

다층/ART2 신경회로망을 이용한 고장진단

A Fault Diagnosis Based on Multilayer/ART2 Neural Networks

이 인 수*, 유 두 형**

In Soo Lee* and Du Hyoung Yu**

* : 상주대학교 전자전기공학부 교수

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

** : 상산전자공업고등학교 교사

** : Sangsan Electronics Technical High School

요 약

본 논문에서는 비선형시스템에서 발생한 고장을 감지하고 분류하기 위한 신경회로망기반 고장진단 방법을 제안한다. 제안한 알고리듬에서는 시스템의 출력과 다층신경회로망 공청모델 출력 사이의 오차가 미리 설정한 문턱값을 넘으면 고장을 감지한다. 고장이 감지되면 다층신경회로망과 ART2 신경회로망을 이용한 고장분류기에서 시스템에서 발생한 고장을 분류한다. 컴퓨터 시뮬레이션 결과로부터 제안한 고장진단방법이 비선형시스템에서의 고장감지 및 분류문제에 잘 적용됨을 알 수 있다.

Abstract

Neural networks-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 multilayer neural network-based nominal model output cross a predetermined threshold. Once a fault in the system is detected, the system outputs are transferred to the fault classifier by multilayer/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.

Key words : Fault detection, fault isolation, multilayer NN, ART2 NN, nonlinear system

1. 서 론

시스템이 방대하고 복잡해지며 많은 공정이 자동화됨에 따라 시스템의 신뢰성 및 안전성 유지에 대한 관심이 고조되고 있을 뿐만 아니라 각 시스템을 이루는 요소의 동작 신뢰성을 높여 시스템의 오동작을 방지하는 일이 매우 중요하게 되었으며, 이를 위한 고장진단기법에 관한 연구가 활발히 이루어지고 있다.

고장진단(fault diagnosis)은 시스템에 고장이 발생하면 각종 고장 현상을 조기에 감지하고, 고장이 발생한 위치 등에 관한 정보를 운전자에게 제공해서 운전자로 하여금 고장에 대한 적절한 조치를 취하도록 하여 안전한 시스템을 구축하는 것을 목표로 한다. 일반적으로 고장진단은 시스템에서의 고장을 판단하기 위한 고장감지(detection)단계, 발생한 고장의 종류를 분류하기 위한 고장분류(isolation)단계 및 고장의 정도를 결정하는 고장식별(identification)단계로 이루어진다.

기존의 고장감지 및 분류방법[1-7]은 크게 모델에 기반한 방법과 모델에 기반하지 않는 방법으로 분류되고, 모델 기반

기법은 정량적 모델 기법과 정성적 모델 기법으로 분류할 수 있다. 정량적 모델 기법은 시스템의 수학적 모델에 의해 제공되는 해석적인 기법을 기초로 하는 것으로서 초기 고장 감지에 유용하나, 고장 진단을 위한 시스템의 정확한 정량적 모델이 필요하므로 불확실성이 존재하고 비선형성이 강한 시스템에는 적용이 어렵다는 문제점이 있다. 정성적 모델 기반 분류 기법은 분류 대상 프로세스에 대한 수학적 모델 대신에 프로세스 운전자의 경험 규칙 또는 추상화된 프로세스의 정성적 동작을 기반으로 하여 고장 분류를 수행하며 정량적 모델 기반 분류 기법에 비해 낮은 분류 성능을 갖는다.

다음으로, 모델에 근거하지 않는 방법은 대상 시스템의 측정치, 경험 또는 물리적 검토를 기초로 하는 것으로서 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 발생될 경우에는 가장 유사한 고장모델을 선

택하므로서 잘못된 고장진단을 행한다. 그러므로 예상되지 않는 고장뿐만 아니라 시스템의 동작 조건에 따라 새로운 고장이 발생될 때에도 이를 분류할 수 있는 수단이 필요하다. 즉, 고장분류기는 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 가능하고 예측하지 않은 새로운 고장이 발생했을 때의 고장분류문제를 해결할 수 있는 신경회로망을 이용한 고장감지와 분류 방법을 제안한다. 제안한 고장진단 알고리듬에서는 다층신경회로망 기반 다중고장모델과 ART2 신경회로망 기반 고장분류기로 고장을 분류하므로 비선형시스템의 고장진단 문제에 직접 적용이 가능할 뿐만 아니라 예측되지 않은 새로운 고장이 발생하여도 이를 새로운 고장으로 분류할 수 있다. 특히, 제안된 방법은 통계적기법[10]에 의한 고장진단 알고리듬과 비교했을 때 신경회로망의 장점인 데이터 병렬처리성으로 인해 고장 분류 시간의 단축이 가능하다. 제안한 고장감지와 분류방법을 비선형시스템의 고장진단문제에 적용하여 성능을 알아보았다.

2. 신경회로망을 이용한 고장감지 및 분류 알고리듬

제안한 신경회로망을 이용한 고장진단알고리듬은 그림 1과 같이 고장감지부와 고장분류부로 구성된다. 고장감지부에서는 고장감지를 위해 다층 신경회로망 공청모델을 이용하였으며 비선형시스템에도 적용 가능하다. 고장분류부에서는 다층 신경회로망 기반 고장모델과 ART2 신경회로망을 이용함으로써 새로운고장의 분류가 가능하며, 고장분류 시간을 단축할 수 있을 뿐만 아니라 비선형시스템의 고장진단문제에도 적용 가능하다.

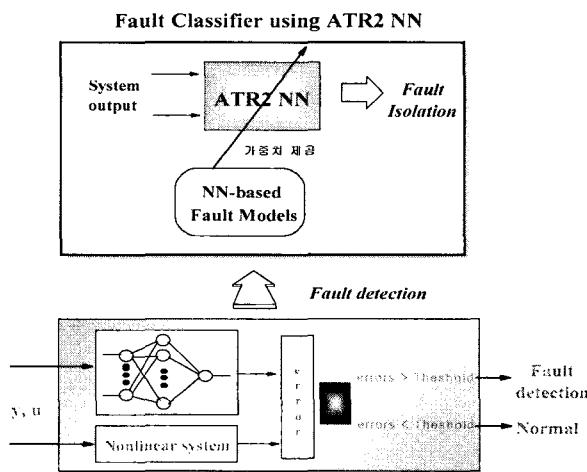


그림 1. 신경회로망을 이용한 고장진단시스템
Fig. 1. Architecture of the neural networks-based fault diagnosis system.

2.1 신경회로망

2.1.1 다층 신경회로망

본 논문에서 고장감지를 위한 공청모델 및 ART2 신경회로망 고장분류기의 다중고장모델부를 구성하기 위한 신경회로망의 구조는 그림 2와 같은 다층신경회로망으로서 입력층, 중간층과 출력층으로 이루어져 있다.

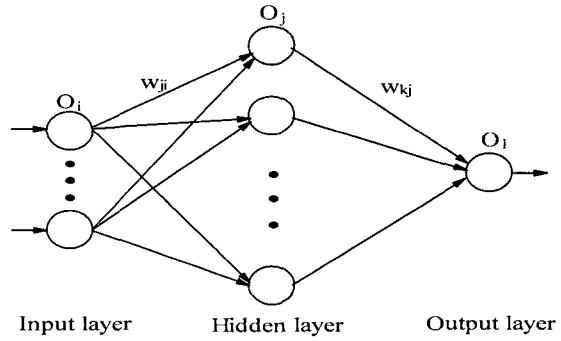


그림 2. 다층 신경회로망의 구조도
Fig. 2. Architecture of the multilayer NN.

다층 신경회로망의 출력값을 계산하는 순방향(feed-forward) 모델식은 은닉층에서의 입출력 관계식과 출력층에서의 입출력 관계식으로 구성된다. 먼저, 은닉층 및 출력층에서의 입출력 관계식은 다음과 같다.

$$net_j = \sum_{i=1}^I w_{ji} \cdot O_i \quad (1)$$

$$O_j = f_j(net_j) \quad (2)$$

$$net_1 = \sum_{j=1}^J w_{1j} \cdot O_j \quad (3)$$

$$O_1 = f_1(net_1) \quad (4)$$

여기서 net_j 는 j 번째 은닉노드의 입력, w_{ji} 는 i 번째 입력노드와 j 번째 은닉노드 사이의 가중치, I 는 입력노드의 수이고, O_i 는 i 번째 입력노드에서의 출력값으로서 입력층에서는 선형대응이므로 O_i 는 신경회로망의 입력이다. 또한 net_1 은 출력노드의 입력으로서 아래첨자 1은 신경회로망의 출력노드가 하나임을 의미하며, w_{1j} 는 j 번째 은닉노드와 출력노드사이의 가중치이고 O_1 는 출력노드에서의 출력값, J 는 은닉노드의 수이다. 그리고 O_1 는 j 번째 은닉노드에서의 출력값으로서 활성화함수인 아래와 같은 시그모이드함수 $f_j(\cdot)$ 를 통과시킨 값이다.

$$f_j(x) = \frac{1 - e^{-x}}{1 + e^{-x}} \quad (5)$$

다층 신경회로망으로부터 원하는 입출력 특성을 얻기 위해서는 학습을 행하여야 한다. 다층 신경회로망의 학습은 오차 역전파 학습알고리듬(back-propagation algorithm)[11]을 이용하여 가중치를 변화시킴으로써 이루어지며, 신경회로망을 학습시키기 위한 성능함수는 다음과 같이 정의한다.

$$E = \frac{1}{2} (d(t) - O_1(t))^2 \quad (6)$$

여기서 $d(t)$ 와 $O_1(t)$ 은 각각 목표값과 실제 신경회로망의 출력노드에서의 출력값이다. 출력노드에서의 오차신호는 아래와 같다.

$$\begin{aligned}\delta_1 &= -\frac{\partial E}{\partial net_1} \\ &= (d(t) - O_1(t)) \cdot f'(net_1)\end{aligned}\quad (7)$$

여기서 net_1 은 출력노드의 입력, $f(\cdot)$ 은 시그모이드함수의 미분이다.

온녁층과 출력층사이의 가중치에 대한 오차함수의 기울기와 가중치는 각각

$$\begin{aligned}\Delta w_{1j} &= -\eta \cdot \frac{\partial E}{\partial w_{1j}} \\ &= \eta \cdot \delta_1 \cdot O_j\end{aligned}\quad (8)$$

$$w_{1j}(t+1) = w_{1j}(t) + \Delta w_{1j} + \alpha \cdot (w_{1j}(t) - w_{1j}(t-1)) \quad (9)$$

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

$$\begin{aligned}\delta_j &= -\frac{\partial E}{\partial O_j} \cdot \frac{\partial O_j}{\partial net_j} \\ &= \delta_1 \cdot w_{1j} \cdot f'(net_j)\end{aligned}\quad (10)$$

$$\begin{aligned}\Delta w_{ji} &= -\eta \cdot \frac{\partial E}{\partial w_{ji}} \\ &= \eta \cdot \delta_j \cdot O_i\end{aligned}\quad (11)$$

$$w_{ji}(t+1) = w_{ji}(t) + \Delta w_{ji} + \alpha \cdot (w_{ji}(t) - w_{ji}(t-1)) \quad (12)$$

여기서 w_{ji} 는 i 번째 입력노드와 j 번째 온녁노드사이의 가중치이며, O_i 는 i 번째 입력노드의 출력값이다.

2.1.2 ART2 신경회로망

ART2 신경회로망은 그림 3과 같이 저장된 패턴과 유사한 입력에 대하여 반응을 하여 이를 학습하기 위한 계층1과 저장된 패턴과 유사성이 없는 패턴이 입력될 경우, 계층1을 차단시키고 새로운 클래스를 생성시키게 하는 계층2로 구성된다. 계층1은 입력층과 출력층을 가지는 두 층(two layer) 신경회로망으로 구성되며, 입력층과 출력층 노드들은 학습 패턴들이 기억되는 가중치로 연결되어 있다. 최초의 입력 패턴이 ART2 신경회로망에 전달되면 출력층에는 생성된 클래스가 없으므로 첫 번째 클래스로 분류하여 입력패턴을 첫 번째 출력노드와 입력노드들 사이의 가중치에 저장한다. 다음에 다른 패턴이 입력되면 첫 번째 클래스와의 유사성을 검사하여 같은 클래스로 학습하거나 새로운 클래스를 생성시키게 되는데, 현 시점에서 이미 M 개의 클래스가 분류 알고리듬에 의해서 생성되어 있다고 가정하고 분류 과정을 단계별로 기술하면 다음과 같다[12]. 이때 이미 신경회로망의 가중치로 저장된 M 개의 패턴을 각 클래스의 템플리트패턴이라고 하며 신경회로망의 N 차원의 입력벡터와 j 번째 출력노드에 대한 N 차원의 가중치벡터를 각각 X 와 V_j 로 표현한다.

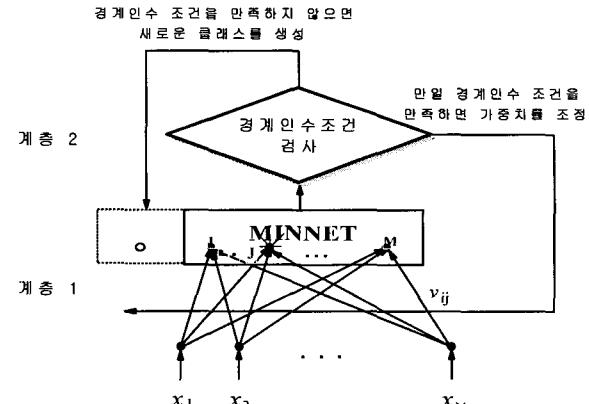


그림 3. ART2 신경회로망의 구조도
Fig. 3. Architecture of the ART2 neural network.

단계 1 : 새로운 패턴이 입력되면, MINNET(minimumnet)이 입력패턴과 각 출력노드와의 거리를 아래와 같이 계산하여, 거리가 최소인 출력노드를 선택하고 이 노드를 승리노드라고 하며 J 로 표시한다.

$$d_j = \| V_j - X \|, \quad j = 1, 2, \dots, M \quad (13)$$

여기서 $\| \cdot \|$ 은 임의의 놈(norm)이다.

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

$$\text{경계인수조건} : \| V_j - X \| < \rho \quad (14)$$

여기서 경계인수 ρ 는 각 클래스의 분류 반경을 결정하는 값이다.

단계 3 : 새로운 클래스 k 가 만들어지며, 이때 가중치는 $V_k = X$ 가 된다.

단계 4 : 승리노드 J 의 가중치는 다음과 같이 조정된다.

$$V_j^{\text{new}} = \frac{X + V_j^{\text{old}} [class_j^{\text{old}}]}{[class_j^{\text{old}}] + 1} \quad (15)$$

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

2.2 고장감지

본 논문에서 대상 시스템은 아래와 같은 이산시간 비선형 시스템으로 가정한다.

$$\begin{aligned}y(k+1) &= g[y(k), y(k-1), \dots, y(k-n+1), \\ &\quad u(k), u(k-1), \dots, u(k-m+1)] + \varepsilon(k)\end{aligned} \quad (16)$$

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

$$\begin{aligned} y(k+1) &= g_f[y(k), y(k-1), \dots, y(k-n+1), \\ &\quad u(k), u(k-1), \dots, u(k-m+1)] + \epsilon(k) \end{aligned} \quad (17)$$

여기서 $g_f(\cdot)$ 는 고장으로 인해 파라미터가 변한 시스템이다. 그러므로 시스템에 고장이 발생하면 이로인해 변화된 비선형시스템 $g_f(\cdot)$ 를 추정하여 이를 분류에 이용하므로써 고장의 원인을 알 수 있다. 본 논문에서는 고장이 발생하면 변화된 비선형시스템 $g_f(\cdot)$ 를 직접 추정하지 않고, 변화된 시스템과 가장 유사한 신경회로망 고장모델을 결정하므로써 고장을 분류한다. 또한 고장을 분류하기 위해 시스템의 입출력 신호를 이용하므로 입출력 신호를 얻을 수 없는 시스템의 완전파괴와 같은 고장은 고려하지 않는다.

최소화해야 할 성능지수, 시스템 출력과 신경회로망 공청모델 출력사이의 오차를 각각 아래와 같이 정의하며 식 (18)을 최소화하는 방향으로 신경회로망을 학습하여 고장감지를 위한 공청모델을 구축한다.

$$J_n(k) = \sum_{i=1}^k e_n^2(i) \quad (18)$$

$$e_n(k) = y(k) - y_n(k) \quad (19)$$

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

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

$$J_n(k) = \sum_{i=k-L+1}^k e_n^2(i) > \delta_f \quad (20)$$

여기서 δ_f 는 고장감지를 위한 문턱값, L 은 윈도우 크기이다. 공청모델이 충분히 학습되었다면 시스템 출력과 공청모델 출력사이의 오차는 시스템 잡음과 거의 같은 성질을 가진다[13]. 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.

$$\bar{J}_n(k) = \sum_{i=k-L+1}^k \frac{e_n^2(i)}{\sigma^2} \sim \chi_L^2 \quad (21)$$

고장감지를 위한 문턱값 δ_f 는 잡음만에 의한 허위고장신호 발생률과 고장신호를 발생시키지 못하는 확률을 동시에 줄이는 방향으로 설정해야 하나, 대부분의 시스템에서 고장에 의한 시스템 파라미터의 변화는 클 것이므로, 이로 인한 시스템 출력과 신경회로망 공청모델 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

$$\Pr \left(\sum_{i=k-L+1}^k \frac{e_n^2(i)}{\sigma^2} > \delta_f \right) = \alpha \quad (22)$$

이므로 χ^2 분포표로부터 상수 δ_f 를 구한 뒤 이로부터 고장

감지를 위한 문턱값 $\delta_f = \sigma^2 \delta_f$ 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.

2.3 ART2 신경회로망과 신경회로망기반 다중고장모델에 의한 고장분류

고장분류기는 그림 4와 같이 ART2 신경회로망 고장분류부와 다중 신경회로망기반 다중고장모델부로 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.

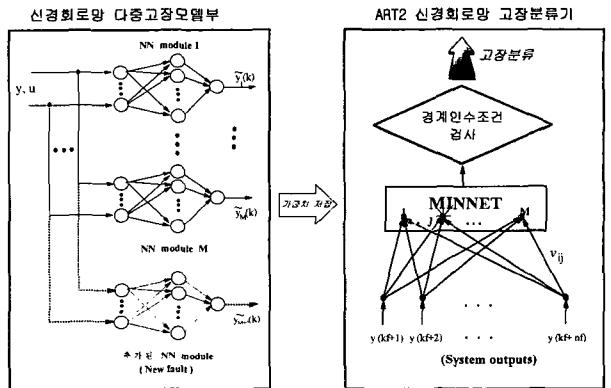


그림 4. 신경회로망 고장분류기의 구조도
Fig. 4. Architecture of the neural networks-based fault classifier.

제안한 ART2 신경회로망과 신경회로망기반 다중고장모델을 이용한 고장분류기에서 고장이 감지된 후 고장을 분류하는 과정은 아래와 같다.

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

단계 2 : 만일 $k = k_f + n_f$ 이면 j 번째 신경회로망 고장모델의 출력 $\tilde{y}_j(k)$ 을 ART2 신경회로망의 가중치 V_j 에 아래와 같이 저장하고,

$$V_j = [\tilde{y}_j(k_f+1), \tilde{y}_j(k_f+2) \dots \tilde{y}_j(k_f+n_f)] \quad (23)$$

ART2 신경회로망의 $X = [y(k_f+1), y(k_f+2) \dots y(k_f+n_f)]$ 와 각 출력노드와의 거리 $d_j = \|V_j - X\|_2$ 를 계산한다. 만일 $k < k_f + n_f$ 이면 단계 1로 간다. 단, $j = 1, 2, \dots, M$, $k = k_f + 1, \dots, k_f + n_f$

단계 3 : 다음과 같은 조건

$$\min \|V_j - X\| < \rho \quad (24)$$

을 만족하면 그 출력노드가 시스템에서 발생한 고장과 일치된 것으로 결정한다. 그렇지 않으면 새로운 고장클래스가 만들어지며 입출력데이터를 이용하여 새로운 고장에 대한 신경회로망 고장모델을 학습시켜서 이를 다중고장모델부에 추가한다.

위 3단계 고장분류 과정에서 k_f 는 고장감지 시간, n_f 는 고장이 감지된 뒤 고장분류기가 동작하는 윈도우의 크기이며, ρ 는 경계인수로서 아래와 같이 설정한다.

$$\rho = \sqrt{\delta_f} \quad (25)$$

각 고장에 대한 신경회로망 고장모델의 학습오차를 고려하여 식 (25)로부터 구한 경계인수 ρ 보다 조금 크게 설정할 필요가 있다.

3. 시뮬레이션결과 및 고찰

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

$$y(k) = \cos(3.14 p_1) y(k-1) - 0.7 y(k-2) + u(k-1) + p_2 u(k-2) + \epsilon(k) \quad (26)$$

여기서 $u(k)$, $y(k)$ 는 각각 시스템의 입력과 출력, $\epsilon(k)$ 는 분산 $\sigma^2 = 0.9 * 10^{-5}$ 인 백색잡음이며 p_1 과 p_2 는 물리적 계수로서 공칭값은 아래와 같다.

$$p_1 = 0.56, \quad p_2 = 0.37 \quad (27)$$

또한 입력은

$$u(k) = 0.5 \cos(k) \quad (28)$$

이다. 그리고 시스템이 정상적으로 동작함에도 불구하고 잡음만에 의한 허위고장신호 발생률을 최대로 줄이기 위해 $\alpha = 0.01$ (1%)로 했으며, (22)로부터 고장감지를 위한 문턱값 δ_f 를 구하면 0.001이며, 여러 번의 시뮬레이션을 통해서 L은 30으로 하였다. 고장감지를 위한 신경회로망 공칭모델 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 ART2 신경회로망 입력층의 노드수는 10개로서 입력 $X = [y(k_f+1), y(k_f+2) \dots y(k_f+n_f)]$ 이고, 경계인수 값은 식 (25)와 학습오차를 고려하여 0.035로 하였고 고장분류기가 동작하는 윈도우크기 n_f 는 10으로 설정했다.

물리적인 계수들의 값을 인위적으로 변화시킴으로써 시스템에서의 예기치 못한 고장상황을 다음과 같이 설정하였다.

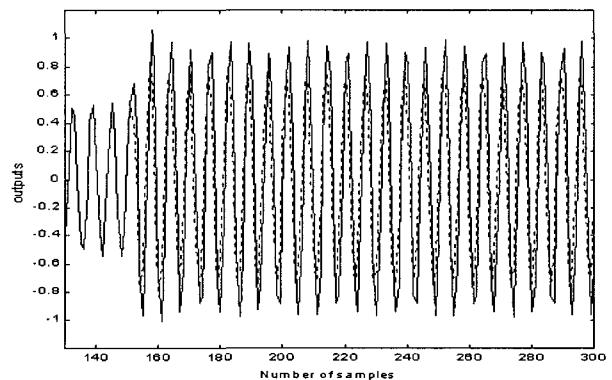
고장 #1 : P_1 이 감소

고장 #2 : P_1 이 증가

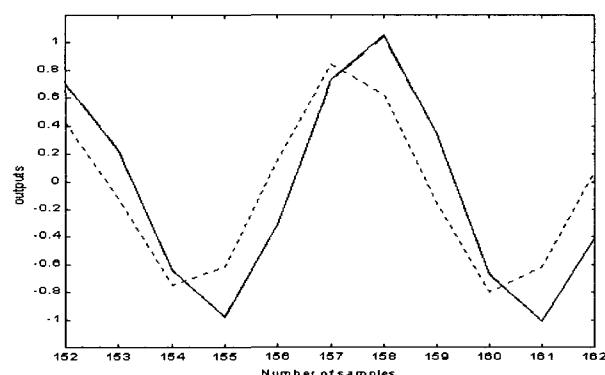
그림 5와 6은 이미 고장 #1 ($P_1 = 0.39$ 로 30% 감소)이 발생하여 두 개의 신경회로망 고장모델(고장모델 1 : 시스템 정상상태에 대한 모델, 고장모델 2 : 고장 #1에 대한 모델)이 구축된 뒤 테스트한 결과이다. 그림 5는 150번째 순간에

$P_1 = 0.39$ 로 감소하는 고장 #1이 다시 발생했을 때의 고장감지 및 분류 결과이다. 5(a)는 시스템출력과 신경회로망 공칭모델출력을 각각 도시한 것으로서 고장으로 인해 두 출력에 차이가 발생함을 알 수 있으며 5(b)로부터 152번째 순간에 윈도우 내에서 시스템출력과 공칭모델과의 자승오차합이 고장감지 문턱값을 넘어 고장을 감지하였음을 알 수 있다. 그리고 5(c)는 시스템출력, 고장모델 1 출력 및 고장모델 2 출력을 각각 도시한 것으로서 시스템출력이 고장모델 2 출력과 거의 같음을 알 수 있으며, 5(d)는 다중고장모델과 ART2 신경회로망을 이용한 고장분류기에 의한 분류결과로서 현재의 시스템 상태를 고장 #1(고장클래스 2)으로 분류함을 알 수 있다.

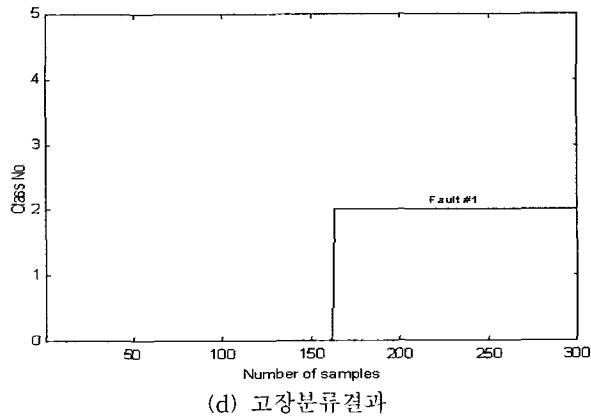
그림 6은 150번째 순간에 고장모델로 구축되지 않은 새로운 고장 #2($P_1 = 0.73$ 으로 30% 증가)가 발생되었을 때의 고장감지 및 분류결과로서 6(b)는 윈도우 내에서 자승오차합의 변화를 도시한 것으로서 152번째 순간에 고장을 감지하였다. 6(c)는 시스템출력과 고장모델 1 및 2의 출력을 도시한 것이며 6(d)는 고장분류결과로서 신경회로망 고장분류기가 일치되는 고장모델이 없음을 선언하고 새로운고장으로 인식함을 알 수 있다. 그림 7은 새로운고장 #2에 대한 신경회로망 고장모델 3이 추가된 뒤 고장 #2가 다시 발생했을 때의 고장감지 및 분류결과로서 7(c)로부터 시스템출력이 고장모델 3 출력과 거의 같음을 알 수 있으며, 7(d)로부터 시스템에 고장 #2가 발생되었음을 알 수 있다.



(a) 시스템출력(_____), 신경회로망 모델출력(.....)

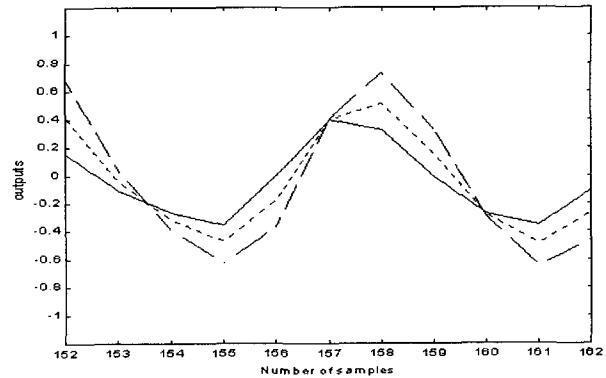


(b) 시스템출력(_____), 고장모델 1 출력(.....) 고장모델 2 출력(-----)

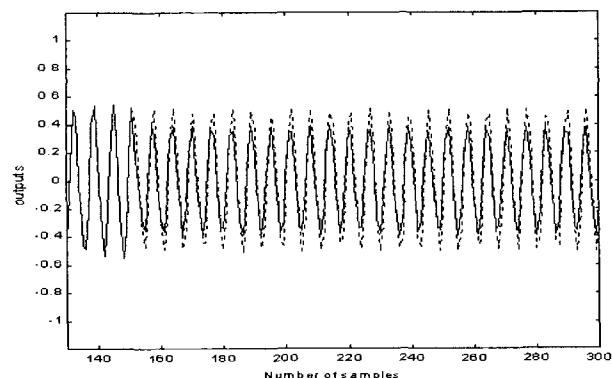


(d) 고장분류결과

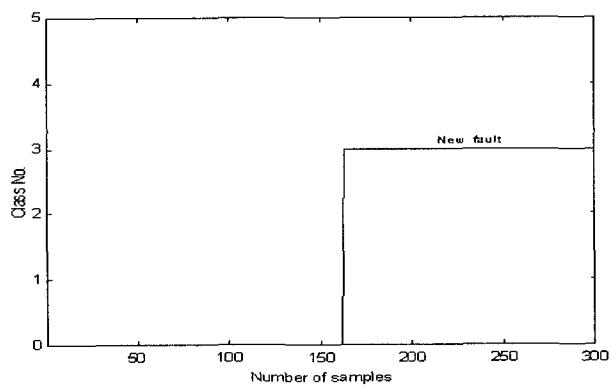
그림 5. 고장 #1에 대한 고장감지와 분류결과
Fig. 5. Results of detection and isolation for fault #1.



(c) 시스템출력(_____), 고장모델 1 출력(.....),
고장모델 2 출력(- - -)

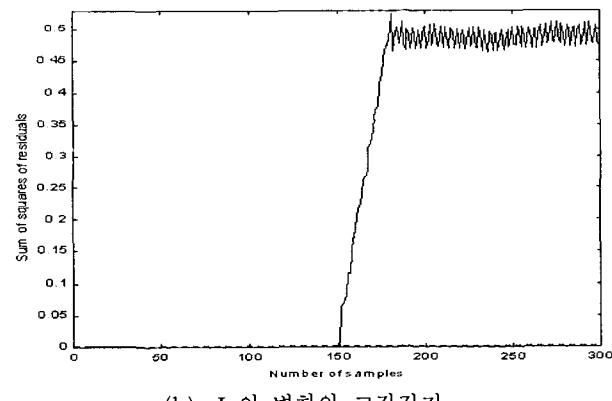


(a) 시스템출력(_____), 신경회로망 모델출력(.....)

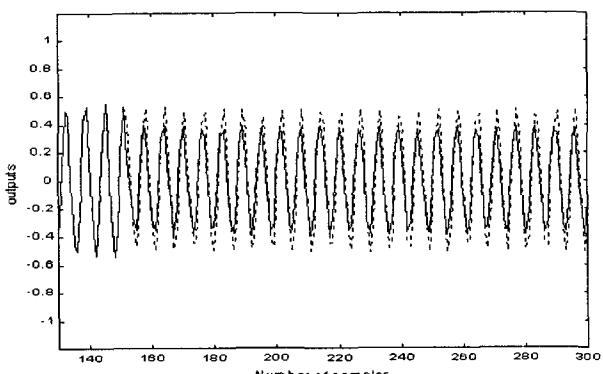


(d) 고장분류결과

그림 6. 새로운 고장 #2에 대한 고장감지와 분류결과
Fig. 6. Results of detection and isolation for fault #2.



(b) J_n 의 변화와 고장감지



(a) 시스템출력(_____), 신경회로망 모델출력(.....)

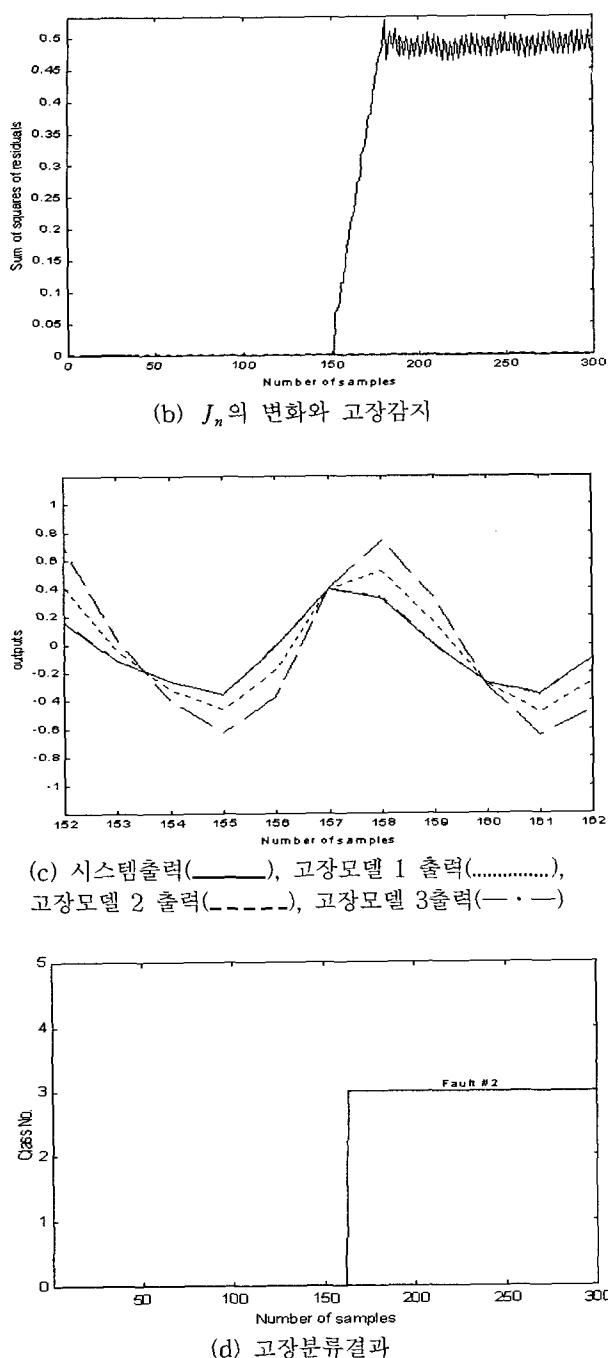


그림 7. 고장 #2에 대한 고장감지와 분류결과
Fig. 7. Results of detection and isolation for fault #2.

4. 결 론

본 논문에서는 비선형시스템의 고장진단 및 예측되지 못한 새로운 고장이 발생되었을 때 이를 감지하고 분류하기 위한 다중 신경회로망을 이용한 고장감지방법과 다중 신경회로망 다중고장모델을 이용한 ART2 신경회로망 고장분류기에 의한 고장분류방법을 제안하였다. 제안한 고장진단알고리즘의 장점은 신경회로망을 이용하여 고장진단을 수행하므로 비선형시스템의 고장진단문제에 직접 적용이 가능하고, 고장분

류에 자율신경회로망인 ART2 신경회로망을 이용하므로 새로운 고장이 발생할 경우에는 새로운 고장클래스로 분류가 가능하며, 통계적 기법을 이용한 방법에 비해서 고장분류를 위한 시간을 단축시킬 수 있다. 제안한 고장진단 알고리듬을 적용한 컴퓨터 시뮬레이션을 통해서 그 성능을 확인한 결과 비선형시스템에서 발생되는 고장을 정확하게 분류할 뿐만 아니라 예측되지 못한 고장이 발생한 경우에도 이를 새로운 고장으로 분류함을 확인할 수 있었다.

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] 이인수, "신경회로망기반 다중고장모델에 의한 비선형시스템의 고장감지와 분류", 대한전자공학회논문집, vol. 39, no. 1, pp.42-50, 2002.
- [11] D. E. Rumelhart and J. L. McClelland, Parallel distributed processing: explorations in the microstructure of cognition. vol. 1, MIT Press, Reading, MA, 1986.
- [12] S. Y. Kung, Digital Neural Networks, Prentice

- Hall, 1993.
[13] J. D. Cryer, Time Series Analysis, Duxbury Press, 1986.
-

저자 소개



이인수(In Soo Lee)

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

관심분야 : 시스템의 고장진단 및 고장 허용제어, 지능제어 및 응용, 지능형센서 시스템 등이다.

유두형(Du Hyoung Yu)

1983년 : 충남대학교 공업교육대학 전자교육공학과(공학사)
2003년 : 상주대학교 산업대학원 전자전기공학부 졸업(공학
석사)
1999년 ~ 현재 : 경상북도 상주시 상산전자공업고등학교 교사

관심분야 : 신경회로망, 고장진단 등이다.