

신경회로망기반 다중고장모델에 의한 비선형시스템의 고장진단

이인수

상주대학교 전자전기공학부

(Tel : 054-530-5324; Fax : 054-530-5320; E-mail : islee@sangju.ac.kr)

Fault Diagnosis of the Nonlinear Systems Using Neural Network-Based Multi-Fault Models

In Soo Lee

School of Electronics and Electrical Engineering, Sangju National University

(Tel : 054-530-5324; Fax : 054-530-5320; E-mail : islee@sangju.ac.kr)

Abstract

In this paper we propose an FDI(fault detection and isolation) algorithm using neural network-based multi-fault models to detect and isolate single 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.

I. 서론

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.

기존의 고장감지 및 분류(FDI : fault detection and isolation)방법은 크게 모델에 근거한 방법과 모델에 근거하지 않는 방법으로 분류할 수 있다. 먼저, 모델에 근거한 방법은 시스템의 수학적 모델에 의해 제공되는 해석적인 기법을 기초로 하는 것으로서 고장진단을 위해서는 시스템의 정확한 정량적모델이 필요하므로 불확실성이 존재하고 비선형성이 강한 시스템에는 적용이 어렵다는 문제점이 있으며 이를 극복할 수 있는 연구가 필요하다.

다음으로, 모델에 근거하지 않는 방법은 대상 시스템의 측정치, 경험 또는 물리적 검토를 기초로 하며, 시스템의 출력값이 제한된 범위를 벗어난지의 유무로써 고장을 감지해내는 한계치 검사, 전문가 시스템 기법 및 신경회로망을 이용한 방법[1-4]등이 있으며, 최근에는 학습의 기능 및 입출력데이터로부터 비선형함수 표현이 가능한 장점이 있는 신경회로망을 고장진단에 이용한 연수결과가 많이 발표되고 있다. 그러나, 신경회로망을 이용한 대부분의 연구에서는 고장을 일종의 패턴으로 간주하여 신경회로망을 미리 획득한 고장패턴으로 학습을 시킨 뒤 고장을 분류하고 있으나, 사전에 모든 고장에 대한 학습 데이터를 얻기가 힘들다는 단점이 있다

[5]. 즉, 예상되지 않은 고장뿐만 아니라 시스템의 동작 조건에 따라 새로운 고장이 발생할 수 있으므로, 이러한 것을 다루기 위해서 패턴 분류기는 분류되어야 할 입력 패턴들을 적응적으로 구별해 내는 것이 필요하며, 이에 대한 해결책으로 자율신경회로망인 ART 신경회로망을 이용하는 연구[6]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 고장의 분류문제와 고장 분류시간의 단축문제를 동시에 해결할 수 있는 고장감지와 분류 알고리즘을 제안한다. 고장분류부에서는 신경회로망기반 다중고장모델을 이용한 고장분류기(fault classifier by neural network-based multi-fault models)를 이용하므로써 이미 신경회로망 고장모델로 구축된 고장이 발생할 경우에는 고장분류 시간을 단축시킬 수 있을 뿐만 아니라 신경회로망의 특성에 의해 비선형시스템의 진단문제에 직접 적용이 가능하다. 그리고, 고장감지부에서는 신경회로망을 고장감지를 위한 공칭모델로 사용함으로써 비선형시스템의 고장진단문제에 적용이 가능하다. 제안한 고장감지와 분류 알고리즘을 비선형시스템의 고장진단문제에 적용하여 성능을 알아보았다.

II. 신경회로망을 이용한 고장진단알고리즘

2.1 신경회로망

본 논문에서 고장감지를 위한 공칭모델 및 고장분류기를 구성하는 신경회로망의 구조는 그림 1과 같이 다층신경회로망이며 입력층, 중간층과 출력층으로 이루어져 있다. 신경회로망의 학습방법은 일반적으로 많이 사용되는 역전파(back-propagation) 알고리즘을 이용하며 신경회로망을 학습시키기 위한 성능함수는 다음과 같다.

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

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

$$\delta_1 = -\frac{\partial E}{\partial net_1} = (d(t) - O_1(t)) \cdot f'(net_1) \quad (2)$$

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




그림 1. 다층 신경회로망의 구조도

은닉층과 출력층사이의 가중치에 대한 오차함수의 기울기와 가중치는 각각

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

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

로 개선이 된다. 여기서 w_{ij} 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.

$$\begin{aligned} \delta_i &= -\frac{\partial E}{\partial O_i} \cdot \frac{\partial O_i}{\partial net_i} \\ &= \delta_1 \cdot w_{ij} \cdot f'(net_i) \end{aligned} \quad (5)$$

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

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

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

2.2 고장감지

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

$$y(k+1) = g[y(k), y(k-1), \dots, y(k-n+1),$$

$$u(k), u(k-1), \dots, u(k-m+1)] + \epsilon(k)$$

(8) 여기서 $u(k)$, $y(k)$ 는 각각 시스템의 입력과 출력, $g(\cdot)$ 의 비선형함수이며, $\epsilon(k)$ 는 백색 잡음이라고 가정한다. 그림 1과 같은 신경회로망을 이용하여 비선형시스템을 모사하여 공칭모델로 만든다. 최소화 해야할 성능지수, 출력오차와 신경회로망 공칭모델출력사이의 오차를 각각 아래와 같이 정의하며 식 (9)를 최소화하는 방향으로 신경회로망을 학습하여 고장감지를 위한 공칭모델을 구축한다.

$$J_n(k) = \sum_{i=1}^L e_n^2(i) \quad (9)$$

$$e_n(k) = y(k) - y_n(k) \quad (10)$$

여기서 y_n 은 신경회로망 공칭모델의 출력이다.

본 논문에서는 실제 시스템 출력과 신경회로망 공칭모델 출력사이의 오차를 계산하며, 윈도우 내에서의 오차가 다음과 같은 조건을 만족하면 고장이 발생된 것으로 인식한다.

$$J_n(k) = \sum_{i=k-L+1}^k e_n^2(i) > \delta_f \quad (11)$$

여기서 $e_n(i)$ 는 시스템 출력과 공칭모델 출력과의 오차이고, δ_f 는 고장감지를 위한 문턱값, L 은 윈도우 크기이다. 공칭모델이 충분히 학습되었다면 시스템 출력과 공칭모델 출력사이의 오차는 시스템 잡음과 거의 같은 성질을 가진다[7]. 따라서, 시스템 출력과 공칭모델 출력사이의 오차 e_n 은 정규분포 $N(0, \sigma^2)$ 를 따르므로 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.

$$\bar{J}_n(k) = \sum_{i=k-L+1}^k \frac{e_n^2(i)}{\sigma^2} \sim \chi_L^2 \quad (12)$$

본 논문에서는 고장감지를 위한 문턱값 δ_f 를 허위고장신호 발생확률을 최대한 줄이는 방향으로 설정한다. 즉, 시스템이 정상일 때 허위고장신호 발생확률의 허용한계를 α 라고 하면

$$\Pr\left(\sum_{i=k-L+1}^k \frac{e_n^2(i)}{\sigma^2} > \delta^0\right) = \alpha \quad (13)$$

이므로 χ^2 분포표로부터 상수 δ^0 를 구한 뒤 이로부터 고장감지를 위한 문턱값 $\delta_f = \sigma^2 \delta^0$ 를 구한다.

2.3 신경회로망기반 다중고장모델을 이용한 고장분류

신경회로망기반 다중고장모델을 이용한 고장분류 그림 2와 같이 신경회로망 고장모델모델부분, 시스템 출력과 각 가설에 대한 고장모델 출력과의 오차를 발생시키고 통계적 분석(statistical analysis)을 하는 부분 및 최종 결정부분으로 이루어져 있으며, 이미 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.

$$Y^k = \{y(i) : i=1, \dots, k\} \quad (14)$$

$$\Lambda_{ji}(k) = \ln \frac{p[Y^k | H_j]}{p[Y^k | H_i]} \quad (15)$$

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 신경회로망으로 구성한다.

식 (15)는 다음과 같은 순환식으로 표현될 수 있으며[8]

$$\Lambda_{ji}(k) = \ln \frac{p[y(k) | Y^{k-1}, H_j]}{p[y(k) | Y^{k-1}, H_i]} + \Lambda_{ji}(k-1) \quad (16)$$

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

$$e_j(k) = y_j(k) - \tilde{y}_j(k) \quad (17)$$

신경회로망기반 다중고장모델에 의한 비선형시스템의 고장진단

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

$$p[e_j(k) | Y^{k-1}, H_j] = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{e_j^2(k)}{2\sigma^2}\right) \quad (18)$$




그림 2. 신경회로망기반 다중고장모델 고장분류기 정으로부터 가설 H_j 에 대한 $y(k)$ 의 확률밀도함수는 아래와 같다.

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

시스템에 발생한 고장분류를 위해 공산함수와 공산비를 이용한 다중 순차적 가설 검증법 중에서 Armitage 검증법[9]을 이용할 수 있다. 그러나 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 오 분류를 행하게 된다. 그러므로 본 논문에서는 새로운 고장이 발생시에 일치되는 가설이 없다는 결정을 할 수 있도록 시스템 출력과 각 고장모델 출력사이의 오차제곱을 고려하여 절대적인 유사도를 검사하는 부분 식 (20)을 첨가했다. 제안한 신경회로망 다중고장모델 분류기에서의 고장 감지 후 고장 분류 과정은 아래와 같다.

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

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

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

$$\Lambda_{\tilde{y}_i}(k_f + n_f) \geq T_{\tilde{y}_i}, \quad \forall i = 1, \dots, M, i \neq j \quad (20)$$

$$\sum_{l=k_f+1}^{k_f+n_f} (y(l) - \tilde{y}_j(l))^2 \leq r \quad (21)$$

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.

$T_{\tilde{y}_i}$ 는 문턱값으로서 아래와 같이 결정된다.

$$T_{\tilde{y}_i} = \ln \frac{1 - \sum_{j \neq i} \tilde{e}(l, j)}{\tilde{e}(j, i)} \quad (22)$$

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

위 3단계 고장분류 과정에서 k_f 는 고장감지 시간, n_f 는 고장이 감지된 뒤 고장분류기가 동작하는 윈도우의 크기이고 r 은 절대유사도 검사를 위한 상수로서 다음과 같이 구한다.

현재 시스템의 상태가 J 번째 고장모델에 해당한다고 가정하면 J 번째 고장모델의 출력과 시스템 출력사이의 오차 e 는 정규분포 $N(0, \sigma^2)$ 을 따른다. 그러므로 윈도우 내에서의 n_f 개의 정규화된 자승오차의 합은 자유도가 n_f 인 $\chi^2_{n_f}$ 분포를 따른다

$$\sum_{l=k_f+1}^{k_f+n_f} \frac{(y(l) - \tilde{y}_J(l))^2}{\sigma^2} \sim \chi^2_{n_f} \quad (23)$$

윈도우 내에서의 n_f 개의 정규화된 자승오차의 합이 $\bar{\delta}$ 이하가 될 확률을 α 라고 하면

$$\Pr\left(\sum_{l=k_f+1}^{k_f+n_f} \frac{(y(l) - \tilde{y}_J(l))^2}{\sigma^2} \leq \bar{\delta}\right) = \alpha \quad (24)$$

이므로 상수 $r = \sigma^2 \bar{\delta}$ 로 구할 수 있다.

III. 시뮬레이션결과 및 고찰

제안한 고장진단알고리즘의 고장감지 및 분류능력을 알아보기 위해 아래와 같은 비선형시스템을 고려한다.

$$y(k) = \cos(3.14 p_1) x(k-1) - 0.7 y(k-2) + u(k-1) + p_2 u(k-2) + \varepsilon(k) \quad (25)$$

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.

$$p_1 = 0.56, p_2 = 0.37 \quad (26)$$

또한 입력은

$$u(k) = 0.5 \cos(k) \quad (27)$$


이며, 고장감지를 위한 δ_f 및 L 은 각각 0.013 및 30으로 설정하였다. 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 $T_{\tilde{y}_i}, r$ 및 n_f 는 각각 4.58, 0.004 및 10이며 $\tilde{e}(i, j)$ 는 0.01로 설정했다. 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 정상상태를 포함한 두개의 신경회로망 고장모델이 구축된 뒤 테스트한 결과이다. 고장 #1의 한 경우로서 $P_1 = 0.8$ 로 증가했을 때의 오차의 변화 및 분류 결과가 그림 3과 같다. 3(a)로부터 152번째 순간에 고장을 감지하였음을 알 수 있다. 3(b)는 제안한 신경회로망기반 다중고장모델을 이용한 고장분류기에 의한 분류결과


로서 고장 #1으로 분류함을 알 수 있다. 그림 4(a)는 150번째에 새로운 고장 #2($P_1 = 0.4$ 로 감소)이 발생했을 때의 윈도우 내에서 자승오차합의 변화이며, 4(c)로부터 제안한 고장분류기의 경우 새로운 고장으로 인식함을 알 수 있다. 그림 5는 고장#2에 대한 신경회로망 고장모델이 추가된 뒤 고장 #2에 대한 분류결과로서 5(b)로부터 고장 #2가 발생되었음을 알 수 있다.




(a) J_n 변화와 고장감지(점선: δ_f)




(b) 제안한 고장분류기에 의한 분류결과
그림 3. 고장 #1에 대한 고장감지와 분류결과




(a) J_n 변화와 고장감지(점선: δ_f)



(b) 제안한 고장분류기에 의한 분류결과
그림 4. 고장 #2에 대한 고장감지와 분류결과



(a) J_n 변화와 고장감지(점선: δ_f)



(b) 제안한 고장분류기에 의한 분류결과
그림 5. 고장 #2에 대한 고장감지와 분류결과

IV. 결론

본 논문에서는 비선형시스템의 고장감지와 분류를 위한 진단 알고리즘을 제안하였으며, 이 방법은 새로운 고장이 발생하는 경우에도 적용할 수 있다. 제안한 고장진단 알고리즘의 특징으로는 먼저, 비선형함수의 묘사가 가능한 신경회로망을 고장모델로 사용하여 고장분류기를 구성하므로 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 입력력데이터로부터 신경회로망 고장모델들을 구축하여 고장모델부에 단순히 추가만 하면 된다.

참고문헌

- [1] 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.
- [2] 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.
- [3] 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.
- [4] 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.
- [5] 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.
- [6] 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.
- [7] J. D. Cryer, *Time Series Analysis*, Duxbury Press, 1986.
- [8] A. P. Sage and J. L. Melsa, *Estimation Theory with Applications to Communications and Control*, McGraw-Hill, 1971.
- [9] I. Jouny and F. D. Garber, "M-ary sequential hypothesis tests for automatic target recognition," *IEEE Trans. Aerosp. Electron. Syst.*, vol. 28, pp. 473-483, 1992.