SVM과 신경회로망을 이용한 비선형시스템의 고장검지와 분류방법 연구

A Study on a Fault Detection and Isolation Method of Nonlinear Systems using SVM and Neural Network

이 인 수*, 조 정 환, 서 해 문, 남 윤 석
(In Soo Lee¹, Jung Hwan Cho², Hae Moon Seo³, and Yoon Seok Nam⁴)

¹Kyungpook National University

²University of Massachusetts Lowell

³Korea Electronics Technology Institute

⁴Dongguk University

Abstract: In this paper, we propose a fault diagnosis method using artificial neural network and SVM (Support Vector Machine) to detect and isolate faults in the nonlinear systems. The proposed algorithm consists of two main parts: fault detection through threshold testing using a artificial neural network and fault isolation by SVM fault classifier. In the proposed method a fault is detected when the errors between the actual system output and the artificial neural network nominal system output cross a predetermined threshold. Once a fault in the nonlinear system is detected the SVM fault classifier isolates the fault. The computer simulation results demonstrate the effectiveness of the proposed SVM and artificial neural network based fault diagnosis method.

Keywords: fault detection, fault isolation, SVM, artificial neural network, nonlinear system

I. 서론

제어시스템의 신뢰성 및 안전성 확보를 위해서는 시스템에서 발생하는 고장을 조기에 감지하고 분류할 수 있는 고장진단시스템의 개발이 절대적으로 필요하다. 이는 시스템에서의 고장은 생산성의 저하를 초래할 뿐만 아니라 심지어는 사람의 생명까지도 위협할 정도로 파급효과가 크기 때문이다.

기존에 연구된 고장진단방법은 크게 모델에 기반한 방법과 모델에 기반하지 않는 방법으로 분류할 수 있다. 먼저, 모델에 기반한 방법에서는 고장진단을 위해서 시스템의 정확한 정량적모델을 필요로 하므로 불확실성이 존재하고 비선형성이 강한 시스템에는 적용이 어렵다는 문제점이 있다 [1-3].

이에 반해서 모델에 근거하지 않는 방법은 대상 시스템의 측정치, 경험 또는 물리적 검토를 기초로 하며, 한계치 검사, 전문가 시스템 기법 및 신경회로망 이용 방법[4,5] 등이 있다. 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 분류한다. 그러나 사전에 모든 고장에 대한 모델을 구축하는 것은 매우 어렵다는 단점이 있다. 이에 대한 해결책으로서 ART (Adaptive Resonance Theory) 신경회로망을 이용하는 연구가 있었다[5,6]. 그러나 참고문헌 [6]에서는 선형시스템의 고장진단방법에 관한 연구결과를 제시했으며, 참고문헌 [7]에서 제시한 방법은 신경회로망 다중모델을 이용한 비선형시스템의 고장진단방법으로서 고장의 분류를 위해서는 다중고장모델을 정확하게 구축해야 한다는 문제점이 있었다.

최근에는 Vapnik [8]에 의해 개발된 통계적 학습이론을 기반으로 하는 SVM (Support Vector Machine)을 필기체 숫자인식 뿐만 아니라 유도전동기의 고장진단에 이용하는 연구결과들이 발표된 바 있다[9-12].

본 논문에서는 비선형시스템에서 발생하는 고장을 감지하고 분류하기 위해 인공신경회로망과 SVM을 이용한 고장검지와 분류 방법을 제안한다[13]. 제안한 고장진단 알고리즘은 고장검지부 및 고장분류부로 구성된다. 즉, 고장검지부에서는 시스템의 출력과 다중신경회로망 공칭모델 출력과의 오차가 미리 설정한 문턱값을 넘으면 비선형시스템에서 발생한 고장을 감지한다[7]. 일단 고장이 감지되면 시스템에서 발생한 고장의 종류를 알아내기 위해 미리 설정한 분류원도우내에서의 출력데이터를 획득한다. 다음으로 획득한 시스템출력과 SVM 고장분류기를 이용하여 시스템에서 발생한 고장의 종류를 분류한다.

* 책임저자(Corresponding Author)

논문접수: 2012. 4. 30., 수정: 2012. 5. 17., 채택확정: 2012. 5. 22.

이인수: 경북대학교 산업전자공학과(insoolee@knu.ac.kr)

조정환: 미국 매사추세츠 로웰대학교 도시환경공학과 Post doc.

(junghwan_cho@uml.edu)

서해문: 전자부품연구원 선임연구원(bmoons@keti.re.kr)

남윤석: 동국대학교 경주캠퍼스 정보통신공학과 교수

(ysnam@dongguk.ac.kr)

※ 이 논문은 2012 제 27회 ICROS 학술대회에 초안이 발표되었음.

II. 제안한 고장감지 및 분류방법

제안한 고장진단시스템은 그림 1과 같이 비선형시스템에서 발생하는 고장을 감지하기 위한 고장감지부와 발생한 고장의 종류를 분류하기 위한 고장분류부로 이루어져 있다. 즉, 다층신경회로망과 문턱값 비교방법에 의해서 고장을 감지하면 고장분류를 위해 설정한 분류윈도우내에서의 출력 데이터를 획득하며 이를 이용하여 SVM 고장분류기에 의해 발생한 고장의 종류를 분류한다.

1. 신경회로망을 이용한 고장감지

고장진단을 위한 대상 시스템은 아래와 같은 이산시간 비선형시스템으로 가정한다.

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

여기서 $u(k)$, $y(k)$ 는 각각 시스템의 입력과 출력, $g(\cdot)$ 의 비선형함수이며, $\epsilon(k)$ 는 백색 잡음이라고 가정한다.

본 논문에서는 고장감지를 위해 그림 2와 같은 다층 신경회로망을 이용하여 비선형시스템의 공칭모델을 구축한다. 사용한 다층 신경회로망은 입력층, 중간층과 출력층으로 이루어져 있으며 신경회로망의 학습을 위해서는 일반적으로 많이 이용되는 역전파(back-propagation) 알고리즘을 이용하였다[14]. 최소화해야 할 성능지수 및 출력오차를 각각 아래와 같이 정의하며 식 (2)를 최소화하는 방향으로 신경회로망을 학습하여 고장감지를 위한 공칭모델을 구축한다.

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

$$e_n(k) = y(k) - y_n(k) \quad (3)$$

여기서 y_n 은 신경회로망 공칭모델의 출력이다.

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

그림 1. 제안한 고장진단방법의 구조도.

Fig. 1. Structure of the proposed fault diagnosis method.

그림 2. 다층 신경회로망의 구조도.

Fig. 2. Architecture of the multilayer neural network.

$$J_n(k) = \sum_{i=k-L+1}^k e_n^2(i) > \delta_f \quad (4)$$

여기서 $e_n(i)$ 는 식 (3)과 같이 시스템 출력과 신경회로망 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[15]. 따라서 시스템 출력과 공칭모델 출력사이의 오차 e_n 은 정규분포 $N(0, \sigma^2)$ 를 따르므로 윈도우내에서의 L 개의 정규화된 자승오차 $\frac{e_n^2(i)}{\sigma^2}$

의 합은 아래와 같이 자유도가 L 인 χ_L^2 (chi-square) 분포를 따르게 된다.

$$\bar{J}_n(k) = \sum_{i=k-L+1}^k \frac{e_n^2(i)}{\sigma^2} \sim \chi_L^2 \quad (5)$$

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

$$\Pr \left(\sum_{i=k-L+1}^k \frac{e_n^2(i)}{\sigma^2} > \delta^\circ \right) = \alpha \quad (6)$$

이므로 χ^2 분포표로부터 상수 δ° 를 구한 뒤 이로부터 고장감지를 위한 문턱값 $\delta_f = \sigma^2 \delta^\circ$ 를 구한다. 그러나 고장으로 인한 시스템 파라미터 변화가 작은 시스템의 경우에는 위에서 구한 δ_f 가 너무 커서 실제 고장에 의한 시스템 파라미터의 변화를 감지하지 못하는 경우가 발생할 수도 있으므로, 통계적 방법에 의해서 구한 δ_f 를 기준값으로 해서 경험적 요소를 고려하여 고장감지 문턱값을 적절하게 선정할 필요가 있다.

그림 3. SVM에 의한 클래스분류.

Fig. 3. Separation of two classes by SVM.

2. SVM을 이용한 데이터 전처리 및 분류

SVM은 Vapnik [8]에 의해 개발된 학습알고리즘으로서 원래 이진분류기(binary classifier)였다. 즉, 그림 3과 같이 특징공간에서 초평면(hyperplane)과 가장 인접한 지지벡터(support vectors)들과의 거리인 여유(margin)를 최대로 하는 최대여유초평면(maximum margin hyperplane)을 찾아서 이진 분류를 수행한다.

그러나 모든 내적(inner product)을 비선형 커널함수(kernel function)로 교체함으로써 최대여유초평면이 원래의 입력공간보다는 훨씬 더 큰 차원을 가지는 비선형 사상(mapping) 특징공간에 적합하게 되었으며 이로 인해 비선형 분류가 가능한 분류기를 설계할 수 있다.

본 논문에서는 SVM (Support Vector Machine)을 비선형성 시스템에서 발생하는 고장을 분류하는 문제에 적용하였다. 즉, 시스템에서 발생한 고장이 감지되면 발생한 고장의 분류를 위해 설정한 분류윈도우내에서의 출력데이터를 획득하며 이를 이용하여 SVM 고장분류기에 의해 발생한 고장의 종류를 알아낸다.

고장감지 후에 고장의 종류를 분류하기 위해 데이터를 획득하는 분류윈도우의 크기는 크게 하면 분류의 신뢰도는 증가하나 데이터 획득시간이 많이 소요되므로 고장분류가 늦어진다. 반면에 분류윈도우 크기가 너무 작으면 고장분류를 위한 시간은 짧아지나 고장분류의 신뢰도가 낮아지므로 적절히 선정한다.

III. 시뮬레이션 결과 및 고찰

제안한 SVM과 신경회로망을 이용한 고장감지 및 분류 방법의 성능 검증을 위한 비선형시스템은 아래와 같다.

$$y(k) = \cos(3.14p_1)y(k-1) - 0.7y(k-2) + u(k-1) + p_2u(k-2) + \epsilon(k) \quad (7)$$

여기서 $u(k)$, $y(k)$ 는 각각 시스템의 입력과 출력으로서 시스템의 입력 $u(k) = 0.5 \cos(k)$ 이다. 그리고 $\epsilon(k)$ 는 분산이 2.56×10^{-4} 인 백색잡음이며 p_1 과 p_2 는 물리적계수로서 공칭값은 각각 0.56 및 0.37이다. 그리고 시스템이 정상적으로 동작함에도 불구하고 잡음만에 의해 고장으로 감지되는 허위고장신호 발생확률을 최대한 줄이기 위해 $\alpha =$

0.01(1%)로 설정했고 식 (6)으로부터 고장감지를 위한 문턱값 δ_f 를 구하면 0.013이며, 고장감지를 위한 윈도우 크기 L 은 30으로 설정하였다. 또한 고장감지를 위한 다층 신경회로망 공칭모델의 입력층, 은닉층 및 출력층의 노드수는 각각 4개, 10개 및 1개로서 신경회로망의 입력은 $u(k-1)$, $u(k-2)$, $y(k-1)$, $y(k-2)$ 이다. 신경회로망의 은닉층 노드수는 학습성능에 큰 영향을 미치는데 본 논문에서는 여러 번의 시뮬레이션을 통해서 신경회로망 공칭모델이 시스템이 정상일 때를 가장 잘 묘사할 수 있도록 은닉층의 수를 10개로 선택하였다. 신경회로망 학습을 위한 학습률 η 와 모멘텀 α 는 각각 0.15 및 0.1로 설정하였다. 그리고 SVM 고장분류기의 학습을 위해서는 가우시안(gaussian) 커널함수를 사용하였고, 고장감지 후에 분류를 위한 분류윈도우의 크기는 15로 했으며 획득한 15개의 시스템 출력데이터와 SVM에 의해 고장을 분류한다.

일반적으로 시스템에서의 고장은 이득, 저항값, 캐패시턴스 등과 같은 물리적 파라미터의 변화 혹은 기계적인 마모 등에 의해 발생하며 이러한 요소들의 변화는 결국 시스템 모델 파라미터를 변화시킨다. 그러므로 제한한 고장진단 방법의 성능을 알아보기 위해서 물리적인 계수들의 값을 인위적으로 변화시킴으로써 시스템에서의 고장상황을 다음과 같이 두 가지로 발생시켰다.

고장 #1 : p_1 이 감소

고장 #2 : p_1 이 증가

먼저 고장감지를 위해 시스템이 정상일 때의 다층신경회로망 공칭모델을 구축하였다. 실제 시스템 출력과 신경회로망 공칭모델과의 오차(식 (4))를 도시하면 그림 4와 같으며, 신경회로망 공칭모델이 실제 비선형시스템을 잘 묘사할 수 있게 충분히 학습되었음을 알 수 있다.

다음으로 두 가지 고장상황에 대한 고장진단결과를 알아본다. 아래의 결과는 이미 고장 #1 ($p_1 = 0.4$ 로 감소)과 고

그림 4. 시스템출력과 신경회로망 공칭모델출력과의 오차.

Fig. 4. Errors between system output and neural network nominal model output.

장 #2 ($p_1 = 0.8$ 로 증가)이 발생하여 세 개의 고장클래스 (SVM의 출력인 고장클래스 1은 시스템이 정상상태인 경우, 고장클래스 2는 고장 #1의 경우, 고장클래스 3는 고장 #2의 경우를 의미한다)가 자동 생성된 뒤 테스트한 결과이다. 그림 5는 150번째 순간에 고장 #1 ($p_1 = 0.35$ 로 감소)이 다시 발생했을 때의 결과들로서 5(a)는 시스템출력과 신경회

로망 출력을 도시한 것이며, 5(b)는 고장 #1의 발생으로 인해 고장 발생순간부터 J_n 이 증가했음을 보여주고 있으며 152번째 순간에 윈도우 내에서 시스템출력과 공칭모델과의 차승오차합이 고장감지 문턱값을 넘어 고장을 감지하였음을 알 수 있다. 그리고 그림 5(c)는 고장감지 후에 분류윈도우내에서 15개의 데이터를 획득한 뒤에 이들 출력데이터

(a) System output and neural network output (nominal system output(dashed line), system output(solid line).

(b) Change of J_n and fault detection (dashed line: δ_f).

(c) Fault classification result by SVM.

그림 5. 고장 #1에 대한 고장감지와 분류결과.

Fig. 5. Results of detection and isolation for fault #1.

(a) System output and neural network output (nominal system output(dashed line), system output(solid line))

(b) Change of J_n and fault detection (dashed line: δ_f).

(c) Fault classification result by SVM.

그림 6. 고장 #2에 대한 고장감지와 분류결과.

Fig. 6. Results of detection and isolation for fault #2.

를 사용하여 SVM으로 분류한 결과로서 SVM 고장분류기가 167번째 순간에 고장클래스 2를 출력하였으며 이는 현재 시스템에는 고장 #1이 발생되었음을 의미하는 것으로써 SVM 고장분류기가 시스템에서 발생한 고장을 정확하게 분류함을 알 수 있다.

다음으로 고장 #2 ($p_1 = 0.85$ 로 증가)가 다시 발생했을 때의 고장감지 및 분류결과는 그림 6과 같다. 즉, 6(a)는 150번째 순간에 p_1 이 증가하는 고장 #2가 발생했을 때의 시스템출력과 신경회로망 공칭모델 출력을 나타낸 것이며, 6(b)는 고장감지결과로서 152번째 순간에 윈도우 내에서의 시스템출력과 신경회로망 공칭모델과의 자승오차합이 고장감지 문턱값을 넘어 고장이 감지되었음을 알 수 있다. 그리고 6(c)는 SVM 고장분류기의 분류결과로서 시스템에서 발생한 고장의 종류를 고장 #2로 잘 분류함을 알 수 있다.

IV. 결론

본 논문에서는 비선형시스템에서 발생하는 고장을 감지하고 분류하기 위해 다층신경회로망과 SVM (Support Vector Machine)을 이용한 고장진단방법을 제안하였다. 제안한 고장진단알고리즘은 시스템에서 발생한 고장감지를 위한 고장감지부와 발생한 고장의 종류를 알아내기 위한 고장분류부로 이루어져 있다. 즉, 시스템의 출력과 다층신경회로망 공칭모델 출력과의 오차가 미리 설정한 문턱값을 넘으면 고장을 감지한다. 일단 시스템에서 고장이 발생되었음이 감지되면 발생한 고장의 종류 분류를 위해 미리 설정한 분류윈도우내에서의 출력데이터를 획득하며 이를 이용하여 SVM 고장분류기에 의해 시스템에서 발생한 고장의 종류를 알아낸다. 시뮬레이션결과들로부터 제안한 다층신경회로망과 SVM 기반 고장감지와 분류방법이 비선형시스템의 고장진단문제에 잘 적용됨을 알 수 있었다. 앞으로의 연구과제는 본 논문에서 제안한 고장진단 방법을 실제 시스템에 적용하는 것이다.

참고문헌

- [1] J. Wagner and R. Shoureshi, "A failure isolation strategy for thermofluid system diagnostics," *ASME Journal of Engineering 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] J. H. Choi, D. An, and J. H. Gang, "A survey on prognostics and comparison study on the model-based prognostics," *Journal of Institute of Control, Robotics and Systems (in Korean)*, vol. 17, no. 11, pp. 1095-1100, 2011.
- [4] J. C. Hoskins and D. M. Himmelblau, "Artificial neural network models of knowledge representation in chemical engineering," *Computers and Chemical Engineering*, 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 and Chemical Engineering*, vol. 14, no. 7, pp. 699-712, 1990.
- [6] I. S. Lee, P. J. Shin, and G. J. Geon, "Diagnosis of a linear system using ART2 neural networks," *Journal of Control, Automation and System Engineering (in Korean)*, vol. 3, no. 3, pp. 244-251, 1997.
- [7] I. S. Lee, "Fault detection and isolation of the nonlinear systems using neural network-based multi-fault models," *The Institute of Electronics Engineers of Korea (in Korean)*, vol. 39-S, no. 1, pp. 42-50, 2002.
- [8] V. N. Vapnik, *The Nature of Statistical Learning Theory*, John Wiley and Sons, 1999.
- [9] J. J. Park, T. W. Kim, and K. M. Kim, "Handwritten numerical recognition using composite features and SVM classifier," *Journal of Korea Institute of Maritime Information & Communication Sciences (in Korean)*, vol. 14, no. 12, pp. 2761-2768, 2010.
- [10] B. A. Kumar, G. Saranya, R. S. Kumar, R. S. Shree, M. Saranya, and E. P. Sumesh, "Fault detection in induction motor using WPT and multiple SVM," *International Journal of Control and Automation*, vol. 3, no. 2, pp. 9-20, 2010.
- [11] D. J. Lee, C. K. Song, J. K. Lee, and M. G. Chun, "Fault diagnosis of induction motor by hierarchical classifier," *Journal of Control, Automation and System Engineering (in Korean)*, vol. 13, no. 6, pp. 513-518, 2007.
- [12] P. Konar and P. Chattopadhyay, "Bearing fault detection of induction motor using wavelet and support vector machines (SVMs)," *Applied Soft Computing*, vol. 11, pp. 4203-4211, 2011.
- [13] I. S. Lee, J. H. Cho, H. M. Seo, and Y. S. Nam, "Fault detection and isolation of nonlinear system based on SVM and artificial neural network," *2012 27th ICROS Annual Conference (in Korean)*, pp. 408-409, 2012.
- [14] D. E. Rumelhart and J. L. McClelland, *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*. vol. 1, MIT Press, Reading, MA, 1986.
- [15] J. D. Cryer, *Time Series Analysis*, Duxbury Press, 1986.

이 인 수

1986년 경북대학교 전자공학과 졸업.
1989년 동 대학원 석사. 1997년 동 대학원 박사. 2005년 8월~2007년 1월 까지 미국 샌디에고 주립대학교 Research scholar. 1997년~2008년 2월까지 상주대학교 전자전기공학부 교수. 2008년 3월~현재 경북대학교 과학기술대학 산업전자공학과 교수. 관심분야는 시스템의 고장진단 및 고장허용제어, 지능제어 및 응용, 지능형센서시스템, 공장자동화.

조 정 환

2001년 경상대학교 제어계측공학과 졸업. 2003년 경북대학교 전자공학과 석사. 2008년 동 대학원 박사. 2009년 2월~현재 미국 매사추세츠 로웰대학교 도시환경공학과 Post doc. 관심분야는 전자후각시스템, 패턴인식, 지능형센서 시스템, 뉴로퍼지.

서 해 문

1998년 경북대 전자공학과 졸업. 2000년 동 대학원 석사. 2009년 동 대학원 박사. 2004년 삼성전자 통신연구소/SoC R&D 센터 선임연구원. 2004년~현재 전자부품연구원 선임연구원. 관심분야는 Sensing SoC, USN, 무선통신 SoC, 무선통신시스템.

남 윤 석

1984년 경북대 전자공학과 졸업. 1987년 동 대학원 석사. 1995년 동 대학원 박사. 1987년~2000년까지 한국전자통신연구원 책임연구원. 2000년~현재 동국대학교 경주캠퍼스 정보통신공학과 교수. 관심분야는 무선측위시스템, WPAN 시스템, 통신프로토콜.