

신경회로망을 이용한 동적 문턱값에 의한 비선형 시스템의 고장진단

Fault Diagnosis of Nonlinear Systems Based on Dynamic Threshold Using Neural Network

소 병 석, 이 인 수, 전 기 준
(Byung Seok Soh, In Soo Lee, and Gi Joon Jeon)

Abstract : Fault diagnosis plays an important role in the performance and safe operation of many modern engineering plants. This paper investigates the problem of fault detection using neural networks in dynamic systems. A general framework for constructing a nonlinear fault detection scheme for nonlinear dynamic systems containing modeling uncertainty is proposed. The main idea behind the proposed approach is to monitor the physical system with an off-line learning neural network and then to approximate the upper and lower thresholds of acceleration of the nominal system with the model-based threshold(ThMB) method. The performance of the proposed fault detection scheme is investigated through simulations of a pendulum with uncertainty.

Keywords : fault detection, dynamic threshold, ThMB, neural network

I. 서론

최근의 시스템은 구동능력과 수행능력 향상에 대한 요구로 인해 더욱 복잡해지고 대형화되어 가고 있으며, 그로 인한 다양한 구동조건에 의해 시스템 매개변수가 변화하거나 시스템의 비선형적인 변화에 의한 고장이 발생할 수 있다. 그러한 고장은 제한된 인간의 능력으로 관리 감독 및 수리가 어렵거나 불가능 할 수 있으며, 그로 인해 생산성 감소나 고가의 장비손실 뿐만 아니라 인명피해까지 초래할 수 있다. 그러므로 현대의 자동화된 제어시스템의 고장에 대한 자동적 감지뿐만 아니라 효과적인 보상이 중요하다.

고장을 감지하며 고장 위치와 성질을 식별하는 관측시스템을 고장진단 시스템이라고 하고, 일반적으로 다음과 같은 작업을 말한다[1]. 먼저 주어진 시스템에 고장이 발생하였는지를 확인하는 고장감지 단계와 고장이 발생한 위치를 결정하는 고장 분류 단계가 있으며, 고장의 크기나 성질 및 형태를 추정하는 고장 식별 단계가 있다.

전기적, 기계적인 장치 및 유량 시스템 등에서 고장을 감지, 판별 및 보상하는 일련의 작업들 중 가장 기본이 되는 단계가 고장감지 단계로서 문턱값을 이용하여 결정한다. 고장감지는 시스템이 출력이 주어진 문턱값 범위를 벗어났을 경우를 말하며, 그러한 범위는 고정된 문턱값(constant threshold) 혹은 동적인 문턱값(dynamic threshold)을 이용하여 결정한다. 고정된 문턱값은 임의의 상수 크기만큼의 오차허용범위를 결정하여 고장을 감지하는 방법으로, 항상 최악의 경우를 고려하여 설정하

므로 효과적인 고장감지가 어렵다. 반면, 동적 문턱값은 정상시스템의 동작허용 가능범위 혹은 오차허용 가능범위를 매순간 동적으로 계산하므로 고장감지의 신뢰도가 높고 신속한 고장감지 및 복구를 도모할 수 있다.

기존의 시스템 고장감지를 위한 동적 문턱값에 관한 연구들로는 Horak 등[2]이 제안한 RMI(reachable measurement interval)방법과 Visinsky 등[3][4]이 제안한 ThMB(model-based threshold)방법 등이 있다. RMI방법은 시스템의 계수들 중 알고 있는 부분과 정확히 알지 못하지만 범위를 측정 할 수 있는 계수들이 포함된 부분으로 분리하고, 각 계수들이 가지는 범위를 이용하여 시스템의 출력오차의 허용 가능범위를 정하며, 이를 이용하여 고장을 감지하는 방법이다. 그러나, RMI방법으로 불확실한 계수들이 포함된 부분의 값들을 계산할 경우 각 부분들간의 상호 연관성 부족으로 인해 감지허용범위가 커지며, 계산 시간이 많이 소요되는 단점이 있다[5]. ThMB방법은 RMI방법의 단점을 보완하기 위하여 모델기반 시스템의 출력과 원하는 출력값의 차이를 계산하여 문턱값을 결정한다. 즉, 비선형 시스템 방정식을 매개변수에 관해 선형화하여 각 계수들간의 상호 연관성을 고려한 방법으로, RMI방법보다 계산량이 감소되며, 감지허용범위가 축소되어 보다 신속한 고장감지를 가능하게 한다. 그러나, 위의 두 방법에서는 정확한 공칭모델을 근거로 하여 일부 계수들의 불확실성을 어느 정도 고려한 동적인 문턱값을 설정하였지만, 실제 시스템에는 모델링오차, 마찰 및 외란 등과 같은 모델링 불확실성이 존재하며 이는 잘못된 고장감지의 원인이 되므로 불확실성이 존재하는 비선형 시스템에 대한 고장감지에는 적용이 어렵다.

본 논문에서는 불확실성이 있는 비선형 시스템에서의 고장감지를 위한 동적인 문턱값 설정방법을 신경회로망과 ThMB방법을 이용하여 결정하였다. 제안한 방법은 신경회로망으로 시스템을 오프라인으로 모사한 후, 공칭 모델과

접수일자 : 2000. 3. 22., 수정완료 : 2000. 7. 5.

소병석 : 삼성전자 중앙연구소

이인수 : 상주대학교 전자전기공학부

전기준 : 경북대학교 전자전기공학부

※ 이 논문은 1999년도 두뇌한국21사업에 의하여 지원되었음.

학습된 신경회로망과의 차이를 결정하고, ThMB방법의 오차량을 적용하여 동적인 고장감지를 한다. 제안한 방법을 모델링 불확실성이 있는 진자의 동적 모의실험에 적용하여 고장진단 알고리즘의 성능을 평가한다.

II. 모델 기반 문턱값

ThMB방법은 RMI방법의 단점을 보완한 것으로 신속하며 신뢰성 있는 고장감지를 위한 동적인 문턱값 탐색방법이다. 강제로봇 동역학에서 보편 운동의 비선형 방정식은 매개변수들에 대해 선형이므로[6], 매개변수 기반의 계수들에 대한 선형형태로 만들기 위해

$$\begin{aligned} \tau &= M(q)(\ddot{q}_d + K_d\dot{e} + K_p e) + N(q, \dot{q}) \\ &= Y(q, \dot{q}, \ddot{q})p \end{aligned} \quad (1)$$

과 같이 관절변수로부터 분리할 수 있다. 여기서 τ 는 플랜트의 출력이며, M 과 N 은 실제질량(m) 및 실제길이(l)에 대한 함수이며 각각 관성질량항수 부분 및 구심력과 코리올리힘(Coriolis force)을 포함하는 함수 부분을 나타낸다. 그리고 e 는 추적오차로서 $q_d - q$ 이고 \ddot{q}_d 는 원하는 출력각(q_d)의 가속도를 의미하며 m 과 l 은

$$m_{\min} \leq m \leq m_{\max} \quad (2)$$

$$l_{\min} \leq l \leq l_{\max} \quad (3)$$

의 범위를 가진다. 각 축의 각은 q 로 정의되고, 행렬 Y 는 알고 있는 상태변수(q, \dot{q}, \ddot{q})의 함수이며, p 는 매개변수 m 및 l 의 조합으로 이루어진 벡터이다. 이렇게 추정된 매개변수 값에서 공칭 매개변수(\hat{m}, \hat{l})을 정하고, \hat{M} 과 \hat{N} 의 값을 계산하여, 플랜트에 토크계산제어기(computed torque controller)를 적용하여 출력되는 제어입력은

$$\tau = \hat{M}(q)(\ddot{q}_d + K_d\dot{e} + K_p e) + \hat{N}(q, \dot{q}) \quad (4)$$

로 계산되며, 강제로봇의 동역학으로부터 \ddot{q} 은

$$\ddot{q} = M^{-1}\tau - M^{-1}N \quad (5)$$

로 계산할 수 있다[3]. (4)로부터 계산된 토크제어입력을 (5)에 대입하면

$$M\ddot{q} = \hat{M}(\ddot{q}_d + K_d\dot{e} + K_p e) + (\hat{N} - N) \quad (6)$$

를 얻을 수 있으며, (6)에서 $\hat{M}\ddot{q}$ 을 더하고 빼서 다시 정리하면 아래와 같은 오차방정식을 얻을 수 있다.

$$\ddot{e} + K_d\dot{e} + K_p e = \hat{M}^{-1}(\hat{M}\ddot{q} + \hat{N}) \quad (7)$$

여기서 $\hat{M} = M - \hat{M}$ 이고 $\hat{N} = N - \hat{N}$ 이다.

(1)을 이용하여 (7)의 우측부분을 상태변수와 매개변수로 분리하면

$$\ddot{e} + K_d\dot{e} + K_p e = \hat{M}^{-1}[Y]\hat{p} \quad (8)$$

을 얻을 수 있다. 여기서 $\hat{p} = p - \hat{p}$ 를 나타낸다. (8)에 의해 ThMB방법에서 제안한 동적인 고장 문턱값을 계산할

수 있다. 즉, (8)을 이용하여 시스템 수식을 매개변수 m 및 l 에 의해 계산되는 부분(M^{-1}, \hat{p})과 시스템의 출력을 변수로 하여 계산되는 부분으로 나눈다. 그리고, (2)와 (3)에서 언급한 매개변수 m 및 l 의 허용범위를 이용하여, 한 샘플링 시간이 지난 후의 오차변화분의 상위 및 하위 최대 오차범위를 정할 수 있다.

강제로봇의 간단한 예로서 진자 시스템을 고려하면, 토크 방정식은

$$\tau = ml^2\ddot{\theta} + mgl\cos(\theta) \quad (9)$$

이고, (8)을 이용하면

$$\begin{aligned} \ddot{e} &= -K_d(\dot{\theta}_d - \dot{\theta}) - K_p(\theta_d - \theta) \\ &+ [\ddot{\theta} \cos(\theta)] \left[\begin{array}{l} (\frac{ml^2}{\hat{m}\hat{l}^2} - 1) \\ (\frac{ml}{\hat{m}\hat{l}} - \frac{1}{\hat{l}})g \end{array} \right] \end{aligned} \quad (10)$$

과 같은 오차방정식을 얻을 수 있다. 그리고 (10)으로부터 진자 시스템에서의 고장 감지를 위한 ThMB 문턱값을 정할 수 있다.

III. 제안한 고장 감지 방법

3.1. 신경회로망

신경회로망은 입출력정보를 이용하여 주어진 비선형 시스템을 온라인 혹은 오프라인으로 모사하는데 사용되어진다. 다층 신경회로망은 그림 1과 같이 입력층, 은닉층 및 출력층으로 구성된다. 신경회로망을 학습시키는 방법은 실제시스템의 출력값과 신경회로망 출력값의 오차제곱합으로 정의되는 성능지수

$$E = \frac{1}{2} \sum_{k=1}^K (y_{dk} - y_k)^2 \quad (11)$$

를 감소시키는 방향으로 가중치를 갱신시키는 방법인 오류역전파 학습 알고리즘을 이용한다[7]. 여기서 K 는 출력노드의 개수이고, y_{dk} 는 모사 대상시스템의 k 번째 출력을 나타내며, y_k 는 신경회로망의 k 번째 출력으로서

$$y_k = \Gamma_k \left(\sum_{j=1}^J W_{jk} \Gamma_j \left(\sum_{i=1}^I V_{ij} x_i \right) \right) \quad (12)$$

으로 나타난다. 여기서 J 와 I 는 각각 은닉노드의 수와 입력노드의 수를, x_i 는 i 번째 입력을 나타내며, V_{ij} 와 W_{jk} 는 각각 i 번째 입력노드와 j 번째 은닉노드간의 가중치, j 번째 은닉노드와 출력층의 k 번째 노드간의 가중치이다. 신경회로망의 활성화함수 $\Gamma(\cdot)$ 는

$$\Gamma(x) = \frac{2}{1 + e^{-\lambda x}} - 1 \quad (13)$$

과 같은 시그모이드 함수를 사용한다. 여기서 λ 는 (13)의 기울기를 결정하는 값이며 본 논문에서는 $\lambda = 1$ 인 경우이다.

입력층과 은닉층 사이의 연결가중치는

$$V_{ij}(t+1) = V_{ij}(t) + \eta \Delta V_{ij}(t) \quad (14)$$

으로 갱신된다. 변화량 ΔV_{ij} 는

$$\begin{aligned} \Delta V_{ij} &= -\frac{\partial E}{\partial V_{ij}} \\ &= \frac{1}{2}(1-z_j^2) \sum_{k=1}^K \left\{ \frac{1}{2}(y_{dk}-y_k)(1-y_k^2)W_{jk} \right\} x_i \end{aligned} \quad (15)$$

로 계산되며, η 는 학습률이고 z_j 는 j 번째 은닉노드에서의 출력값이다.

유사한 방법으로, 은닉층과 출력층 사이의 연결가중치와 변화량 ΔW_{jk} 는 각각

$$W_{jk}(t+1) = W_{jk}(t) + \eta \Delta W_{jk}(t) \quad (16)$$

$$\begin{aligned} \Delta W_{jk} &= -\frac{\partial E}{\partial W_{jk}} \\ &= \frac{1}{2}(y_{dk}-y_k)(1-y_k^2)z_j \end{aligned} \quad (17)$$

으로 계산된다.




그림 1. 다층 신경회로망 구조.
Fig. 1. Structure of a multi-layer neural network.

3.2. 신경회로망을 이용한 동적 문턱값 결정

실제시스템과 모델시스템과의 오차는 매개변수의 값들과 모사하지 못한 불확실한 부분의 크기로 인해 발생한다. 매개변수 값들을 정확히 측정하였고, 불확실한 크기가 무시할 만큼 작다면 실제시스템이 모델시스템과 유사하여, ThMB방법만으로 고장을 감지할 수 있다. 그러나, 실제시스템은 불확실성이 존재하여 모델링 된 시스템과의 오차가 발생하고, 그로 인해 모델링 불확실성을 고려하지 않은 기존의 방법에 의해 계산된 동적 문턱값은 고장감지를 놓치거나 혹은 잘못된 고장감지를 할 수 있다.

본 논문에서 제안하는 동적인 문턱값 생성방법은 불확실성을 포함하는 시스템을 신경회로망과 ThMB방법을 이용하여 결정함으로써 신뢰성 있는 고장감지를 가능하게 하고자 한다.

모델링 불확실성을 가지는 시스템을

$$\ddot{q}_r(m, l, q, \dot{q}, t) = \ddot{q}_m(m, l, q, \dot{q}, t) + f_u(q, \dot{q}, t) \quad (18)$$

으로 나타낼 수 있다. 즉, 실제시스템(\ddot{q}_r)의 출력을 어떤 한 시점에 모델링 가능(\ddot{q}_m)한 부분의 출력과 불확실성을 가진 부분(f_u)의 출력으로 분리하였다. 그리고, 모델링 된 시스템의 출력오차 각가속도 \ddot{e}_m 를

$$\ddot{e}_m(m, l, q, \dot{q}, t) = \ddot{q}_d(t) - \ddot{q}_m(m, l, q, \dot{q}, t) \quad (19)$$

에서와 같이 원하는 각가속도(\ddot{q}_d)와 모델링가능한 각가속도(\ddot{q}_m)의 차이로 두었을 때, 공칭 관성질량(\hat{m})과 공칭 길이(\hat{l}) 및 실제질량(m)과 실제길이(l)를 이용한 ThMB 오차범위를

$$\ddot{e} + K_d \dot{e} + K_p e = M^{-1}[Y] \hat{p} \quad (20)$$

을 이용하여 매시간 문턱값을

$$\ddot{e}_l(q, \dot{q}, t) \leq \ddot{e}_m(m, l, q, \dot{q}, t) \leq \ddot{e}_u(q, \dot{q}, t) \quad (21)$$

와 같이 구할 수 있다. 여기서 K_d 와 K_p 는 토크계산제어의 계수들이며, \ddot{e}_l , \ddot{e}_m 과 \ddot{e}_u 는 각각 ThMB방법에서 구한 하위 및 상위 최대허용 문턱값이다.




그림 2. 제안한 고장감지 시스템 구성도.
Fig. 2. Structure of the proposed fault detection system.

신경회로망으로 실제시스템을 오프라인 학습한 후

$$\delta_{\min} + f_{nn}(q, \dot{q}) \leq \ddot{q}_r(\hat{m}, \hat{l}, q, \dot{q}, t) \leq \delta_{\max} + f_{nn}(q, \dot{q}) \quad (22)$$

과 같이 범위를 결정한다. 여기서 $f_{nn}(q, \dot{q})$ 은 오프라인 학습한 신경회로망의 출력을 나타내고, 실제시스템과 신경회로망 출력사이의 오차가 상위 최대오차(δ_{\max})와 하위 최대오차(δ_{\min}) 범위 내에 있다고 가정하며, 각각의 오차는 신경회로망의 학습결과에 의해 결정한다.

ThMB범위를 나타내는 (21)과 신경회로망 모사범위를 나타내는 (22)로부터

$$\begin{aligned} \ddot{e}_l - \delta_{\max} - f_{nn} &\leq \ddot{e}_m(m, l, t) - \ddot{q}_r(\hat{m}, \hat{l}, t) \\ &\leq \ddot{e}_u - \delta_{\min} - f_{nn} \end{aligned} \quad (23)$$

을 얻을 수 있고, 이를 재구성하면 다음과 같다.

$$\begin{aligned} \ddot{e}_l - \delta_{\max} - f_{nn} + \ddot{q}_m(m, l, t) &\leq \ddot{q}_d(t) - \ddot{q}_r(\hat{m}, \hat{l}, t) \\ &\leq \ddot{e}_u - \delta_{\min} - f_{nn} + \ddot{q}_m(m, l, t) \end{aligned} \quad (24)$$

(24)는 제안한 동적 문턱값을 구하는 수식으로서, 이를 이용하여 불확실성이 있는 시스템의 동적 문턱값을 구할 수 있다. 동적 문턱값에 의한 고장감지방법은 그림 2에 나타나 있다. 즉, 시스템의 출력(so)과 원하는 값과의 차이가 문턱값 상위범위(up)보다 크거나 하위범위(lb)보다 작다면 고장이 발생하였음을 감지할 수 있다.

IV. 모의실험 결과

본 논문에서 제안한 고장감지 알고리즘을 진자에 적용하여 모의실험을 하였다. 사용된 진자시스템은

$$\tau = ml^2\ddot{\theta} + mg\ell\cos(\theta) + f_u(q, \dot{q}, t) \quad (25)$$

이며, 토크계산제어기에서의 제어출력토크는

$$\tau = \hat{M}(q)(\ddot{q}_d + K_d\dot{e} + K_p e) + \hat{N}(q, \dot{q}) \quad (26)$$

이다. 모의실험에 사용된 모델링 불확실성($f_u(q, \dot{q}, t)$) [9][10]은

$$\begin{aligned} f_u(q, \dot{q}, t) &= F(\dot{q}) + \tau_d \\ &= 5 \sin(\dot{q}) + 2\dot{q} + 0.5 \sin(30t) \end{aligned} \quad (27)$$


으로 두었다. 여기서 $F(\dot{q})$ 는 미지의 마찰이고, τ_d 는 미지의 외란을 나타낸다.

모의실험에서 사용되어진 공칭 질량(\hat{m})과 공칭 길이(\hat{l})는 각각 10kg과 1m라고 두었으며, 실제시스템의 질량과 길이는 각각 10.7kg과 1.009m이고, 시간 $t = 0.1$ 에서부터 움직인다고 가정하였다. 모의실험에서 고장감지를 위해 사용한 신경회로망은 하나의 은닉층을 가지며, 입력노드, 은닉노드 및 출력노드의 개수를 각각 6개, 17개, 1개로 두었으며, 학습률(η)은 3.2로 임의로 두어, 2000개의 표본으로 10000번의 반복학습을 하였다. 신경회로망을 오프라인으로 학습한 후 실제시스템과의 최대 오차를 $\delta_{max} = 0.102$, $\delta_{min} = -0.125$ 로 설정하였다.


임의로 발생시킨 고장은 시스템의 질량 m 이 감소 또는 증가하는 경우로서, 먼저 $t = 10$ 에서 시스템의 질량 m 이 아래와 같이 점차적으로 감소하는 고장이 발생되었을 때의 고장감지결과를 비교한다.

$$m = \begin{cases} 10.7 & (0 \leq t < 10) \\ 10.7 * (1 - 0.065 * (t - 10)) & (10 \leq t \leq 13) \\ 8.6135 & (13 < t) \end{cases} \quad (28)$$

시스템의 질량 m 이 $t = 10$ 에서 (28)과 같은 양으로 감소하는 고장이 발생한 경우에 ThMB방법을 적용하여 고장감지를 수행한 결과가 그림 3에 나타나 있으며, 그림 3(a)는 각속도 오차의 상위범위 및 하위범위를 나타내며, 그림 3(b)는 각가속도 오차의 상위범위 및 하위범위를 나타내고 있다. 이 결과로부터 시스템의 고장감지를 ThMB 방법만을 사용하면 모델링 불확실성을 고려하지 않음으로 인해 고장이 발생하지 않은 시간인 8초 전후에서 각속도 및 각가속도 오차가 상한 문턱값보다 크게 되어 고장이 발생되지 않았음에도 불구하고 잘못된 고장감지(false alarm)를 함을 알 수 있다. 반면에 모델링 불확실성을 고려하여 ThMB와 신경회로망을 이용한 제안한 방법에 의한 결과를 그림 4에 나타내었다. 그림 4(a)는 각속도 오차의 상위범위 및 하위범위를 나타내며, 그림 4(b)는 각가속도 오차의 상위범위 및 하위범위를 나타내고 있다. 결과들




(a) 각속도 오차와 ThMB 문턱값




(b) 각가속도 오차와 ThMB 문턱값

그림 3. 질량 감소일 경우.

Fig. 3. Decreasing of mass.



(a) 각속도 오차와 제안한 문턱값



(b) 각가속도 오차와 제안한 문턱값

그림 4. 질량 감소일 경우.


Fig. 4. Decreasing of mass.

로부터 제안한 방법을 이용할 경우에는 모델링 불확실성


에 의한 잘못된 고장감지가 발생하지 않았으며, 고장이 발생한 후 각속도 및 각가속도 오차가 하한 문턱값을 넘게 되므로서 정확하게 고장감지를 함을 알 수 있다.

다음으로 질량이 증가하는 고장이 발생한 경우로서, $t = 10$ 에서 고장이 발생하여 $t = 13$ 까지 아래와 같이 점차적으로 질량이 증가하였을 때의 고장감지결과를 비교한다.

$$m = \begin{cases} 10.7 & (0 \leq t < 10) \\ 10.7 * (1 + 0.065 * (t - 10)) & (10 \leq t \leq 13) \\ 12.7865 & (13 < t) \end{cases} \quad (29)$$



a) 각속도 오차와 ThMB 문턱값

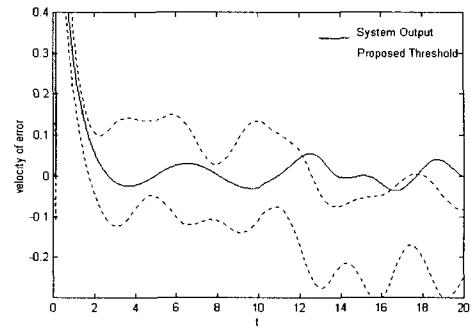


b) 각가속도 오차와 ThMB 문턱값


그림 5. 질량 증가일 경우.

Fig. 5. Increasing of mass.

플랜트의 질량이 10초부터 (29)와 같은 양으로 증가하는 고장이 발생한 경우에 ThMB방법 및 제안한 방법에 의한 고장감지 결과가 각각 그림 5 및 6에 나타나 있다. 그림 5(a) 및 (b)는 ThMB방법을 이용한 경우의 고장감지 결과로서 각각 각속도 및 각가속도에 의한 고장감지결과를 도시한 것으로서, 모델링 불확실성으로 인해 고장이 발생하지 않은 시간인 8초 전에 각속도 및 각가속도 오차가 상한 문턱값보다 크게 되어 고장이 발생되지 않았음에도 불구하고 잘못된 고장감지를 함을 알 수 있다. 반면에 그림 6(a) 및 (b)의 결과들로부터 신경회로망을 이용한 제안한 방법을 이용할 경우에는 모델링 불확실성에 의한 잘못된 고장감지가 발생하지 않았으며, 고장이 발생된 후 각속도 및 각가속도 오차가 상한 문턱값을 넘게 되므로서 정확하게 고장감지를 함을 알 수 있다.



a) 각속도 오차와 제안한 문턱값



b) 각가속도 오차와 제안한 문턱값

그림 6. 질량 증가일 경우.

Fig. 6. Increasing of mass.

V. 결론

본 논문에서는 불확실성이 있는 비선형 시스템의 고장 감지를 위한 동적인 문턱값을 설정하는 방법을 제안하였다. 동적인 문턱값 설정방법에는 ThMB방법과 RMI방법이 있지만, 실제시스템을 모델링 할 경우 존재하는 모델링 불확실성 부분으로 인해 잘못된 고장감지가 발생한다. 이러한 단점을 보완하기 위하여 모델링 불확실성이 있는 시스템의 고장감지를 위한 동적 문턱값을 신경회로망과 ThMB방법을 상호 결합하여 결정하였다. 즉, 실제시스템에 존재하는 모델링 불확실성 부분을 신경회로망을 이용하여 오프라인으로 모사한 후, 기존의 ThMB방법을 기준으로 신경회로망과 상호 결합하여 고장감지용 문턱값을 결정하는 방법이다.

고장이 서서히 발생할 경우에 대하여 모의실험을 실시하였으며, 기존의 ThMB방법에서는 모델링 불확실성이 존재하는 경우에는 고장이 발생하지 않았음에도 불구하고 고장이 발생하였다는 잘못된 고장감지결과를 발생시켰지만, 제안한 방법에서는 모델링 불확실성을 고려하므로써 불확실성으로 인한 잘못된 고장감지를 방지하고 정확한 고장감지가 이루어짐을 알 수 있었다. 앞으로 남은 연구 과제는 사용된 신경회로망의 학습속도 개선 및 신속한 고장감지를 도모하는 것이다.

참고문헌

[1] J. Chen and R. J. Patton, *Robust Model-Based Fault Diagnosis for Dynamic Systems*, Kluwer Academic Publishers, Mass, 1999.

[2] D. T. Horak and B. H. Allison, "Experimental implementation and evaluation of the RMI failure detection algorithm," *Proc. Amer. Cont. Conf.*, pp. 1803-1810, 1987.

[3] M. L. Visinsky, I. D. Walker, and J. R. Cavallaro, "New dynamic model-based fault detection thresholds for robot manipulators," *IEEE Int. Conf. Robot. and Automat.*, pp. 1388-1395, 1994.

[4] M. L. Visinsky, J. R. Cavallaro, and I. D. Walker, "A dynamic fault tolerance framework for remote robots," *IEEE Trans. Robot. and Automat.*, vol. 11, no. 4, pp. 477-490, 1995.

[5] M. L. Visinsky, J. R. Cavallaro, and I. D. Walker, "Dynamic sensor-based fault detection for robots," *SPIE Conf. Telem manipulator Technol. and Space Robot.*, pp. 385-396, 1993.

[6] M. W. Spong and M. Vidyasagar, *Robot Dynamics and Control*, John Wiley & Sons, Inc., NY, 1989.

[7] J. M. Zurada, *Introduction to Artificial Neural Network Systems*, West Publishing Company, MN, 1992.

[8] A. T. Vemuri, *Learning methodologies for non-linear fault diagnosis and accommodation*, Ph. D. dissertation, University of Cincinnati, OH, 1996.

[9] A. T. Vemuri and M. M. Polycarpou, "Neural network based robust fault diagnosis in robotic systems," *IEEE Trans. Neural Networks*, vol. 8, no. 6, pp. 1410-1419, 1997.

[10] Z. Qu, D. M. Dawson, and J. H. Dorsey, "Exponentially stable trajectory following of robotic manipulators under a class of adaptive control," *Automatica*, vol. 28, pp. 579-586, 1992.



소 병 석

1972년 5월 15일생. 1997년 대구대학교 제어계측공학 졸업. 2000년 경북대학교 대학원 전자공학과 석사. 2000년 ~ 현재 삼성전자 중앙연구소 연구원. 관심분야는 고장진단, 신경회로망, 퍼지 제어.



이 인 수

1963년 4월 16일생. 1986년 경북대학교 전자공학과 졸업. 1989년 동대학원 석사. 1997년 동대학원 박사. 1997년~ 현재 국립상주대학교 전자전기공학과 조교수. 관심분야는 시스템의 고장진단 및 고장허용제어, 지능제어 및 응용, 공장자동화등.

전 기 준

제어 · 자동화 · 시스템공학 논문지 제2권, 제1호, 참조.