

감독/무감독 신경회로망을 이용한 비선형 시스템의 고장진단

유두형, *김광태*, *이인수

* 상주대학교 전자전기공학부

전화 : 054-530-5324 / 핸드폰 : 017-9771-1496

A Fault Diagnosis of Nonlinear Systems Using Supervised/Unsupervised Neural Networks

Du Hyoung Yu, Kwang Tae Kim, In Soo Lee

School of Electronics and Electrical Engineering, Sangju National University

E-mail : rdh123@hanmir.com

Abstract

Neural network-based fault diagnosis algorithm to detect and isolate faults in the nonlinear systems is proposed. In the proposed method, the fault is 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 system outputs are transferred to the fault classifier by ART2 NN (adaptive resonance theory 2 neural network) for fault isolation. 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. 서론

시스템이 방대하고 복잡해지며 많은 공정이 자동화됨에 따라 시스템의 신뢰성 및 안전성 유지에 대한 관심이 고조되고, 각 시스템을 이루는 요소의 동작 신뢰성을 높여 시스템의 오동작을 방지하는 일이 매우 중요한 위치를 차지하게 되었으며, 이를 위한 고장진단 기법에 관한 연구가 활발히 이루어지고 있다.

최근에 신경회로망을 고장진단에 이용한 연구[1,2] 결과가 많이 발표되고 있으나, 대부분의 연구에서 미리 구축한 고장모델 중에서 가장 유사한 고장모델을 선택하여 고장을 분류하지만 사전에 모든 고장모델을 구축하는 것은 매우 어렵다. 특히 예측되지 않은 새로운 고장이 발생할 경우에 가장 유사한 고장모델을 선택함으로써 잘못된 고장진단을 행한다. 그러므로, 예측치 않은 새로운 고장이 발생할 때에도 이를 분류할 수 있는 수단이 필요하여 ART(adaptive resonance theory) 신경회로망을 이용하는 연구[3]가 있으나, 파라미터 추정시간으로 인해 고장분류 시간이 지연된다는 문제점이 있다.

본 논문에서는 비선형 시스템에도 적용 가능하고 예측하지 않은 새로운 고장이 발생했을 때의 고장분류 및 고장 분류 시간 단축 문제를 동시에 해결할 수 있는 신경회로망을 이용한 고장 감지와 분류 방법을 제안한다. 제안된 고장 진단 알고리즘에서는 신경회로망기반 다중고장모델과 ART2 신경회로망을 이용한 고장분류기로 고장을 분류하므로 비선형 시스템의 진단 문제에 직접 적용이 가능하고 예측하지 않은 새로운 고장이 발생하여도 이를 새로운 고장으로 분류할 수 있다. 특히 통계적기법[4]에 비해 고장 분류 시간을 단축시킬 수 있다. 그리고, 고장감지부에서도 신경회로망을 고장 감지를 위한 공칭모델로 사용함으로써 비선형 시스템의 고장감지 문제에 적용이 가능하다.

II. 신경회로망을 이용한 고장감지 및 분류 알고리즘

제안된 신경회로망을 이용한 고장 감지 및 분류기는 그림 2-1과 같이 다중 신경회로망을 이용한 고장감지부와 신경회로망 기반 고장모델과 ART2 신경 회로망을 이용한 고장분류부로 구성된다.




그림 2-1. 신경회로망을 이용한 고장 감지 및 분류기의 구조

1. 신경회로망 (1) 다중 신경회로망

본 논문에서 고장감지를 위한 공칭모델 및 ART2 신경회로망 고장분류기의 다중고장모델부를 구성하는 신경회로망의 구조는 그림 2-2와 같이 다중신경회로망으로서 입력층, 중간층과 출력층으로 이루어져 있다.




그림 2-2. 다중 신경회로망의 구조도

다중 신경회로망으로부터 원하는 입출력 특성을 얻기 위해서는 학습을 행하여야 하는데 오차 역전파 학습알고리즘(back-propagation algorithm)[5]을 이용하여 가중치를 변화시킴으로 이루어지며, 신경회로망을 학습시키기 위한 성능함수는 다음과 같이 정의한다.

$$E = \frac{1}{2} (d(t) - O_j(t))^2 \quad (2.1)$$

여기서 $d(t)$ 와 $O_j(t)$ 는 목표값 및 실제 신경회로망의 출력노드에서의 출력값이다.

출력노드에서 오차신호는 다음과 같다.

$$\delta_j = -\frac{\partial E}{\partial net_j} = (d(t) - O_j(t)) \cdot f'(net_j) \quad (2.2)$$

여기서 net_j 는 출력노드의 입력, $f(\cdot)$ 는 시그모이드 함수의 미분이다. 은닉층과 출력층 사이의 가중치에 대한 오차함수의 기울기와 가중치는

$$\Delta w_{ij} = -\eta \cdot \frac{\partial E}{\partial w_{ij}} = \eta \cdot \delta_j \cdot O_i \quad (2.2)$$

$w_{ij}(t+1) = w_{ij}(t) + \Delta w_{ij} + \alpha \cdot (w_{ij}(t) - w_{ij}(t-1))$ (2.4)로 개선된다. η 는 학습률, α 는 학습속도 개선을 위한 모멘텀 항이며 O_j 는 j 번째 은닉노드에서 출력값이다. 마찬가지로, j 번째 은닉노드에서 오차신호 및 입력층과 은닉층 사이의 가중치의 조정은 각각 다음과 같다.

$$\delta_i = -\frac{\partial E}{\partial O_i} \cdot \frac{\partial O_i}{\partial net_i} = \delta_j \cdot w_{ij} \cdot f'(net_i) \quad (2.5)$$

$$\Delta w_{ji} = -\eta \cdot \frac{\partial E}{\partial w_{ji}} = \eta \cdot \delta_i \cdot O_j \quad (2.6)$$

$$w_{ji}(t+1) = w_{ji}(t) + \Delta w_{ji} + \alpha \cdot (w_{ji}(t) - w_{ji}(t-1)) \quad (2.7)$$

(2) ART2 신경회로망

ART2 신경회로망은 그림 2-3과 같이 저장된 패턴과 유사한 입력에 대하여 반응하여 이를 학습하기 위한 계층1과 저장된 패턴과 유사성이 없는 패턴이 입력될 경우, 계층1을 차단하고 새로운 클래스를 생성시키는 계층2로 구성된다. 계층1은 입력층과 출력층을 가지는 두 층 신경회로망으로 구성되며, 입력층과 출력층 노드들은 학습 패턴들이 기억되는 가중치로 연결되어 있다. 최초의 입력 패턴이 ART2 신경회로망에 전달되면 출력층에는 생성된 클래스가 없으므로 첫 번째 클래스로 분류하고 입력패턴을 첫 번째 출력노드와 입력노드들 사이의 가중치에 저장한다. 다음에 다른 패턴이 입력되면 첫 번째 클래스와의 유사성을 검사하여 같은 클래스로 학습하거나 새로운 클래스를 생성한다.

현 시점에서 이미 M 개의 클래스가 분류 알고리즘에 의해서 생성되어 있다고 가정하고 분류 과정을 단계별




그림 2-3. ART2 신경회로망의 구조도

로 기술하면 다음과 같다. 이때 저장된 M 개의 패턴을 각 클래스의 템플릿패턴이라고 하며 신경회로망의 N 차원의 입력벡터와 j 번째 출력노드에 대한 N 차원의 가중치벡터를 각각 X 와 V_j 로 표현한다.

단계 1 : 새로운 패턴이 입력되면, MINNET (minimum net)이 입력 패턴과 각 출력노드와의 거리를 다음과 같이 계산하여, 거리가 최소인 출력노드를 선택하여 승리노드라고 하며 J 로 표시한다.

$$d_j = \| V_j - X \| \quad j = 1, 2, \dots, M \quad (2.8)$$

여기서 $\| \cdot \|$ 은 임의의 놈(norm)이다.

단계 2 : 승리노드 J 의 거리가 경계인수조건을 만족하면 경계인수검사를 통과하여 단계 4로 가며, 그렇지 못하면 단계 3으로 간다.

$$\text{경계인수조건 : } \| V_J - X \| < \rho \quad (2.9)$$

여기서 경계인수 ρ 는 각 클래스의 분류 반경을 결정하는 값이다. 승자 클래스의 중심 반경 ρ 이내에 들어오면 입력 패턴은 승자 클래스와 유사한 패턴임을 의미하며 입력 패턴을 승자 클래스에 포함시키고 노드의 중심값을 수정한다.

단계 3 : 만약 입력 패턴이 승자 클래스의 중심 반경보다 크면 입력 패턴은 기존의 클래스와는 다른 패턴임을 의미하여 새로운 클래스 k 가 만들어지며, 이때 가중치는 $V_k = X$ 가 된다.

단계 4 : 승리노드 J 의 가중치는 다음과 같이 조정된다.

$$V_J^{new} = \frac{X + V_J^{old} \| class_j^{old} \|}{\| class_j^{old} \| + 1} \quad (2.10)$$

여기서 V_J^{old} 와 V_J^{new} 는 J 번째 출력 노드에서의 조정 전후의 가중치 벡터이며, $[class_i]$ 는 클래스 i 에 속한 패턴들의 개수를 의미한다.

단계 5 : 모든 입력이 제시될 때까지 위 과정을 반복한다.

2. 고장감지

본 논문에서는 고장진단을 위한 대상 시스템을 다음과 같은 이산 시간 비선형 시스템으로 가정한다.

$$y(k+1) = g[y(k), y(k-1), \dots, y(k-n+1), u(k), u(k-1), \dots, u(k-m+1)] + \epsilon(k) \quad (2.11)$$

고장으로 인한 비선형 시스템은 다음과 같이 표현할 수 있다.

$$y(k+1) = g_f[y(k), y(k-1), \dots, y(k-n+1), u(k), u(k-1), \dots, u(k-m+1)] + \epsilon(k) \quad (2.12)$$

여기서 $g_f(\cdot)$ 는 비선형 함수로서 고장으로 인해 파라미터가 변한 시스템이다.

최소화 해야할 성능지수, 시스템 출력과 신경회로망

공칭모델 출력사이의 오차를 각각 다음과 같이 정의하며 식(2.13)을 최소화하는 방향으로 신경회로망을 학습하여 고장감지를 위한 공칭모델을 구축한다.

$$J_n(k) = \sum_{i=1}^k e_n^2(i) \quad (2.13)$$

$$e_n(k) = y(k) - y_n(k) \quad (2.14)$$

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 원도 내에서의 오차가 다음과 같은 조건을 만족하면 고장이 발생된 것으로 인식한다.

$$J_n(k) = \sum_{i=k-L+1}^k e_n^2(i) > \delta_f \quad (2.15)$$

여기서 δ_f 는 고장감지를 위한 문턱값, L 은 원도 크기이다. 공칭모델이 충분히 학습되었다면 시스템 출력과 공칭모델 출력사이의 오차는 시스템 잡음과 거의 같은 성질을 가진다[6]. 따라서, 오차 e_n 은 정규분포 $N(0, \sigma^2)$ 를 따르며, 원도 내에서의 L 개의 정규화된 자승오차 $\frac{e_n^2(i)}{\sigma^2}$ 의 합은 다음과 같이 자유도가 L 인 χ^2 (chi-square)분포를 따르게 된다.

$$\bar{J}_n(k) = \sum_{i=k-L+1}^k \frac{e_n^2(i)}{\sigma^2} \sim \chi^2_L \quad (2.16)$$

대부분의 시스템에서 고장에 의한 시스템 파라미터의 변화는 크며 이로 인한 시스템 출력과 신경회로망 공칭모델 출력과의 오차는 시스템이 정상일 때 잡음만에 의한 오차에 비해서 클 것이므로 본 논문에서는 고장감지를 위한 문턱값 δ_f 를 허위고장신호 발생 확률을 최대한 줄이는 방향으로 설정한다. 시스템이 정상일 때 허위고장신호 발생 확률의 허용한계를 α_1 라고 하면

$$\Pr \left(\sum_{i=k-L+1}^k \frac{e_n^2(i)}{\sigma^2} > \delta^\circ \right) = \alpha_1 \quad (2.17)$$

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

3. ART2 신경회로망과 신경회로망기반 다중고장모델에 의한 고장분류

고장분류기는 그림 2-4와 같이 ART2 신경회로망 고




그림 2-4. 신경회로망 고장분류기의 구조

장분류기와 다중 신경회로망기반 다중고장모델부로 이

루어져 있다. 고장모델들은 미리 구축하는 것이 아니라 고장분류기의 최종 결정부에서 새로운 고장이 발생된 것으로 인식되면 입력력 데이터를 이용하여 새로운 고장에 대한 신경회로망 고장모델을 학습시켜서 이를 고장모델모듈 부분에 추가하는 과정을 거치는데 이미 M 개의 고장모델이 구축되어 있다고 가정하고 분류 과정을 기술한다. 제안된 고장분류기에서 고장이 감지된 후 고장을 분류하는 과정은 다음과 같다.

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

단계 2 : 만 $k = k_j + n_j$ 이면 j 번째 신경회로망 고장모델의 출력 $\bar{y}_j(k)$ 을 ART2 신경회로망의 가중치 V_j 에 다음과 같이 저장하고

$$V_j = [\bar{y}_j(k_j+1), \bar{y}_j(k_j+2) \dots \bar{y}_j(k_j+n_j)] \quad (2.18)$$

ART2 신경회로망의 각 출력노드와 입력 $X = [y(k_j+1), \dots, y(k_j+n_j)]$ 의 거리 $d_j = \|V_j - X\|_2$ 를 계산한다. 만일 $k < k_j + n_j$ 이면 단계 1로 간다. 단, $j=1, 2, \dots, M$ 이고, $k=k_j+1, \dots, k_j+n_j$ 이다. k_j 는 고장 감지 시간, n_j 는 고장 감지 후 고장분류기가 동작하는 원도의 크기이다.

단계 3 : 다음과 같은 조건

$$\min \|V_j - X\| < \rho \quad (2.19)$$

을 만족하면 그 출력노드가 시스템에서 발생한 고장과 일치된 것으로 결정한다. 그렇지 않으면 새로운 고장 클래스가 만들어지며 이는 새로운 고장이 발생되었음을 의미하며 새로운 고장에 대한 신경회로망 고장모델을 만들어 추가한다.

고장분류기에서 새로운 고장 상황으로 결정되면 입력력데이터를 이용하여 새로운 고장에 대한 신경회로망 고장모델을 학습시켜서 이를 고장모델모듈 부분에 추가한다. ρ 는 고장 분류를 위한 경계인수로 다음과 같이 설정한다.

$$\rho = \sqrt{\delta_f} \quad (2.20)$$

III. 시뮬이션 결과 및 고찰

제안된 신경회로망에 의한 고장진단 알고리즘을 다음과 같은 비선형 시스템에 적용하여 고장감지 및 분류능력을 알아보았다.

$$y(k) = \cos(3.14 p_1)y(k-1) - 0.7y(k-2) + u(k-1) + p_2 u(k-2) + \epsilon(k) \quad (3.1)$$

여기서 $u(k)$, $y(k)$ 는 시스템의 입력 및 출력이고, $\epsilon(k)$ 는 분산 $\sigma^2 = 0.9 \cdot 10^{-5}$ 인 백색잡음이며, p_1 과 p_2 는 물리적 계수로서 공칭값은 다음과 같다.

$$p_1 = 0.56, \quad p_2 = 0.37 \quad (3.2)$$

또한 입력은

$$u(k) = 0.5 \cos(k) \quad (3.3)$$

이다. 잡음만에 의한 허위고장신호 발생 확률을 최대한으로 줄이기 위해 $\alpha_1 = 0.01$ (1%)로 했으며, 식(2.17)로부터 고장감지를 위한 문턱값 δ_f 를 구하면 0.001이며, 여러 번의 시뮬레이션을 통해 L 은 30으로 하였다. 고장감지를 위한 신경회로망 공칭모델 및 신경회로망기반 다중고장모델을 이용한 고장분류기에서 신경회로망 고장모델의 구조는 한 개의 은닉층을 갖는 3단의 구조로서 입력층, 은닉층 및 출력층의 노드 수는 4개, 10개 및 1개이며, 입력은 $u(k-1)$, $u(k-2)$, $y(k-1)$,


$y(k-2)$ 이다. 신경회로망의 학습을 위한 학습률 η 와 모멘텀 α 는 0.15 및 0.1로 설정하였다. ART2 신경회로망의 입력층의 노드 수는 10개로서 입력 $X=[y(k_f+1), \dots, y(k_f+n_f)]$ 이며, 경계인수 값은 식 (2.20)에 의해 $\rho=0.1$ 이고, 고장분류기가 동작하는 원도 크기 n_f 는 10으로 설정했다.

물리적인 계수를 인위적으로 변화시킴으로 시스템에 서 예측치 못한 고장상황을 다음과 같이 설정하였다.

고장 #1 : P_1 이 감소


고장 #2 : P_1 이 증가

다음의 결과는 이미 고장 #1($P_1 = 0.4$ 로 감소)이 발생하여 두 개의 신경회로망 고장모델(고장모델 1은 시스템이 정상상태인 경우, 고장모델 2는 고장 #1에 대한 모델)이 구축된 뒤 테스트 결과이다. 그림 3-1은 150번째 순간에 고장 #1인 $P_1 = 0.4$ 로 감소했을 때의 오차의 변화 및 분류 결과이다. 그림 3-1(a)로부터 152 번째 순간에 원도 내에서 시스템출력과 신경 회로망 공칭모델 출력과의 자승오차합이 고장감지 문턱값을 넘어 고장을 감지하였음을 알 수 있다. 3-1(b)는 다중 고장모델과 ART2 신경회로망을 이용한 고장분류기에 의한 분류 결과로 고장 #1로 분류함을 알 수 있다.



(a) I_n 변화와 고장 감지 (b) 고장 분류 결과
그림 3-1. 고장 #1에 대한 고장 감지와 분류결과


그림 3-2(a)는 150번째에 고장모델로 구축되지 않은 새로운 고장 #2($P_1 = 0.8$ 로 증가)가 발생했을 때의 원도 내에서 자승오차합의 변화를 도시한 것으로 152 번째 순간에 고장을 감지하였으며, 3-2(b)로부터 제안된 고장분류기가 일치되는 고장모델이 없음을 선언하고 새로운 고장으로 분류함을 알 수 있다



(a) I_n 변화와 고장 감지 (b) 고장 분류 결과

그림 3-2. 고장 #2에 대한 고장 감지와 분류결과(새로운고장)

그림 3-3은 고장#2에 대한 신경회로망 고장 모델이 추가된 뒤 고장 #2가 다시 발생했을 때의 고장감지 및 분류결과로서 3-3(a)와 3-3(b)로부터 시스템에 #2가 발생되었음을 알 수 있다. 즉 새로운 고장으로 인식하지 않고 신경회로망 고장 모델에 존재하는 고장으로 인식한 것을 알 수 있다.



(a) I_n 변화와 고장 감지 (b) 고장 분류 결과
그림 3-3. 고장 #2에 대한 고장 감지와 분류결과

IV. 결론

본 논문에서는 비선형 시스템에서의 고장진단 및 예측되지 못한 새로운 고장이 발생되었을 때 이를 감지하고 분류하기 위한 다중 신경회로망을 이용한 고장 감지방법과 다중 신경회로망 다중고장모델 기반 ART2 신경회로망 고장분류기에 의한 고장분류방법이 제안되었다.

제안된 고장진단알고리즘의 장점은 신경회로망을 이용하므로 비선형 시스템의 고장진단문제에 직접 적용이 가능하고, 새로운 고장이 발생할 경우에는 새로운 고장클래스로 분류가 가능하며, 통계적 기법을 이용한 방법에 비해서 고장분류를 위한 시간을 단축시킬 수 있다.

MATLAB을 이용한 컴퓨터 시뮬레이션을 통해서 제안된 알고리즘의 성능을 확인한 결과 비선형 시스템에서 발생하는 고장을 감지하고 정확하게 분류할 뿐만 아니라 예측되지 못한 고장이 발생한 경우에도 이를 새로운 고장으로 분류함을 확인할 수 있었다.

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] 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.
- [3] 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.
- [4] 이인수, "신경회로망기반 다중고장모델에 의한 비선형시스템의 고장감지와 분류", 대한전자공학회논문집, vol. 39, no. 1, pp.42-50, 2002.
- [5] D. E. Rumelhart and J. L. McClelland, Parallel distributed processing: explorations in the microstructure of cognition. vol. 1, MIT Press, Reading, MA, 1986.
- [6] J. D. Cryer, Time Series Analysis, Duxbury Press, 1986.