

페루프 제어 시스템을 위한 퍼지-신경망 기반 고장 진단 시스템의 개발

Development of Neuro-Fuzzy-Based Fault Diagnostic System for Closed-Loop Control System

김 성 호, 이 성 룡, 강 정 규
(Sung-Ho Kim, Seong-Ryong Lee, and Jung-Kyu Kang)

Abstract : In this paper an ANFIS(Adaptive Neuro-Fuzzy Inference System)-based fault detection and diagnosis for a closed loop control system is proposed. The proposed diagnostic system contains two ANFIS. One is run as a parallel mode within the model in closed loop control(MCL) and the other is run as a series-parallel mode within the process in closed loop(PCL) for the generation of relevant symptoms for fault diagnosis. These symptoms are further processed by another classification logic with simple rules and neural network for process and controller fault diagnosis. Experimental results for a DC shunt motor control system illustrate the effectiveness of the proposed diagnostic scheme.

Keywords : fault detection & diagnosis, adaptive neuro-fuzzy inference system(ANFIS), process fault, controller fault, DC shunt motor

I. 서론

최근 산업용 프로세스의 가장 두드러진 특징은 자동화와 집적화라 할 수 있다. 이러한 경향은 프로세스의 고성능화, 다기능화를 가능하게 한다는 입장에서는 필수적이지만 요구되는 바의 신뢰도, 안전성 및 경제성의 확보를 위한 고성능의 감시 및 고장진단시스템(FDI: Fault Detection and Identification)의 개발은 어느 때보다도 절실히 요구되고 있다.

일반적으로 FDI는 고장 검출을 위한 증상의 발생과 이에 근거한 진단 메커니즘을 포함한다. 증상발생기법은 크게 해석적 기법과 정성적 기법으로 구분할 수 있으며 이중 해석적 기법에는 상관함수, FFT 등의 주파수 특성을 이용한 신호해석기법과 파라미터, 상태변수 추정 및 패러티 방정식들을 이용한 모델기반 해석기법이 있다. 모델기반 해석기법은 지난 20년간 Wilsky, Iserman 등에 의해 저차 선형 프로세스의 구동장치 및 측정장치 등의 고장진단에 광범위하게 연구되어 왔다[1][4]. 그러나 모델기반 해석기법은 근본적으로 계통에 대한 정확한 수학적 모델을 요구하므로 불확실성을 포함한 계통, 대규모 계통 및 비선형성이 강한 계통에의 적용성이 곤란하다는 문제점을 갖는다. 이에 반해 정성적 기법은 계통에 대한 정확한 수학적 모델을 요구하지 않으면서도 고장의 검출 및 진단을 수행할 수 있다는 점 때문에 최근 이에 대한 연구가 활발히 진행되고 있다. 이의 대표적인 예로 최근 고장진단 분야에 적극적으로 도입되고 있는 신경망 기반 진단기법을 들 수 있다. 신경망 기반 진단기법은 비선형성이 강한 고장 데이

터가 주어질 경우, 학습시킨 패턴들에 대해서도 정확한 진단을 수행할 수 있을 뿐만 아니라 약간의 오차가 존재하는 패턴들에 대해서도 어느 정도 신뢰할 수 있는 결과를 얻을 수 있다는 점 때문에 고장진단 분야에서 적극적으로 도입되고 있다[5]~[8]. 그러나 이들 기법 대부분은 신경망이 갖는 고유의 비선형 분리기능만을 이용한 것으로 신경망 내부에 분산 저장되어 있는 시스템 및 고장과 관련된 유용한 정보를 활용하지 못하고 있다.

Jang 등은 퍼지 추론을 수행하는 퍼지-신경망(ANFIS: Adaptive Neuro-Fuzzy Inference System)의 후건부를 입력에 대한 선형 다항식으로 대체한 새로운 형태의 퍼지-신경망을 제안하고 이를 비선형 계통의 모델링 및 제어에 적용한 바 있다[9]. 이러한 퍼지-신경망은 내부에 모델링하고자 하는 비선형 시스템에 대한 구간별 선형화모델을 갖는다. 또한 비선형 시스템의 모든 상태를 여기시킬 수 있는 입력과 이때의 출력을 학습에 이용한다면 학습완료된 퍼지-신경망은 비선형 시스템의 정적 및 동적 특성을 효과적으로 표현하는 것이 가능하게 된다. 이에 본인 등은 학습된 퍼지-신경망의 후건부에 분산저장된 시스템과 관련된 정보를 활용하여 고장진단의 성능을 향상시킬 수 있는 퍼지-신경망 기반 고장진단 시스템을 제안한 바 있다[10]. 기제안된 시스템은 진단 대상 프로세스와 직렬 및 병렬로 구동되는 두 개의 퍼지-신경망을 갖으며 고장 진단에 사용되는 증상 패턴으로 각 퍼지-신경망 후건부에 존재하는 선형화 파라미터들간의 잔차를 이용하였다. 그러나 기제안된 시스템은 원천적으로 개루프로 운용되고 있는 시스템에만 적용이 가능하다는 적용상의 한계를 갖는다. 따라서 본 논문에서는 진단 대상 프로세스가 제어되고 있는 상황에서도 제어기 및 프로세스의 고장 및 검출이 가능한 퍼지-신경망 기반 진단기법을 제안하고 Feedback사의 직류분권 전동기 제어 시스템에의 적용을 통해 유용성을 확인하고자

접수일자 : 2000. 10. 14., 수정완료 : 2001. 3. 9.

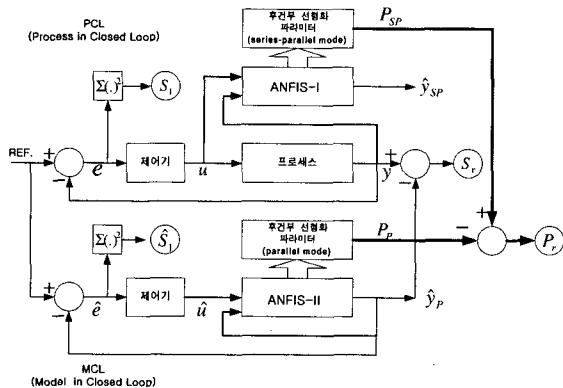
김성호, 이성룡, 강정규 : 군산대학교 전자정보공학부(shkim@kunsan.ac.kr/srlee@kunsan.ac.kr/ggangsang@hanmail.net)

* 본 논문은 에너지 관리공단의 2000 에너지 기술 학술진흥사업으로 연구되었음.

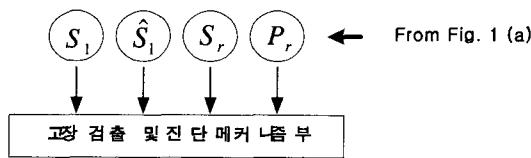
한다.

II. 제안된 고장 진단 시스템의 구조

개루프 시스템에 한정되어 적용이 가능한 기 제안된 퍼지-신경망 기반 고장진단 시스템의 한계를 극복하기 위하여 본 논문에서는 제어기를 포함한 폐루프 제어시스템에서도 적용이 가능한 그림 1과 같은 진단 시스템을 제안하고자 한다.



(a) 고장 진단 시스템의 중상 발생부



(b) 고장검출 및 진단 메커니즘부

그림 1. 제안된 고장진단 시스템의 구조.

Fig. 1. Structure of the proposed fault diagnostic system.

제안된 시스템은 그림 1과 같이 고장 진단을 위해 필수적으로 요구되는 중상 발생부 (a)와 이에 근거한 진단 메커니즘부 (b)로 구성된다. 그림 1(a)의 중상 발생부는 크게 PCL(Process in Closed Loop) 및 MCL(Model in Closed Loop)로 구성된다. 이중 PCL은 제어기 및 프로세스가 포함된 제어시스템으로 제어기 및 프로세스가 고장진단의 대상이 된다. 또한 PCL과 동일한 기준입력으로 병렬로 구동되는 MCL은 PCL의 정상동작을 시뮬레이션하는 컴퓨터 프로그램을 의미한다. PCL 및 MCL에 존재하는 ANFIS-I 및 ANFIS-II는 진단 대상 프로세스의 정상동작시의 입/출력 및 이의 지연된 신호들에 의해 학습된 것으로 ANFIS-I은 프로세스로부터의 입출력을 받아들이는 직·병렬모드(Series-Parallel Mode)로 구동되며 ANFIS-II는 자신의 출력을 다시 입력으로 받아들이는 병렬모드(Parallel Mode)로 구동된다. 따라서 학습된 ANFIS가 진단 대상 프로세스의 정상적인 동작을 모사할 수 있다면 MCL은 정상동작시의 PCL과 동일한 응답 특성을 나타내게 된다. 그러나 PCL에 존재하는 제어기 및 프로세스에

고장이 발생하게 되면 PCL과 MCL은 서로 다른 응답특성을 나타내게 되며 본 논문에서는 고장진단을 위한 중상 데이터로 PCL과 MCL로부터의 얻어지는 각종 신호 및 ANFIS 내의 시스템관련 정보들을 이용하고자 한다. 그럼 1(a)에서 y 는 제어대상 프로세스의 출력을 나타내며 \hat{y}_{sp} 및 \hat{y}_p 는 각각 ANFIS-I의 출력 및 ANFIS-II의 출력을 나타낸다. 또한 P_{sp} 및 P_p 는 ANFIS-I 및 ANFIS-II 내부의 하중화된 후진부 선형화 파라미터를 나타내며 P_r 은 이들간의 잔차를 의미한다. S_1 은 제어대상 프로세스와 ANFIS-II의 출력간 잔차를 나타내며 S_1 및 \hat{S}_1 는 PCL 및 MCL의 제어 성능지수를 의미한다.

그림 1(a)로부터 얻어지는 각종의 중상 데이터 P_r , S_r , S_1 및 \hat{S}_1 는 그림 1(b)의 고장검출 및 진단 메커니즘부에 입력된다. 고장검출 및 진단 메커니즘부는 S_1 을 입력으로 받아 들여 임계치검사를 통해 고장검출을 수행한다. 또한 검출된 고장원인의 진단을 위해 S_1 , \hat{S}_1 는 If-then 구조의 결정로직에 사용되며 P_r 은 프로세스의 고장진단을 위해 일반적 3층 신경망의 입력으로 사용된다. 제안된 진단 시스템의 각 부분별 동작 및 기능에 대해 살펴보면 다음과 같다.

1. 퍼지-신경망의 구조

퍼지-신경망은 퍼지 시스템의 언어적이고 논리적인 추론 능력과 신경망의 학습 능력을 결합하여 서로의 단점을 보완한 것으로 최근 비선형 계통의 모델링 및 제어에 적극적으로 도입되고 있다. 이와 관련된 많은 연구 중 Jang은 퍼지 추론을 수행하는 퍼지-신경망의 결론부를 입력에 대한 선형 방정식으로 대체한 그림 2와 같은 퍼지-신경망을 제안한 바 있다.

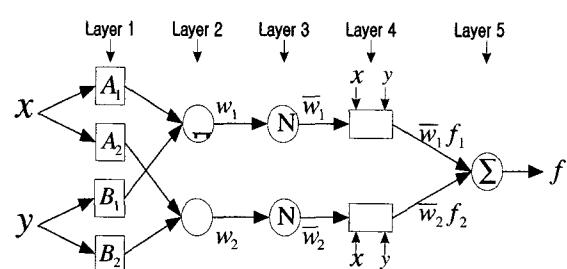


그림 2. 퍼지-신경망의 구조.

Fig. 2. Structure of a neuro-fuzzy system.

그림 2의 퍼지 신경망을 언어적 규칙으로 표현하면 다음과 같다.

Rule 1 : If x is A_1 and y is B_1 , then $f_1 = p_1x + q_1y + r_1$

Rule 2 : If x is A_2 and y is B_2 , then $f_2 = p_2x + q_2y + r_2$

여기서 x, y 는 입력, A_i, B_i 는 각 입력에 대한 소속 함수, f_i 는 각 규칙에서의 출력, 그리고 (p_i, q_i, r_i) 은 각 규칙에서 입력에 대한 선형 파라미터를 나타낸다.

그림 2의 layer 1, 4는 동정될 파라미터를 갖고 있으며 layer 2, 3, 5는 단지 규정된 연산만을 수행한다. layer 1의

파라미터는 신호의 forward pass시 조정되며 layer 4의 파라미터는 신호의 backward pass시 조정된다. 페지-신경망의 추론 메커니즘을 나타내면 그림 3과 같다.

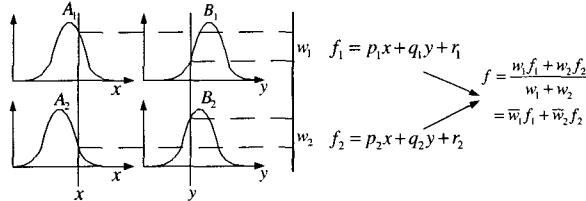


그림 3. 페지-신경망의 추론 메커니즘.

Fig. 3. Inference mechanism of neuro-fuzzy system.

페지-신경망의 최종 출력을 나타내는 그림 3은 (1)과 같이 후건부 파라미터의 선형 조합으로 표현 될 수 있다.

$$\begin{aligned} f &= \frac{w_1}{w_1 + w_2} f_1 + \frac{w_2}{w_1 + w_2} f_2 \\ &= \frac{w_1}{w_1 + w_2} (p_1 x + q_1 y + r_1) + \frac{w_2}{w_1 + w_2} (p_2 x + q_2 y + r_2) \\ &= (\frac{w_1 p_1}{w_1 + w_2} x + \frac{w_1 q_1}{w_1 + w_2} y + \frac{w_1 r_1}{w_1 + w_2}) + (\frac{w_2 p_2}{w_1 + w_2} x + \frac{w_2 q_2}{w_1 + w_2} y + \frac{w_2 r_2}{w_1 + w_2}) \end{aligned} \quad (1)$$

2. 제안된 고장 진단 시스템의 동작 특성

본 논문에서는 고장의 종류로 제어대상 프로세스의 고장과 제어기 고장을 가정하며 각 고장에 대한 진단 시스템의 동작 특성을 살펴보면 다음과 같다.

2.1 고장 검출 및 프로세스 고장 진단

페지-신경망은 직·병렬 모델링 또는 병렬 모델링 기법에 의해 학습된다. 직·병렬 모델링은 동정될 시스템의 입/출력 데이터를 이용하여 학습되며 병렬 모델링 기법은 시스템의 입력 및 페지-신경망의 추정 출력을 학습 입력으로 사용한다. 또한 학습이 완료된 페지-신경망도 학습시와 마찬가지로 직·병렬 모드 및 병렬 모드로 동작시키는 것이 가능하다. 일반적으로 시스템이 정상적으로 동작할 경우, 직·병렬 및 병렬 모드로 동작하는 학습 완료된 페지-신경망은 편차없이 시스템의 출력을 추종하는 것이 가능하다. 그러나 시스템의 내부 파라미터의 변동(프로세스 고장)이 발생한다면 각 모드로 동작하는 페지-신경망은 서로 다른 특성을 나타낸다. 즉 병렬 모드로 동작하는 페지-신경망은 자신의 출력을 입력으로 사용하기 때문에 시스템의 파라미터 변동과 무관하게 시스템의 정상동작을 표현하게 된다. 이에 반해 직·병렬 모드로 동작하는 페지-신경망은 시스템의 출력을 입력으로 사용하기 때문에 고장이 발생한 경우, 병렬 모드로 동작하는 페지-신경망과는 다른 출력을 나타낸다. 따라서 페지-신경망의 상기의 특성을 이용한다면 효과적인 고장의 검출 및 진단이 가능하게 된다. 만일 그림 1(a)에서와 같이 정상 운전 데이터에 의해 학습된 페지-신경망을 직·병렬 모드 및 병렬 모드로 동작시킨다면 전체 제어 시스템에서 발생된 고장(프로세스고장 및 제어기고장)의 검출은 PCL 및 MCL로부터의 잔차, S_e ,을 고찰함으로써 수행될 수 있으며 이중 프로세스 고장은 각 페지-신경망 후건부에 존재하는 선형 파라미터들간의 잔차, P_r ,을 고찰함으로써 진단될 수 있다. 페지-신경망 후건부의 선형 파라미터들의 하중화는 다음과 같이 구할 수 있다.

$$P = [p_1, p_2, \dots, p_n] \quad (2)$$

$$p_i = \frac{\sum_{j=1}^l w_j p_{i,j}}{\sum_{j=1}^l w_j} \quad i = 1, \dots, n$$

(2)에서 n 은 페지-신경망의 후건부 선형 파라미터의 수이며 l 은 후건부 선형모델의 수(규칙의 수)이다. 또한 $p_{i,j}$ 는 j 번째 규칙의 i 번째 선형 파라미터를 의미한다. 따라서 프로세스 고장의 진단을 위해 사용되는 하중화 파라미터들간의 잔차는 (3)과 같이 구할 수 있다.

$$P_r = P_{SP} - P_P \quad (3)$$

(3)에서 P_{SP} 와 P_P 는 각각 직·병렬모드 및 병렬모드로 동작하는 각 페지-신경망의 하중화 파라미터를 나타내며 P_r 은 그림 1(b)의 고장 검출 및 진단 메커니즘부의 고장원인 판별을 위해 도입되는 일반적인 3층 신경망의 입력으로 사용된다.

2.2 제어기 고장 진단

제어기에 의해 제어되고 있는 시스템의 경우 제어기 고장은 프로세스에 적절치 못한 입력을 가할 뿐 시스템 자체에 어떠한 영향도 주지 않으므로 이는 P_r 에 어떠한 파라미터의 잔차도 만들지 못하게 된다. 따라서 P_r 만에 의한 제어기 고장의 진단은 불가능하며 이를 위해 PCL 및 MCL로부터 다음의 수식을 통해 얻어지는 추가적인 양상, S_1 , \hat{S}_1 및 이들간의 잔차 S_e 을 사용하여 제어기 고장을 검출한다.

$$S_1 = \sum_{i=1}^l (REF - y(i)) \quad (4)$$

$$\hat{S}_1 = \sum_{i=1}^l (REF - \hat{y}_p(i)) \quad (5)$$

$$S_e = |S_1 - \hat{S}_1| \quad (6)$$

상기의 고장 검출 및 진단과 관련된 진단 메커니즘을 나타내면 그림 4와 같다.

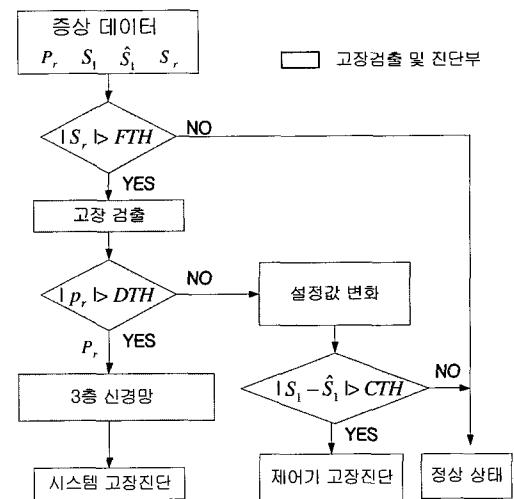


그림 4. 고장진단 순서도.

Fig. 4. Flowchart of the proposed fault diagnosis algorithm.

그림 4에서 FTH는 고장 검출시 사용되는 S ,에 대한 임계값이며 DTH는 P ,에 대한 임계값을 나타낸다. 상기 FTH 및 DTH는 제안된 시스템의 진단성능을 결정짓는 인자로 너무 크게 설정하면 miss alarm을 초래하게 되고 반면에 너무 작게 설정하면 false alarm을 초래하게 된다. 따라서 이들 값의 설정은 시스템의 동특성 및 노이즈 레벨을 고려하여 선정되어야 한다. 특히 고장의 검출과 관련된 FTH는 검출 가능한 고장 크기와 시스템의 노이즈 특성을 고려하여 신중히 선정되어야 한다.

III. 직류 전동기 제어 시스템에의 적용

1. 직류 분권 전동기 제어시스템

그림 5는 Feedback사의 직류 전동기 제어 시스템으로 전동기에 계자 전압 및 전기자 전압을 인가할 수 있는 사이리스터로 구성된 전력 구동부와 PI(D) 제어기를 포함하는 PE483 모듈과 직류 분권 전동기 및 타코미터 등을 포함하는 PE482B 모듈로 구성된다.

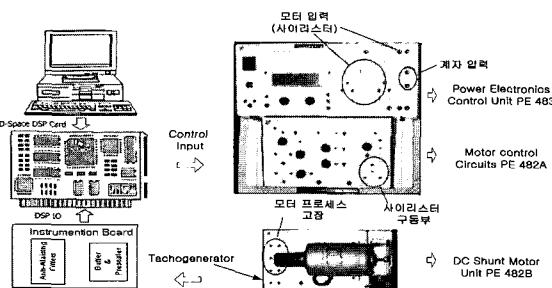


그림 5. Feedback사 전동기 제어시스템.

Fig. 5. DC motor control system.

상기 시스템의 고장 검출 및 진단을 위해서는 그림 1(a)와 같은 증상 발생부의 설계가 요구되며 본 논문에서는 Pentium II 300Mhz 컴퓨터와 A/D 및 카운터를 내장한 dSPACE사의 TMS320C31 DSP 보드를 사용하여 PCL을 구현하였다. 또한 PCL의 제어기는 디지털 PI 제어기로 구현하였으며 이의 샘플링시간은 0.04초로 설정하였다. PCL과 병렬로 구동되는 MCL은 동일 컴퓨터상에서 C언어를 사용하여 구현하였다.

본 논문에서는 PI 제어기 이득이 운전중 변화되는 제어기 고장과 운전중 전동기 파라미터가 변동하는 프로세스 고장 두 종류를 다루고자 한다.

2. 시스템 모델링

일반적으로 시스템의 효과적인 학습을 위해서는 시스템의 모든 상태를 예기시킬 수 있는 다양한 주파수 성분을 갖는 신호를 입력으로 사용하는 것이 바람직하다. 따라서 본 논문에서는 평균이 0.0146이고 분산이 0.0159인 가우시언 분포를 갖는 랜덤 신호를 입력으로 하였으며 또한 직류 전동기의 소프트에 연결된 타코미터를 출력으로 사용하였다. 학습에 사용될 입력, 출력 및 소속함수의 수 등의 결정을 위해 여러 경우에 대한 모델링 특성을 고찰하였으며 최종적으로 다음과 같은 구조의 퍼지-신경망을 채택하였다.

$$y(k) = f(u(k-2), u(k-1), y(k-2), y(k-1)) \quad (7)$$

또한 각 입력당 두 개씩 모두 8개의 소속함수를 사용하였으며 학습에 사용된 입출력 파형을 나타내면 그림 6과 같다.

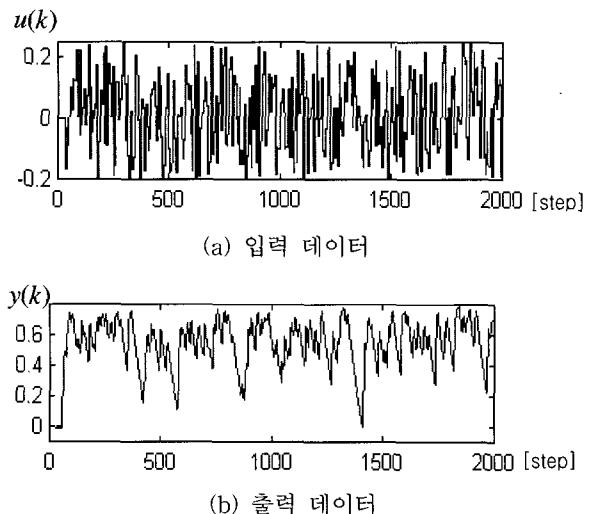


그림 6. ANFIS 학습에 사용된 입·출력 데이터.
Fig. 6. I/O training data for ANFIS learning.

그림 6과 같은 입출력 데이터를 이용하여 (7)의 형태를 갖는 퍼지 신경망의 학습전과 학습후의 퍼지-신경망 전건부 소속함수의 변화를 나타내면 그림 7, 8과 같다.

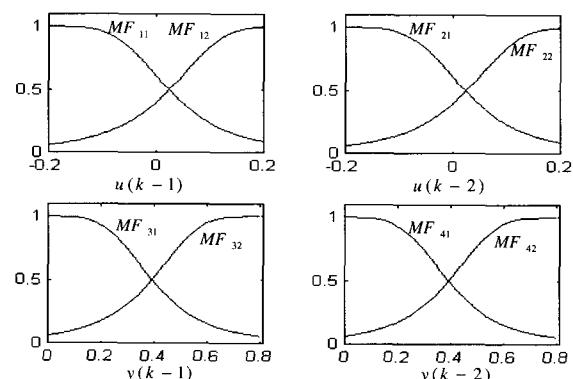


그림 7. 학습전 퍼지-신경망 소속함수의 형태.
Fig. 7. Initial shape of membership functions.

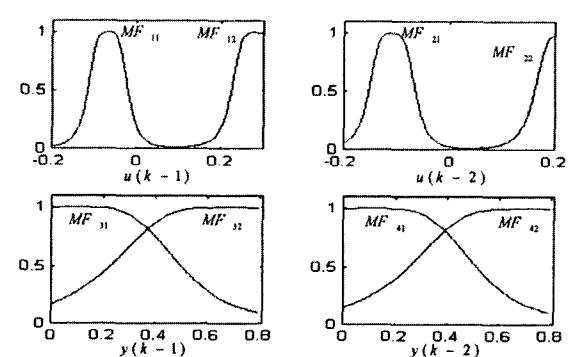


그림 8. 학습후 퍼지-신경망 소속함수의 형태.
Fig. 8. Final shape of membership functions.

또한 학습 완료된 퍼지-신경망의 모델링 특성을 확인하기 위해 평균이 0.0208, 분산이 0.0136 인 입력을 사용하였으며 이 경우의 퍼지-신경망 모델링 특성을 나타내면 그림 9와 같다.

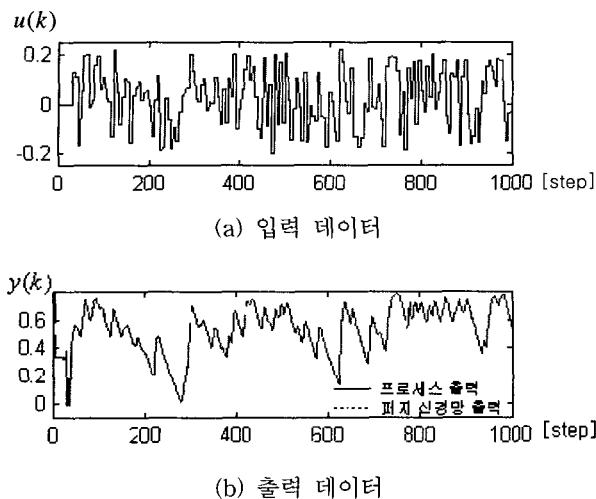


그림 9. 학습된 퍼지-신경망의 응답 특성.
Fig. 9. Recall characteristic of trained ANFIS.

그림으로부터 학습에 사용한 데이터와 다른 신호가 퍼지-신경망에 인가되어도 실제 시스템의 응답을 정확히 표현할 수 있음을 알 수 있다.

3. 고장의 검출 및 진단

3.1 고장 검출

전철에서 구한 퍼지-신경망은 학습 입력 패턴으로 네 개의 입력을 사용하였으므로 후건부에 나타날 수 있는 전체 파리미터의 수는 상수항을 포함하여 다섯개가 된다. 그림 10은 정상운전시의 하중화 파라미터의 잔차이다.

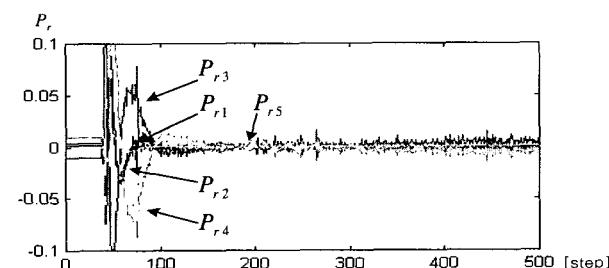


그림 10. 정상동작시의 하중화 파라미터 잔차(P_r).
Fig. 10. Residuals of weighted parameters in normal operation.

그림으로부터 알 수 있듯이 전동기 및 PI제어기가 정상으로 동작할 경우, MCL 및 PCL로부터의 퍼지-신경망 후건부 하중화 파라미터들간의 잔차, P_r 는 과도상태가 지나면 0으로 수렴함을 알 수 있다. 그러나 만약 제어기 및 전동기에 고장(전동기 파라미터 변화 및 PI 제어기 이득변화)이 발생한다면 증상 S_r 은 그림 11과 같은 응답특성을

보인다. 그러나 제어기의 영향으로 인해 일정 시간후에는 다시 0으로 수렴하게 되며 따라서 고장의 검출은 S_r 에 대한 임계치 검사를 통해 수행될 수 있다.

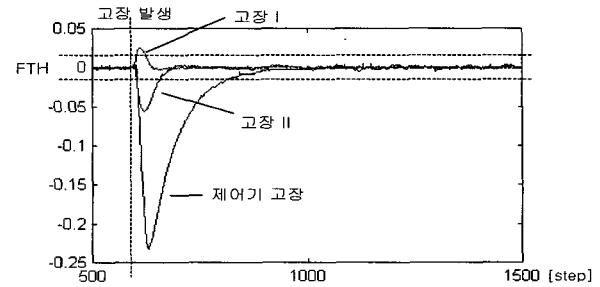


그림 11. 고장 발생시 증상 S_r 응답특성.

Fig. 11. Characteristic of S_r in case of fault occurrence.

3.2 프로세스 고장

프로세스의 고장진단은 S_r 에 대한 임계치 검사에 의해 고장이 검출된 후 수행되는 과정으로 본 논문에서는 계자 저항증가(고장 I: 220Ω 증가)과 전기자 저항 증가(고장 II: 330Ω 증가)의 두 가지 고장을 고려하기로 한다. 각 고장이 발생한 경우 PCL 및 MCL로부터의 P_r 의 변화를 나타내면 그림 12, 13과 같다.

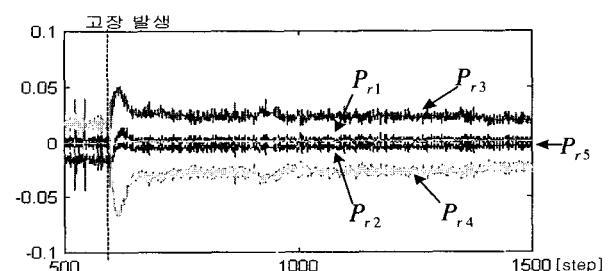


그림 12. 계자 저항증가(고장 I)시의 파라미터 잔차(P_r).
Fig. 12. Residuals of parameter in case of field resistance increase.

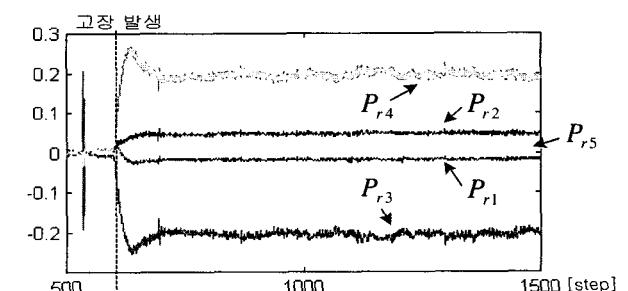


그림 13. 전기자 저항 증가(고장 II)시의 파라미터 잔차(P_r).
Fig. 13. Residuals of parameter in case of armature resistance increase.

그림 12, 13으로부터 각각의 고장에 대해 P_r 의 잔차가 서로 상이함을 알 수 있으며 따라서 이 정보는 그림 1(b)의 고장검출 및 진단 메커니즘부의 일반적 3층 신경망에 입력되어 프로세스에서 발생하는 고장 원인을 판별하게 된다.

3.3 제어기 고장

제어기 고장 역시 S_e 에 대한 임계치 검사에 의해 고장이 검출된 후 수행되는 과정으로 본 논문에서는 PI 제어기의 고장으로 적분기의 이득이 2.3617에서 1.7로 감소하였을 경우를 고려하였으며 이 경우의 퍼지-신경망 하중화 파라미터의 잔차를 나타내면 그림 14와 같다.

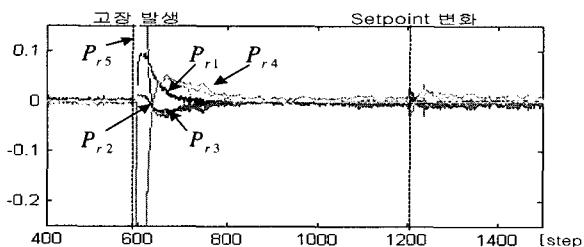


그림 14. 제어기 고장이 발생했을 때의 파라미터 잔차.
Fig. 14. Parameter residual in case of controller fault.

제어기 이득의 감소는 시스템 입력량의 변화를 초래하고 출력의 잔차를 발생시키지만 다시 제어기에 의해서 고장의 영향이 사라져 결국 P_r 은 0으로 가게 되며 이는 P_r 만을 이용해서는 제어기 고장의 진단을 할 수 없음을 의미한다. 따라서 S_e 에 대한 임계치 검사에 의해 고장이 검출된 후 P_r 이 다시 0으로 수렴한다면 제어기 고장이 발생했는지를 알기 위해 PCL 및 MCL로부터의 추가적인 정보 S_1 과 \hat{S}_1 를 구한 후 이들 간의 잔차에 대한 임계치 검사를 통해서 제어기의 고장진단을 수행한다. S_1 과 \hat{S}_1 의 획득을 위해서 추가적인 setpoint의 변화가 요구되면 이를 나타내면 그림 15와 같다. 즉 추가적인 setpoint 변화가 발생하면 PCL 및 MCL에 존재하는 제어기의 성능이 변화되며

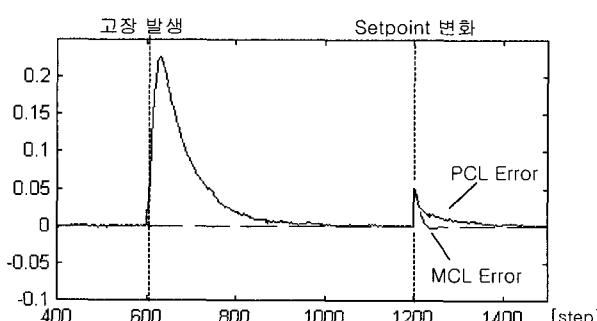


그림 15. 설정값 변화시의 제어기 출력 편차의 변화.
Fig. 15. Controller output error in case of additional setpoint change.

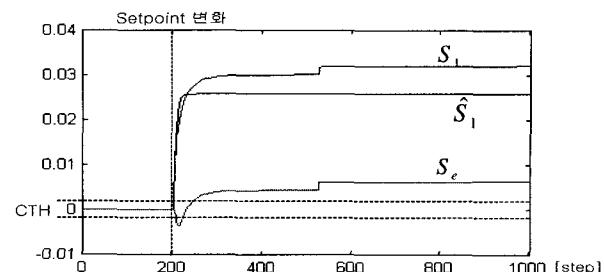


그림 16. 추가적인 setpoint 변화 후의 S_e 응답 특성.
Fig. 16. Response characteristic of S_e after additional setpoint change.

이는 그림 16과 같은 편차를 발생하게 되고 궁극적으로 이에 대한 임계치 검사를 통해 제어기 고장의 진단이 가능하게 된다.

3.4 고장 검출 및 진단 메커니즘부

상기의 고장 검출 및 진단에 관련된 사항을 고려하여 진단 메커니즘부를 구현하면 다음과 같다.

전동기의 고장 진단을 위한 진단 메커니즘부에 존재하는 3층 신경망은 Levenberg-Marquardt 학습방법 및 0에서 1사이의 출력 뉴런을 갖는 신경망을 채택하였다. 신경망의 학습입력 패턴으로 그림 17과 같이 각 동작상태에 대한 퍼지-신경망의 하중화 파라미터 잔차 P_r 를 사용하였으며 이에 대한 출력 학습 패턴은 표 1과 같이 선정하였다.

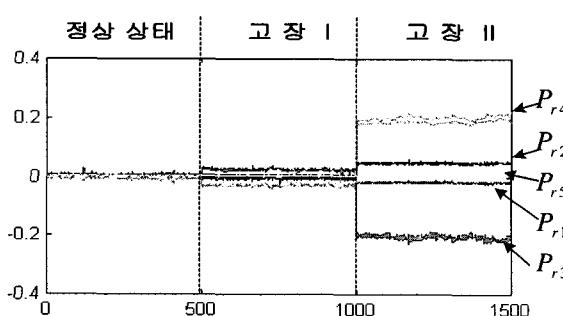


그림 17. RBFN 학습을 위한 입력 패턴.
Fig. 17. Input training data for RBFN learning.

표 1. 고장 분리를 위한 학습 출력값.

Table 1. Target pattern for fault isolation.

	정상 상태	고장 I (계자저항 증가)	고장 II (전기자저항 증가)
뉴런 1	1	0	0
뉴런 2	0	1	0
뉴런 3	0	0	1

그림 18은 학습시 사용한 입력데이터에 대한 신경망의 응답 특성으로 전동기의 정상 및 고장 I, II에 대해 정확히 고장의 진단을 수행함을 알 수 있다.

일반적으로 발생되는 고장의 크기는 학습시의 데이터와는 다르게 되며 이러한 경우 신경망의 응답 특성을 나타내

면 그림 19와 같다. 그림에서 고장 I(계자 저항 180Ω 증가) 및 고장 II(전기자 저항 증가 220Ω 증가)등의 프로세스 고장에 대해 모두 만족할 만한 응답특성을 보이고 있다. 그

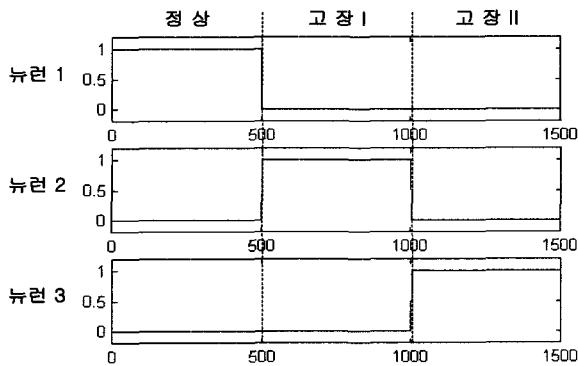


그림 18. 학습 데이터에 대한 RBFN 응답 특성.

Fig. 18. Recall characteristic of RBFN.

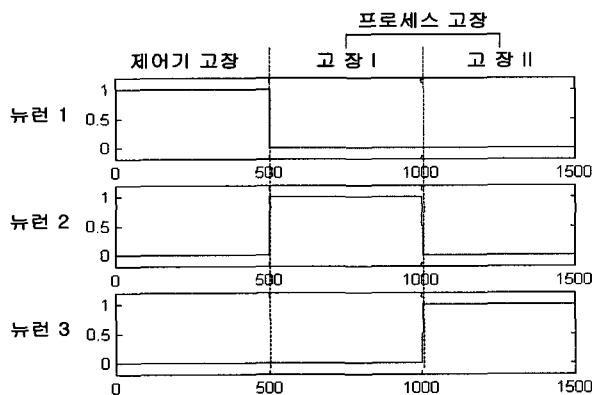


그림 19. 학습시와는 다른 고장에 대한 응답특성.

Fig. 19. Response characteristic in case of different fault magnitude.

러나 제어기의 고장에 대해서는 P_e 이 모두 0으로 수렴하기 때문에 시스템이 정상적으로 동작한다고 판단한다. 이러한 false alarm은 고장 검출 진단 메커니즘부의 추가적인 setpoint 변화에 의해 얻어지는 S_e 의 임계값 조사에 의해 제어기 고장을 분류할 수 있게 된다.

IV. 결과 및 고찰

본 논문에서는 페루프 제어 시스템의 고장 진단에 적용 가능한 퍼지-신경망 기반 고장진단 시스템을 제안하였다. 제안된 시스템은 진단 대상 프로세스의 모델로 정적 및 동적 모델링이 가능한 퍼지-신경망을 사용하였으며 고장의 검출 및 진단은 학습완료된 퍼지-신경망을 각각 직·병렬 모드 및 병렬 모드로 구동시키는 PCL과 MCL로부터 얻어

지는 다양한 증상 신호를 이용하여 수행되었다. 또한 제안된 진단 기법의 유성을 확인을 위해 Feedback사의 직류분권 전동기 제어 시스템에 실제 적용 실험을 수행하였다. 그러나 다양한 고장발생의 제약으로 인해 한정된 경우의 고장에 대한 고찰을 수행하였으나 상정된 각각의 고장에 대해서 효율적인 고장의 검출 및 진단이 가능함을 확인할 수 있었다. 본 논문에서는 PCL 및 MCL로 구성되는 증상 발생부로부터 한정된 수의 증상 신호를 사용하였으나 이와는 별도로 추가적인 신호를 진단에 사용한다면 보다 향상된 진단 결과를 얻을 수 있을 것으로 기대한다.

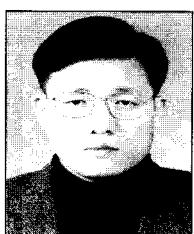
참고문헌

- [1] R., Isermann, "Integration of fault detection and diagnosis methods", *IFAC-Symposium SAFEPROCESS'94*, Espoo, pp. 597-612, 1994.
- [2] A. S., Willsky, "A survey of design methods for failure detection in dynamic systems", *Automatica*, vol. 12, pp. 601-611, 1976.
- [3] R., Isermann, "On the application of model-based fault detection for technical processes", *Control Engineering Practice*, vol. 2, no. 3, pp. 439-450, 1994.
- [4] R. Patton and P. Frank, *Fault diagnosis in dynamic systems. Theory and application*, Prentice Hall Int. UK.
- [5] T. Sorsa and H., Koivo, "Dynamic fault diagnosis using radial basis function networks", *TOOLDIAG'93*, Toulouse, I/160-169, 1993
- [6] R. J., Patton, and J., Chen, "Fault diagnosis in non-linear dynamic systems via neural networks", *Proc. IEE Int. Conf. Control'94*, vol. 2, pp. 1346-1351, 1994.
- [7] D., Fussel, P., Balle, R. and Isermann, "Closed loop fault diagnosis based on a nonlinear process model and automatic fuzzy rule generation", *IFAC symp. on Safeprocess'97*, vol. 1, pp. 359-364, 1997.
- [8] T. Sorsa, "Neural networks in process fault diagnosis", *IEEE Trans. on Syst., Man and Cybernetics*, vol. 21, no. 4, pp. 815-825, 1991.
- [9] J. S. Jang, "ANFIS: Adaptive-network-based fuzzy inference systems", *IEEE Trans. on Systems, Man, and Cybernetics*, vol. 23, pp. 665-685, May, 1993.
- [10] 김성호, 김정수, 박귀태, 박태홍, 이종렬, "퍼지-신경망기반 고장진단 시스템의 설계", *대한전기학회*, vol. 48A, no. 10, 1999.



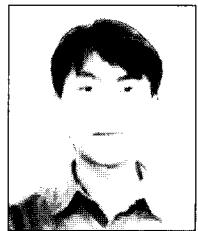
김 성 호

1984년 고려대학교 졸업. 동 대학원 석사(1986), 동 대학원 박사(1991), 현재 군산대학교 전자정보 공학부 부교수.



이 성 풍

1980년 명지대학교 전기공학과 졸업(학사), 동 대학원 석사(1982), 1988년 전북대 전기공학과 박사. 1997-1998 미국 Virginia Tech. 교환교수, 현재 군산대학교 전자정보 공학부 부교수.



강 정 규

1999년 군산대학교 제어계측공학과 졸업(학사)동 대학원 전자공학과 석사(2001), 현재 (주)마이크로컨트롤즈 근무.