하지 않는 방법으로 분류할 수 있다. 먼저, 모델에 기반한 방법은 시스템의 수학적 모델에 의해 제공되는 해석적인 기법을 기초로 하는 것으로서 상태추정 접근법[1]과 파라미터추정 접근법[2,3]으로 나눌 수 있으며, 이 방법에서는 시스템의 정확한 정량적모델을 필요로 하므로 비선형성이 강한 시스템에는 적용이 어렵다는 문제점이 있다.

다음으로, 모델에 근거하지 않는 방법은 대상 시스템의 측정치, 경험 또는 물리적 검토를 기초로 하며, 시스템의 출력 값이 제한된 범위를 벗어나는지의 유무로써 고장을 감지해내는 한계치 검사, 전문가 시스템 기법 및 신경회로망을 이용한 방법[4-7] 등이 있으며, 최근에는 학습 기능 및 입출력 데이터로부터 비선형함수 표현이 가능한 장점이 있는 신경회로망을 고장진단에 이용한 연구결과가 많이 발표되고 있다. 그러나, 신경회로망을 이용한 대부분의 연구에서는 발생이 가능한 모든 고장을 미리 예측하여 신경회로망으로 고장모델을 구축한 뒤 고장이 발생하면 구축한 고장모델 중에서 가장 유사한 것을 선택하여 고장을 분류한다. 그러나 사전에 모든 고장에 대한 모델을 구축하는 것은 매우 어렵다는 문제점이 있다[8]. 특히 사전에 고장모델로 구축하지 않은 예상하지 못

한 새로운 고장이 발생될 경우에는 가장 유사한 고장모델을 선택하므로서 잘못된 고장진단을 행할 수 있다. 그러므로 예상하지 못한 고장뿐만 아니라 시스템의 동작 조건에 따라 새로운 고장이 발생될 때에도 이를 분류할 수 있는 수단이 필요하다. 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.

이[10]는 신경회로망기반 다중고장모델을 이용한 고장분류기(fault classifier by neural network-based multi-fault models)를 이용하므로써 신경회로망의 특성에 의해 비선형 시스템의 진단문제에 직접 적용이 가능할 뿐만 아니라 이미 신경회로망 고장모델로 구축된 고장이 발생할 경우에는 고장분류 시간을 단축시킬 수 있으며, 예상하지 않은 새로운 고장이 발생하여도 이를 새로운 고장으로 분류할 수 있는 고장진단 알고리듬을 제안한 바 있다. 그러나 이 알고리듬에서는 고장분류를 위해서 로그공산비를 구해야 하므로 많은 계산량이 요구된다.

본 논문에서는 로그공산비를 구하지 않고 각 신경회로망기반 고장모델과 시스템과의 오차량만으로 고장분류가 가능한 고장진단 방법을 제안한다. 제안한 고장진단 알고리듬은 이[10]의 알고리듬을 기반으로 하므로 비선형시스템에도 적용 가능할 뿐만 아니라 예상하지 않은 새로운 고장이 발생했을 때의 고장분류문제를 동시에 해결할 수 있다. 즉, 고장분류부에서는 신경회로망을 이용한 고장분류기를 이용하므로써 비선형시스템의 진단문제에 직접 적용이 가능할 뿐만 아니라 기존의 Armitage 검증법[11]을 수정하므로서 예상하지 않은 새로운 고장이 발생하여도 이를 새로운 고장으로 분류할 수 있다. 특히 고장분류시 로그공산비를 이용하지 않는 수정된 분류알고리듬을 사용하므로 계산량을 많이 줄일 수 있다. 또한, 고장감지부에서도 고장감지를 위해 신경회로망 공청모델을 사용하므로 비선형시스템의 고장감지문제에 적용이 가능하다. 제안한 고장감지와 분류방법을 비선형시스템의 고장진단문제에 적용하여 성능을 알아보았다.

II. 신경회로망기반 통계적방법에 의한 고장진단 알고리듬

2.1 신경회로망에 의한 고장감지

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

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

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

$$\begin{aligned} y(k+1) &= g_f[y(k), y(k-1), \dots, y(k-n+1), \\ &\quad u(k), u(k-1), \dots, u(k-m+1)] + \varepsilon(k) \end{aligned} \quad (2)$$

여기서 $g_f(\cdot)$ 는 비선형함수로서 고장으로 인해 파라미터가 변한 시스템이다. 시스템에 고장이 발생하면 식 (1)과 같이 표현된 비선형시스템이 식 (2)의 관계로 변화하므로 비선형 시스템 $g_f(\cdot)$ 를 추정하여 이를 분류에 이용한다면 고장의 원인을 알 수 있다. 그러나 고장이 발생될 때마다 $g_f(\cdot)$ 를 추정하여 고장 분류에 이용하는 것은 매우 어렵다. 그러므로 본 논문에서는 고장이 발생하면 변화된 비선형시스템 $g_f(\cdot)$ 를 직접 추정하지 않고, 변화된 시스템과 가장 유사한 신경회로망 고장모델을 결정하므로써 고장을 분류한다. 또한, 본 논문에서는 고장을 분류하기 위해 시스템의 입출력 신호를 이용하므로 입출력 신호를 얻을 수 없는 시스템의 완전파괴 같은 고장은 고려하지 않는다.

최소화 해야 할 성능지수, 시스템 출력과 신경회로망 공청모델 출력사이의 오차를 각각 아래와 같이 정의하며 성능지수를 최소화하는 방향으로 신경회로망을 학습하여 고장감지를 위한 공청모델을 구축한다.

$$J_n(k) = \sum_{i=1}^k e_n^2(i) \quad (3)$$

$$e_n(k) = y(k) - y_n(k) \quad (4)$$

여기서 $y_n(k)$ 는 신경회로망 공청모델의 출력이며, $e_n(k)$ 는 시스템 출력과 공청모델 출력과의 오차이다.

본 논문에서 고장감지를 위한 공청모델 및 신경회로망기반 다중고장모델 고장분류기에서 고장모델을 구성하는 신경회로망의 구조는 그림 1과 같이 다층신경회로망으로서 입력층, 은닉층과 출력층으로 이루어져 있다. 그림 1의 다층 신경회로망으로부터 원하는 입출력 특성을 얻기 위해서는 학습을 행하여야 하는데, 여기에서는 다층 신경회로망의 학습을 위해 일반적으로 많이 이용되는 역전파(back-propagation) 알고리듬[12]을 이용하였으며 자세한 기술은 생략한다.

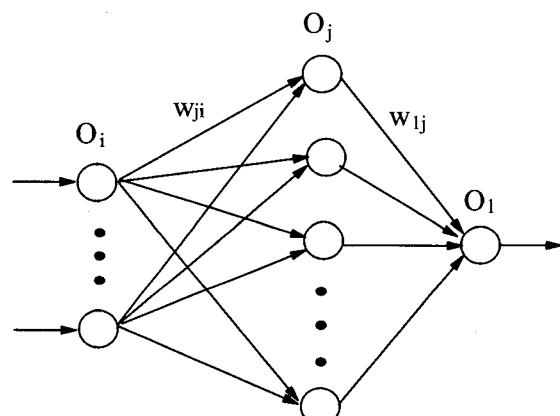


그림 1. 다층 신경회로망의 구조도

Fig. 1. Architecture of the multilayer neural network.

고장감지는 식 (1)으로 표현되는 시스템이 고장으로 인해 식 (2)와 같이 변화하는 순간을 알아내는 것으로서 본 논문에서는 그림 2와 같이 실제 시스템 출력과 신경회로망 공청

모델 출력 사이의 오차를 계산하여 원도우 내에서의 오차가 다음과 같은 조건을 만족하면 고장이 발생된 것으로 인식한다.

$$J_n(k) = \sum_{i=k-L+1}^k e_n^2(i) > \delta_f \quad (5)$$

여기서 δ_f 는 고장감지를 위한 문턱값, L 은 원도우 크기이다. 원도우 크기 L 은 크게 설정하면 고장감지에 대한 신뢰도는 증가하나, 과거의 데이터를 많이 이용하므로써 고장에 빠르게 반응하기가 힘들뿐만 아니라 이로 인해 고장의 분류가 늦어지는 문제가 있다. 반면에 원도우 크기가 너무 작으면 고장에는 빠르게 반응하나 고장감지에 대한 신뢰도가 낮아지므로 적절히 설정한다. 신경회로망 공정모델이 충분히 학습되었다면 시스템 출력과 공정모델 출력사이의 오차는 시스템 잡음과 거의 같은 성질을 가진다[13]. 따라서, 오차 e_n 은 정규분포 $N(0, \sigma^2)$ 를 따르며, 원도우 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.

$$\bar{J}_n(k) = \sum_{i=k-L+1}^k \frac{e_n^2(i)}{\sigma^2} \sim \chi_L^2 \quad (6)$$

고장감지를 위한 문턱값 δ_f 는 잡음만에 의한 허위고장신호 발생확률과 고장이 발생했지만 고장신호를 발생시키지 못하는 확률을 동시에 줄이는 방향으로 설정해야 하나, 대부분의 시스템에서 고장에 의해 변화된 시스템 출력과 신경회로망 공정모델 출력과의 오차는 시스템이 정상일 때 잡음만에 의한 오차에 비해서 클 것이다. 그러므로 본 논문에서는 고장감지 문턱값을 허위고장신호 발생확률을 최대한 줄이는 방향으로 설정한다. 즉, 시스템이 정상일 때 허위고장신호 발생확률의 허용한계를 α 라고 하면

$$\Pr \left(\sum_{i=k-L+1}^k \frac{e_n^2(i)}{\sigma^2} > \delta^o \right) = \alpha \quad (7)$$

이므로 χ^2 분포표로부터 상수 δ^o 를 구한 뒤 이로부터 고장감지를 위한 문턱값 $\delta_f = \sigma^2 \delta^o$ 를 구한다.

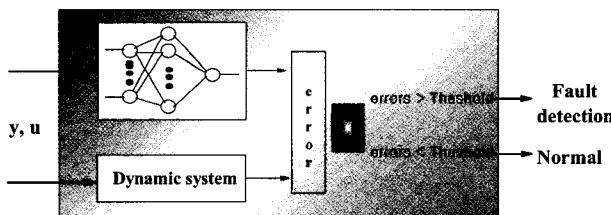


그림 2. 신경회로망에 의한 고장감지

Fig. 2. Fault detection by neural network.

2.2 신경회로망기반 다중고장모델 고장분류기에 의한 고장분류

신경회로망기반 다중고장모델 고장분류기는 그림 3과 같이 신경회로망 고장모델모듈부분, 시스템 출력과 각 고장모델 출력과의 오차를 이용하여 고장의 종류를 결정하는 최종 결정부분으로 이루어져 있다. 고장모델들은 미리 구축하는

것이 아니라 고장분류기의 최종 결정부에서 새로운 고장이 발생된 것으로 분류되면 입출력데이터를 이용하여 새로운 고장에 대한 신경회로망 고장모델을 학습시켜 이를 고장모델 모듈부분에 추가하는 과정을 거치는데 이미 이러한 과정을 거쳐서 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.

$$Y^k = \{ y(i) : i=1, \dots, k \} \quad (8)$$

$$\Lambda_{ji}(k) = \ln \frac{p[Y^k | H_j]}{p[Y^k | H_i]} \quad (9)$$

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 3과 같이 신경회로망으로 구성한다.

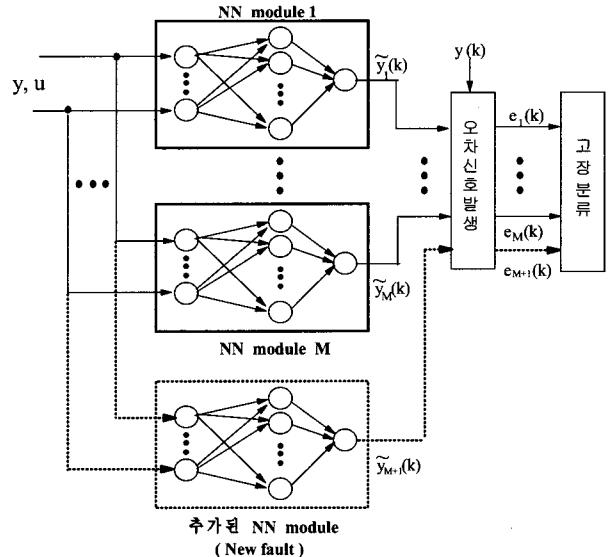


그림 3. 신경회로망기반 다중고장모델을 이용한 고장분류기

Fig. 3. Fault classifier by neural network-based multi-fault models.

식 (9)는 다음과 같은 순환식으로 표현될 수 있으며[14]

$$\Lambda_{ji}(k) = \ln \frac{p[y(k) | Y^{k-1}, H_j]}{p[y(k) | Y^{k-1}, H_i]} + \Lambda_{ji}(k-1) \quad (10)$$

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

$$e_j(k) = y_j(k) - \hat{y}_j(k) \quad (11)$$

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

$$p[e_j(k) | Y^{k-1}, H_j] = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{e_j^2(k)}{2\sigma^2}\right) \quad (12)$$

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

$$p[y(k) | Y^{k-1}, H_j] = \frac{1}{\sqrt{2\pi}\sigma} \exp -\frac{(y(k) - \tilde{y}_j(k))^2}{2\sigma^2} \quad (13)$$

시스템에 발생한 고장분류를 위해 공산함수와 공산비를 이용한 다중 순차적 가설 검증법 중에서 Armitage 검증법 [11]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.

$$T_{ji} = \ln \frac{1 - \sum_{l \neq j} \tilde{e}(l, j)}{\tilde{e}(j, i)} \quad (14)$$

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

그런데, Armitage 검증법은 각 고장모델에 대한 실제 시스템 출력의 공산함수를 계산하고 이로부터 각 고장모델 사이의 로그 공산비를 구해서 현재 시스템의 상태와 가장 유사한 고장모델을 결정하는 상대적인 유사도 검사기법이므로 고장모델로 구축되지 않은 새로운 고장이 발생하면 기존의 고장모델 중에서 가장 유사한 것을 선택하여 이를 시스템의 상태로 결정하는 오 분류를 행하게 된다. 이러한 문제점을 해결하고자 이[10]는 새로운 고장이 발생 시에 일치되는 가설이 없다는 결정을 할 수 있도록 시스템 출력과 각 고장모델 출력사이의 오차제곱을 고려하여 절대적인 유사도를 검사하는 부분을 첨가하여 신경회로망기반 다중고장모델 고장분류기에서 고장이 감지된 후 고장을 분류하는 과정을 아래와 같이 수정한 바 있다.

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

단계 2 : 각 가설에 대한 로그 공산비 $\Lambda_{ji}(k)$ 와 시스템 출력과 각 고장모델 출력사이의 오차제곱합 $\sum_{l=k_j+1}^k (y(l) - \tilde{y}_j(l))^2$ 을 구한다. 만일 $k < k_j + n_f$ 이면 단계 1로 간다. 단, $i, j = 1, 2, \dots, M$, $i \neq j$, $k = k_j + 1, \dots, k_j + n_f$

단계 3 : 다음과 같은 두 조건

$$\Lambda_{ji}(k_f + n_f) \geq T_{ji}, \quad \forall i = 1, \dots, M, i \neq j \quad (15)$$

$$\sum_{l=k_j+1}^{k_f+n_f} (y(l) - \tilde{y}_j(l))^2 \leq r \quad (16)$$

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.

즉, 절대적인 유사도를 검사하는 부분인 식 (16)을 알고리듬에 첨가하므로서 새로운 고장이 발생하면 이를 분류할 수 있도록 하였으며, 발생한 고장이 새로운 고장으로 결정되면 입출력데이터를 이용하여 새로운 고장에 대한 신경회로망 고장모델을 학습시켜서 이를 고장모델부분에 추가한다. 위해서 k_f 는 고장감지 시간, n_f 는 고장이 감지된 뒤 고장분류기가 동작하는 윈도우의 크기이며, T_{ji} 는 문턱값으로서 (14)와 같다. 그리고 r 은 절대유사도 검사를 위한 상수이다. 그런데 이 알고리듬에서도 분류를 위해서 Armitage 검증법에서와 같이 식 (15)와 같은 로그공산비를 구하는 과정이 포함되므로 고장분류를 위한 계산량이 많으므로 계산시간을 감소시키기 위한 분류 알고리듬의 보완이 필요하다.

고장이 감지된 후 주어진 윈도우 크기 (n_f)에서 식 (15)와 (16)을 동시에 만족하는 고장모델이 존재하기 위한 필요충분조건은 정리 1과 같다.

(정리 1)

이미 M 개의 신경회로망기반 다중고장모델이 구축되어 있으며 각 신경회로망 고장모델의 출력과 시스템의 출력사이의 오차는 잡음만에 의한 것이라고 가정하자. k_f 순간에 고장이 감지되고 $k_f + n_f$ 순간에 아래의 조건

$$1) \sum_{l=k_f+1}^{k_f+n_f} (y(l) - \tilde{y}_j(l))^2 \leq r \quad \forall j = 1, \dots, M \quad (17)$$

$$2) \Lambda_{ji}(k_f + n_f) \geq T_{ji} \quad \forall i, j = 1, \dots, M, i \neq j \quad (18)$$

을 만족하는 J 번째 고장모델이 존재하기 위한 필요충분조건은 J 번째 고장모델의 출력이 다음과 같은 두 조건

$$1) \sum_{l=k_f+1}^{k_f+n_f} (y(l) - \tilde{y}_J(l))^2 \leq r, \text{ for } J \quad (19)$$

$$2) \sum_{l=k_f+1}^{k_f+n_f} (y(l) - \tilde{y}_i(l))^2 \geq 2\sigma^2 T_{ji} \\ + \sum_{l=k_f+1}^{k_f+n_f} (y(l) - \tilde{y}_j(l))^2 \quad \forall i = 1, \dots, M, i \neq J \quad (20)$$

을 만족하는 것이다.

증명)

먼저, 식 (20)을 T_{ji} 에 대해 정리하면 아래와 같고

$$-\frac{1}{2\sigma^2} \sum_{l=k_f+1}^{k_f+n_f} (y(l) - \tilde{y}_J(l))^2 + \frac{1}{2\sigma^2} \sum_{l=k_f+1}^{k_f+n_f} (y(l) - \tilde{y}_i(l))^2 \geq T_{ji} \quad (21)$$

식 (15)와 (18)로부터 k_f 순간부터 샘플수 n_f 까지의 로그공산비 $\Lambda_{ji}(k_f + n_f)$ 를 구해보면 다음과 같다.

$$\begin{aligned} \Lambda_{ji}(k_f + n_f) &= \ln \frac{p[y(k_f + n_f) | Y^{k_f+n_f-1}, H_j]}{p[y(k_f + n_f) | Y^{k_f+n_f-1}, H_i]} \\ &\quad + \Lambda_{ji}(k_f + n_f - 1) \\ &= -\frac{1}{2\sigma^2} \sum_{l=k_f+1}^{k_f+n_f} (y(l) - \tilde{y}_J(l))^2 + \\ &\quad \frac{1}{2\sigma^2} \sum_{l=k_f+1}^{k_f+n_f} (y(l) - \tilde{y}_i(l))^2 \end{aligned} \quad (22)$$

결국 식 (21)의 좌변은 $\Lambda_{ji}(k_f + n_f)$ 이므로

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

을 만족한다. 그러므로 식 (19)와 (20)을 만족하는 J 번째 고장모델은 식 (17)과 (18)을 만족한다.

다음으로 식 (17)과 식 (18)을 만족하는 J 번째 고장모델이 존재하면 J 번째 고장모델은 식 (19)와 (20)을 만족한 다를 증명한다. 식 (17)과 (18)을 만족하는 J 번째 고장모델이 존재하므로

$$\sum_{l=k_f+1}^{k_f+n_f} (y(l) - \tilde{y}_j(l))^2 \leq r \quad (23)$$

$$\Lambda_{ji}(k_f + n_f) \geq T_{ji}, \forall i = 1, \dots, M, i \neq J \quad (24)$$

가 성립한다. k_f 순간부터 샘플수 n_f 까지의 로그공산비 $\Lambda_{ji}(k_f + n_f)$ 는 식 (22)와 같고 이를 식 (24)에 대입하여 정리하면 식 (20)

$$\begin{aligned} \sum_{l=k_f+1}^{k_f+n_f} (y(l) - \tilde{y}_i(l))^2 &\geq 2\sigma^2 T_{ji} + \\ \sum_{l=k_f+1}^{k_f+n_f} (y(l) - \tilde{y}_j(l))^2 &\forall i = 1, \dots, M, i \neq J \end{aligned}$$

이 성립한다.

그러므로 정리 1로부터 아래와 같이 고장 분류알고리듬을 수정할 수 있으며, 수정된 알고리듬에서는 로그공산비를 구하지 않고 식 (25)와 (26)과 같이 시스템 출력과 각 고장모델 출력사이의 오차만을 고장분류에 이용하므로 분류시 계산시간을 줄일 수 있다.

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

단계 2 : 시스템 출력과 각 고장모델 출력사이의 오차제곱합 $\sum_{l=k_f+1}^{k_f+n_f} (y(l) - \tilde{y}_j(l))^2$ 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

$$\begin{aligned} \sum_{l=k_f+1}^{k_f+n_f} (y(l) - \tilde{y}_j(l))^2 &\leq -2\sigma^2 T_{ji} + \\ \sum_{l=k_f+1}^{k_f+n_f} (y(l) - \tilde{y}_i(l))^2 &\forall i = 1, \dots, M, i \neq j \quad (25) \end{aligned}$$

$$\sum_{l=k_f+1}^{k_f+n_f} (y(l) - \tilde{y}_j(l))^2 \leq r \quad (26)$$

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.

절대유사도 검사를 위한 상수 r 은 통계적해석에 의해서 설정할 수 있다. 즉, 현재 시스템의 상태가 J 번째 고장모델에 해당한다고 가정하면, J 번째 고장모델의 출력과 시스템 출력사이의 오차 e 는 정규분포 $N(0, \sigma^2)$ 을 따르므로 원도

우 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 갖는다.

$$\sum_{l=k_f+1}^{k_f+n_f} \frac{(y(l) - \tilde{y}_j(l))^2}{\sigma^2} \sim \chi^2_{n_f} \quad (27)$$

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

$$\Pr \left(\sum_{l=k_f+1}^{k_f+n_f} \frac{(y(l) - \tilde{y}_j(l))^2}{\sigma^2} \leq \bar{\delta} \right) = \alpha \quad (28)$$

이므로 χ^2 분포표를 이용하여 상수 $\bar{\delta}$ 를 구한 뒤, 이로부터 $r = \sigma^2 \bar{\delta}$ 을 구한다. 만일 각 고장모델의 유사성이 아주 작을 경우는 α 를 크게 해도 잘못 분류할 가능성이 줄어드나, 유사성이 클 경우에는 α 를 작게하여 r 을 작게 설정해야 한다.

제안한 수정된 분류알고리듬의 장점으로는 먼저 새로운 고장이 발생하면 절대적인 유사도 검사조건에 의해 일치되는 가설이 없다는 결정을 할 수 있다. 다음으로는 기존의 알고리듬에서는 유사도 검사를 위해서는 로그공산비를 구해야 하지만 제안한 방법에서는 로그공산비를 구하지 않고 오차량만으로 검증이 가능하므로 고장분류를 위한 계산량을 많이 줄일 수 있다는 점을 들 수 있다.

III. 시뮬레이션결과 및 고찰

다음과 같은 비선형시스템에 제안한 고장진단 알고리듬을 적용하여 고장감지 및 분류성능을 알아보았다.

$$\begin{aligned} y(k) = &\cos(3.14 p_1) y(k-1) - 0.7 y(k-2) + \\ &u(k-1) + p_2 u(k-2) + \varepsilon(k) \quad (29) \end{aligned}$$

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

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

이며, 시스템의 입력은

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

이다. 그리고 허위고장신호 발생확률을 최대로 줄이기 위해 $\alpha = 0.01$ (1%)로 했으며, (7)로부터 고장감지를 위한 문턱값 δ_f 를 구하면 0.013이며, 여러 번의 시뮬레이션을 통해서 L은 30으로 하였다. 고장감지를 위한 신경회로망 공청모델 및 신경회로망기반 다중고장모델을 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 $\tilde{e}(i, j)$ 는 0.01로 설정했다.

제안한 고장진단 알고리듬의 고장분류성능을 알아보기 위해서 Armitage 검증법에 의한 분류방법과 제안한 분류방법의 결과를 비교하였으며, 두 방법은 모두 신경회로망기반 고장모델을 이용한다. 시스템에서의 예기치 못한 고장상황을 다음과 같이 설정하였다.

고장 #1 : P_1 이 감소

고장 #2 : P_1 이 증가

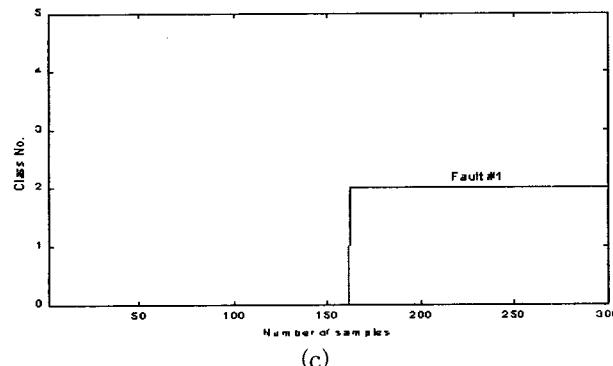
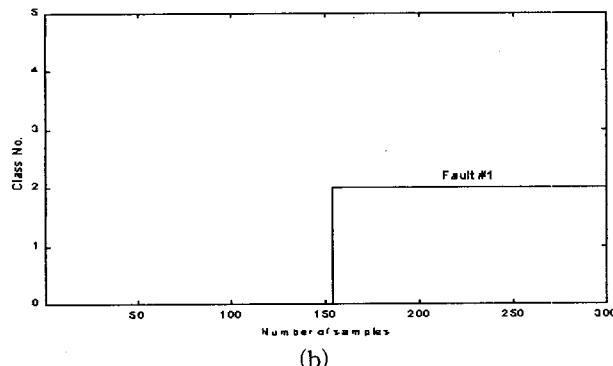
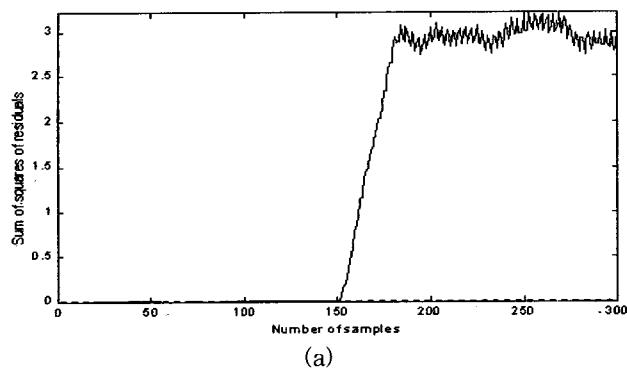


그림 4. 고장 #1에 대한 고장감지와 분류결과

- (a) J_n 의 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

그림 4는 이미 고장 #1($P_1 = 0.4$ 로 감소)이 발생하여 두 개의 신경회로망 고장모듈(고장모델 1은 시스템이 정상상태인 경우, 고장모델 2는 고장 #1에 대한 모델)이 구축된 뒤 다시 150번째 순간에 고장 #1이 발생했을 때의 오차의 변화 및 분류 결과이다. 4(a)로부터 152번째 순간에 원도우 내에서 시스템출력과 공정모델과의 자승오차합이 고장감지 문턱값을 넘어 고장을 감지하였음을 알 수 있다. 그리고 4(b)는 Armitage 검증법에 의한 분류결과를 도시한 것으로서 현재

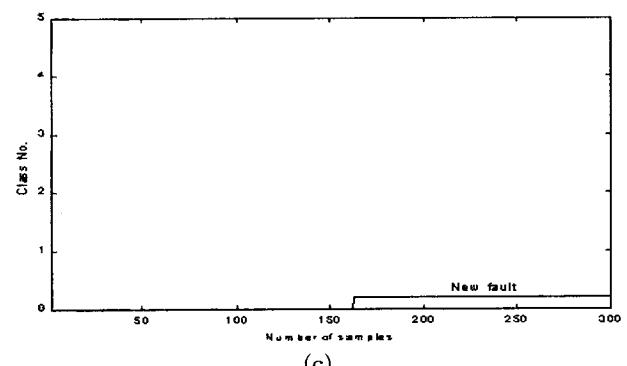
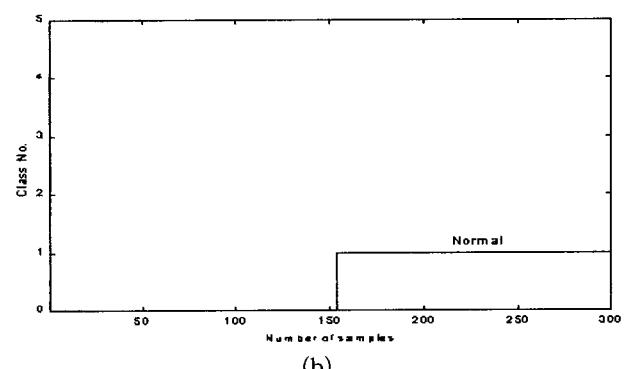
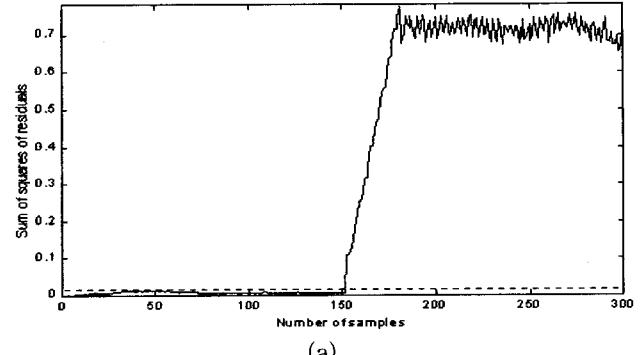


그림 5. 고장 #2에 대한 고장감지와 분류결과

- (a) J_n 의 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

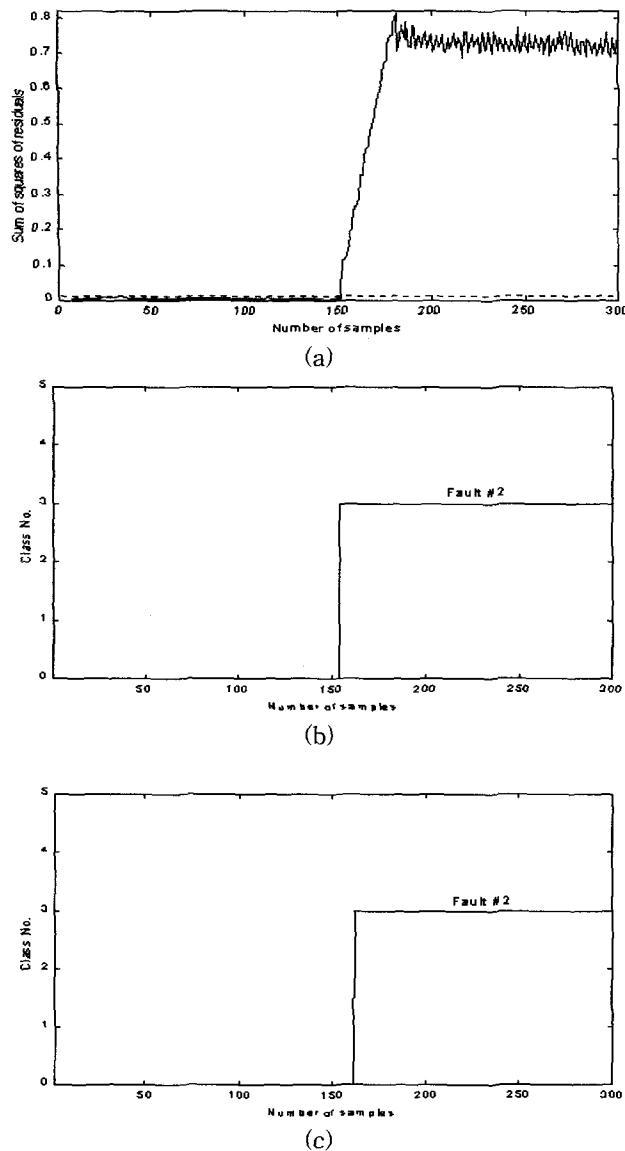


그림 6. 고장 #2에 대한 고장감지와 분류결과
 (a) J_n 의 변화와 고장감지(점선: δ_f)
 (b) Armitage 방법에 의한 분류결과
 (c) 제안한 방법에 의한 분류결과

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

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.

그림 5(a)는 150번째에 고장모델로 구축되지 않은 새로운 고장 #2($P_1 = 0.7$ 로 증가)가 발생했을 때의 윈도우 내에서 자승오차합의 변화를 도시한 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 의해 일치되는 고장모델이 없음을 선언하고 새로운 고장으로 인식함을 알 수 있다. 그림 6은 고장#2에 대한 신경회로망 고장모델 3이 추가된 뒤 고장 #2의 한 형태인 $P_1 = 0.8$ 로 증가하는 고장이 발생했을 때의 고장감지 및 분류결과로서 그림 6(a)에 도시된 바와 같이 152번째 순간에 고장을 감지하였으며, Armitage 검증법에 의한 분류결과인 6(b)와 제안한 고장분류기에 의한 분류결과인 6(c)로부터 시스템에 고장 #2가 발생되었음을 알 수 있다.

IV. 결론

본 논문에서는 비선형시스템에서의 고장진단을 위해 신경회로망을 이용한 고장감지방법과 신경회로망기반 다중고장모델 고장분류기에 의한 고장분류방법을 제안하였다. 제안한 방법에서는 비선형함수의 묘사가 가능한 신경회로망을 고장감지 및 분류를 위한 고장분류기에 이용하므로써 비선형시스템의 고장진단문제에 직접 적용이 가능할 뿐만 아니라 새로운 고장이 발생할 경우에는 새로운 고장클래스로 분류가 가능하다. 특히, 제안한 고장진단알고리듬에서는 실제 시스템의 출력과 각 고장모델과의 로그공산비를 구하지 않고 오차량만으로 고장분류가 가능하므로 분류를 위한 계산량을 많이 줄일 수 있다는 장점이 있다.

컴퓨터 시뮬레이션을 통해서 제안한 고장진단 알고리듬이 비선형시스템에서 발생되는 고장을 정확하게 분류할 뿐만 아니라 예상하지 못한 새로운 고장이 발생한 경우에도 이를 새로운 고장으로 분류함을 알 수 있다.

참고 문헌

- [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] 이인수, "신경회로망기반 다중고장모델에 의한 비선형시스템의 고장감지와 분류", 대한전자공학회 논문집, vol. 39-S, no. 1, pp.42-50, 2002.
- [11] 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.
- [12] D. E. Rumelhart and J. L. McClelland, Parallel distributed processing: explorations in the microstructure of cognition. vol. 1, MIT Press, Reading, MA, 1986.
- [13] J. D. Cryer, Time Series Analysis, Duxbury Press, 1986.
- [14] A. P. Sage and J. L. Melsa, Estimation Theory with Applications to Communications and Control, McGraw-Hill, 1971.

저자 소개



이인수

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

관심분야 : 시스템의 고장진단 및 고장허용제어, 지능제어 및
응용등이다.

E-mail : islee@sangju.ac.kr



조원철

1964년 2월 7일생
1986년 경북대학교 전자공학(공학사)
1989년 동대학원 졸업(공학석사).
1997년 동대학원 졸업(공학박사).
1997년~ 현재 경상북도립 경도대학 전자
과 조교수.

관심분야 : 적응제어, 뉴로퍼지제어등이다.