

# 신경회로망을 이용한 센서 고장진단 및 극복

Sensor Failure Detection and Accommodation Based on Neural Networks

李均正, 李奉基  
국방과학연구소

## 要 約

본 논문에서는 실제 물리적인 여유 센서를 가지지 않는 수중운동체의 센서 고장진단 및 극복에 관한 문제를 신경회로망을 사용하여 접근하였다. 이를 위하여 설계된 신경회로망은 센서 고장 진단을 위한 신경회로망과 고장 확인 및 대체정보 생성을 위한 신경회로망으로 구성하였으며, 온라인(on-line) 학습을 위하여 확장 역전파(Extended Back-Propagation) 학습법을 사용하였다. 시뮬레이션은 수중운동체의 방위변화를 센서에 대하여 수행하였으며, 제안된 기법이 센서에 대한 고장진단기와 센서 추정기로 사용할 수 있음을 확인하였다.

## Abstract

This paper presents a neural networks based approach for the problem of sensor failure detection and accommodation for ship without physical redundancy in the sensors. The designed model consists of two neural networks. The first neural network is responsible for the failure detection and the second neural network is responsible for the failure identification and accommodation. On the yaw rate sensor of ship, simulation results indicates that the proposed method can be useful as failure detector and sensor estimator.

Keywords : Fault-tolerance, Neural Network, EBPA(Extended Back-Propagation Algorithm)

## 1. 서론

일반적으로 고장에 대한 진단 및 극복 기술은 여유분(redundancy)의 개념을 이용한다. 이는 고장을 감시하기 위한 자원과 고장 극복을 위한 자원 또는 정보를 추가적으로 가짐을 의미한다. 본 연구에서는 하드웨어 고장에 대한 진단 및 극복에 소프트웨어적인 신경회로망 기법을 사용할 수 있음을 검증하고자 하였다.

수중운동체는 자체의 운동특성이 매우 느리며, 다른 동적 시스템(dynamic system)에 비하여 제어력의 영향이 미치지 않는 데는 매우 큰 시간 지연을 가진다. 특히, 센서에 크게 의존하여 운항하는 수중운동체에서는 센서의 신뢰성 또는 고장 대비 기능은 매우 중요하다.

따라서 본 논문에서는 Napolitano 등이 제안하였던 확장 역전파 학습 알고리즘(EBPA : Extended Back Propagation Algorithm)<sup>[1,2,3,4]</sup>을

항공기에 비하여 동적 특성이 매우 느린 수중운 동체에 적용하여, 신경회로망의 동특성 학습능 렷을 살펴보고, 센서고장 진단 및 극복에 적용하였 다. 사용된 수중운동체의 운동모델은 국방과학연 구소에서 자체 개발한 시뮬레이터<sup>[5]</sup>를 사용하였 다.

그림 1은 수중운동체 센서 고장진단 및 극복에 대한 개념도이다.

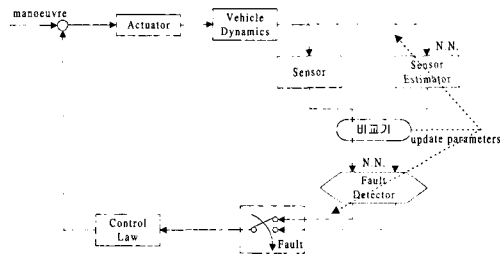


그림 1. 센서 고장진단 및 대체정보 생성 개념도  
Fig.1. Diagram on the fault detection & accommodation

## 2. 신경회로망의 학습 알고리즘<sup>[2]</sup>

일반적인 역전파 학습 알고리즘은 다음과 같은 몇가지의 문제점을 가진다. 첫 번째로 복잡한 시 스템에 대한 학습 속도가 느리다는 것이다. 이는 오랜 시간 동안 학습을 시켜야함을 의미한다. 다 음으로는 국부 최소점(local minimum)의 존재로 인하여 역전파 학습 알고리즘은 신경회로망의 가 중치를 변화시키지 못할 수도 있다는 것이다. 이 러한 두 가지 문제점은 서로 상관적으로 연관되 어있다. 예를 들자면, 학습 계수(learning rate)를 크게 하면 역전파 알고리즘을 사용하는 신경회로 망은 학습 속도를 개선시킬 수는 있지만, 불행히 도 이는 전체 최소점 주위에서 계속 진동하는 문 제점을 발생시킬 수 있다.

그러나 역전파 알고리즘을 고장진단 문제에 적

용하는데 가장 큰 문제점은 신경회로망의 뉴런들 에서 사용하는 활성화 함수의 출력 범위가 한정되 어 있다는 것이다. 따라서 실제로 출력될 값들의 최대값과 최소값을 사전에 알고있어야 한다는 것 이다. 이러한 모든 문제는 이종 신경회로망 (heterogeneous network)을 이용함으로써 극복 할 수 있다. 이종 신경회로망이란 신경회로망의 은닉층이나 출력층의 각 뉴런(neuron)들은 파라 메터들을 변화시킴으로써 자신의 출력 범위나 시 그모이드의 기울기를 변화시킬 수 있는 신경회로 망이다.

여기서는 그림2에서와 같이 m개의 입력 데이 터를 가진 3층의 신경회로망을 기준으로 설명하 자면 다음과 같다. 역전파 알고리즘의 입력 뉴런 들로부터 k개의 은닉층의 뉴런으로 가는 순방향 통로의 계산은 식(1)과 같다.

$$net_i = \sum_{h=1}^m \nu_{ih} I_h + \theta_i, \quad i=1, \dots, k \quad (1)$$

여기서 표준 시그모이드 함수를 사용한다면 은 닉층 노드의 출력값(H<sub>i</sub>)은 식(2)와 같다.

$$H_i = f(net_i) = \frac{1}{1 + e^{-net_i}}, \quad i=1, \dots, k \quad (2)$$

식(1), (2)와 유사하게 n개의 뉴런을 가지는 출 력층에서 순방향 통로의 계산과 그 출력값(O<sub>j</sub>)은 식 (3) 및 식(4)와 같다.

$$net_j = \sum_{i=1}^k \omega_{ij} H_i + \Gamma_j, \quad j=1, \dots, n \quad (3)$$

$$\hat{y}_j = O_j = f(net_j) = \frac{1}{1 + e^{-net_j}}, \quad j=1, \dots, n \quad (4)$$

확장 역전파 알고리즘은 목적은 수정된 활성화함 수를 이용하여 은닉층과 출력층의 각 뉴런들의 성능을 향상시키는 것이다. 식(5)와 (6)은 식(3)과 (4)를 수정한 은닉층과 출력층의 뉴런에서 사용 되는 활성화함수이다.

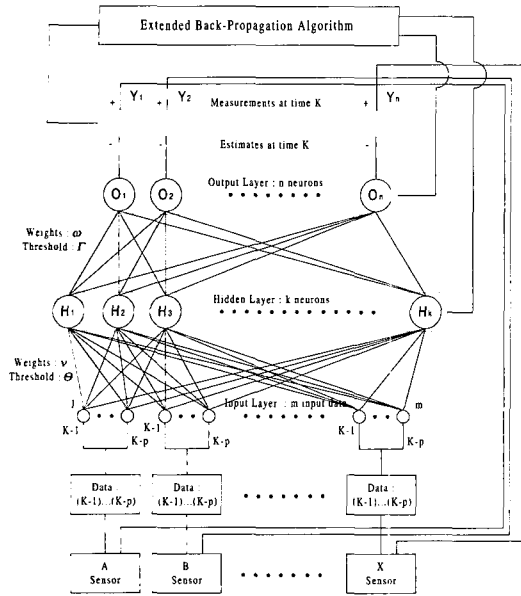


그림 2. 3층 신경회로망의 구조

Fig.2. Structure of 3-layer neural network

$$H_i = \frac{U_i - L_i}{1 + e^{-net_i/T_i}} + L_i, \quad i=1, \dots, k \quad (5)$$

$$O_j = \frac{U_j - L_j}{1 + e^{-net_j/T_j}} + L_j, \quad j=1, \dots, n \quad (6)$$

여기서,  $U_i$ 와  $L_i$ 는 각각 은닉층과 출력층의 뉴런의 출력값 중에서 최대값과 최소값을 나타낸다. 그리고  $T_i$ 는 수정된 시그모이드 함수의 기울기를 나타낸다. 원래의 시그모이드 함수는  $U=1, L=0$  그리고  $T=1$ 의 경우에 해당한다. 센서 출력값과 신경회로망 추정값의 차이를 최소화하기 위하여 일반 역전파 알고리즘에서 사용하였던 최대경사 감소법(steepest descent method)에 의하여 연결가중치와 신경회로망 파라미터들이 갱신된다. 단지 차이점이라고는 시간에 대하여 독립적인  $net, U, L$  그리고  $T$ 라는 변수가 사용된다.

### 3. 신경회로망의 설계

그림 3에 표현된 것처럼 다수의 신경회로망 구조를 가지는 온라인 학습 신경회로망을 이용하여 센서 고장진단 및 대체정보 생성 문제를 해결할 수 있다. 다수의 신경회로망 구조란 고장 진단을 위한 신경회로망(FD-NN: Failure Detection NN)과 고장 확인 및 대체정보 생성을 위한 신경회로망(FA-NN : Failure Accommodation NN)으로 구성된 신경회로망이다<sup>[1,2,3,4]</sup>.

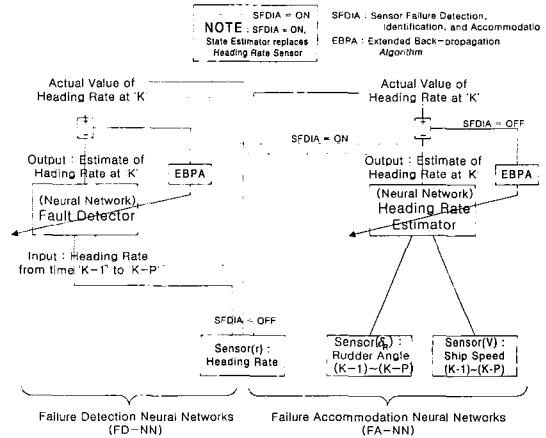


그림 3. 3층 센서 고장진단 및 극복 신경회로망

Fig. 3. Fault tolerant neural network on the sensors

시스템의 고장 유무에 상관없이 항상 학습상태에 있는 고장진단 신경회로망의 현재 시간 (K)에서의 입력(  $I_K^{FD}$  )은 시간 간격 (K-1)부터 (K-P)까지의 방위변화율로서 식(7)과 같이 정의하고, 출력(  $O_K^{FD}$  )은 식 (8)과 같이 정의하였다.

$$I_K^{FD} = [ r_{K-1} \quad r_{K-2} ] \quad (7)$$

where  $r$  : ship heading rate (deg/sec)  
 $K$  : discrete time index

$$O_K^{FD} = [ \hat{r}_K^{FD} ] \quad (8)$$

시뮬레이션에서는 과거 궤적의 수 P를 2로

선정하였으며, 시간 간격은 0.5초로 하였다. 이는 그림3의 좌측 부분으로 과거의 센서값을 이용하여 현재의 센서값을 추정하고, 임의의 시간 K에서 센서 출력 벡터  $Y_K^{FD}$ 는 식(9)와 같으며, 식(10)으로 정의되는 추정오차 파라미터 값이 임계값 이상일 경우 고장 발생을 감지한다. 그리고 신경회로망 연결가중치 및 신경회로망 파라미터들의 갱신을 위하여 추정오차의 각 파라미터에 대한 미분값이 이용된다.<sup>[6~10]</sup>

$$Y_K^{FD} = [ r_K ] \quad (9)$$

$$E_K^{FD} = \frac{1}{2} ( Y_K^{FD} - O_K^{FD} )^T ( Y_K^{FD} - O_K^{FD} ) \quad (10)$$

$$= \frac{1}{2} ( r_K^{FD} - \hat{r}_K^{FD} )^2$$

고장이 발생하였을때 함방위 변화율 센서에 대한 대체정보 생성을 위하여 수직타(rudder)와 함속을 입력으로 가지는 다른 신경회로망을 구성하였다. 대체정보 생성 기능을 구현하기 위해서는 입력 파라미터를 센서 고장의 영향을 받지 않는 요소들로 구성해야 한다. 즉, 센서 출력을 생성하는 근본적인 원인이 되는 파라미터로 구성해야 한다. 대체정보 생성 신경회로망도 역시 고장진단 신경회로망과 같이 실제 센서값과 신경회로망 추정값과의 차이는 확장 역전파 학습 알고리즘을 이용하여 신경회로망의 연결 가중치와 파라미터를 갱신하는데 사용된다.

그림3에서 SFDIA=OFF로 표시된 실선부는 센서 고장 발생 이전에만 동작하고, SFDIA=ON으로 표시된 점선부는 신경회로망에 의해서 고장이 감지된 이후에 동작하는 부분이다. 즉 고장진단 신경회로망(FD-NN)은 고장 진단 및 확인 이후에는 실제 센서 출력을 이용하지 않고 대체정보 생성 신경회로망(FA-NN)의 출력을 이용하여 학습한다.

대체정보 생성 신경회로망의 입력벡터(  $I_K^{FA}$  )는 식(11)과 같이 방위 변화를 일으키는 근본 원

인이 되는 제어 타각과 자함의 속도로 구성하였으며, (K-1)부터 (K-P)까지의 과거의 값들로 구성하였다. 시뮬레이션에서는 과거 궤적의 개수 P를 3으로 선정하였다.

$$I_K^{FA} = \begin{bmatrix} \delta_{R_{K-1}} & \delta_{R_{K-2}} & \delta_{R_{K-3}} \\ V_{K-1} & V_{K-2} & V_{K-3} \end{bmatrix} \quad (11)$$

where,  $\delta_R$ : deflection angle of rudder  
 $V$ : ship speed

대체정보 생성 신경회로망의 출력(  $O_K^{FA}$  )은 식(12)와 같다.

$$O_K^{FA} = [ \hat{r}_K^{FA} ] \quad (12)$$

방위변화율의 고장을 진단하기 이전까지의 실제 센서값(  $Y_K^{FA}$  )은 식(13)으로 표현되고, 추정오차는 식(14)와 같이 정의한다.

$$Y_K^{FA} = [ r_K ] \quad (13)$$

$$E_K^{FA} = \frac{1}{2} ( Y_K^{FA} - O_K^{FA} )^T ( Y_K^{FA} - O_K^{FA} ) \quad (14)$$

$$= \frac{1}{2} ( r_K^{FA} - \hat{r}_K^{FA} )^2$$

고장진단 신경회로망에서 고장을 일차적으로 진단하고, 센서 고장에 대한 확인은 고장 진단 신경회로망에서와 마찬가지로 실제 센서 출력과 신경회로망의 차이가 임계값 이상일 경우에 고장이라고 판단한다. 두 개의 신경회로망에서 고장에 대한 평가를 하는 것은 고장에 대한 오경보율(false alarm rate)을 줄이기 위함이다.

센서 고장에 대한 극복 방법은 고장난 센서 출력을 사용하지 않고, 그 센서의 출력을 추정하는 신경회로망의 출력을 사용하는 것으로 이루어진다. 즉, 고장이 진단되고 확인되면 그림3에 나타나 있는 SFDIA가 ON 상태가 된다. 즉 실제 센서값을 사용하던 모든 부분을 대체정보 생성 신경회로망의 출력으로 대체함으로써 이루어진다. 이때의 대체정보 생성 신경회로망의 입력은 남아 있는 정상 상태의 센서값들을 입력으로 가진다.

이러한 고장에 대한 조정을 위해서 고장이 발생한 이후부터는 대체정보 생성 신경회로망 (FA-NN)의 학습은 중지되고 더 이상의 연결 가중치의 갱신은 이루어지지 않는다. 여기서 대체정보 생성 신경회로망은 추정하고자 하는 센서의 출력을 입력으로 사용하지 않는다는 사실에 주의해야 한다. 이는 자신을 입력으로 가지지 않는다는 것을 의미하며, 자신이 고장이 났을 경우에 효과적으로 대처하기 위함이다.

이러한 신경회로망에 근거한 센서 고장진단 및 대체정보 생성 알고리즘은 온라인 학습이 가능하다는 것에 기인한 추가적인 특징을 가진다. 첫째로, 이 방법은 센서들이 동시에 고장이 일어나지 않는다면 여러 센서들의 고장에 대해서도 적용 가능하다. 물론 정상 상태와 비교해서 정확성 측면에서 어느 정도의 시스템 성능 저하는 당연한 것이다. 다음으로는 간헐적인 센서 고장에 대해서도 적용 가능하다는 것이다. 즉, 만일 센서가 다시 정상적으로 작동한다면, 다시 추정값을 생성하는 신경회로망 대신 실제 센서를 이용할 수 있다.

#### 4. 시뮬레이션 결과 및 분석

##### 4.1. 시뮬레이션 조건

센서 고장 진단 및 대체 정보 생성 신경회로망을 구성하기 위하여 다음과 같은 2가지의 고장을 고려하여 시뮬레이션 하였다. 정상적인 센서값은 식(15)와 같이 정의하였다.

$$\text{정상상태} \triangleq \text{Sensor}(K) \quad (15)$$

- ① 고장 1에 대한 정의  
고장 1은 식(16)과 같이 정의한다.

$$\text{고장 1} \triangleq \text{bias} + |A| \text{random}(K) \quad (16)$$

여기서 random(K)는 평균이 0(zero)이고, 최대 크기가 1이며, 균일 분포를 가지는 백색잡음(white noise)이라고 가정하였다. |A|는 백색잡음의 최대 크기를 조절하는 요소이며, bias는 편향된 크기를 나타내는 값이다. 그러므로 고장난 센서는 최대  $\max(\text{bias}) + |A|$ 를 가질 수 있다. 시뮬레이션에서는 |A|의 크기를 2.5, bias의 크기를 7로 하였다.

- ② 고장 2에 대한 정의  
고장 2는 식 (17)과 같이 정의한다.

$$\text{고장 2} \triangleq \text{bias} + \text{Sensor}(K) \quad (17)$$

고장 2에 의한 센서 출력값은 정상적인 출력으로부터 바이어스(bias)의 크기만큼 편향되어 나타나게 된다. 본 논문에서는 바이어스(bias)의 크기를 4 deg/sec와 2 deg/sec 경우에 대해서 시뮬레이션 하였다. 만일 바이어스의 크기가 센서 출력값의 최대보다 월등히 크다면 이는 고장 1의 경우와 매우 유사한 결과를 낼 것이라는 예측을 할 수 있기 때문이다.

- ③ 수중운동체 운동모델  
수중운동체의 운동모델은 국방과학연구소에서 자체 개발한 시뮬레이터를 사용하였다<sup>[5]</sup>. 사용된 모델은 시스템의 비선형성에 대하여 각종 시뮬레이션을 통하여 충분히 고려되었으며, 운동방정식의 계산에 필요한 시간 간격은 0.1초로 하였다.

- ④ 신경회로망의 입력 및 구조  
그림 4 및 그림 5는 대체정보생성 신경회로망의 입력으로 사용되는 함속과 제어타각을 표시한

것이다.

표 1은 고장진단 및 대체정보 생성 신경회로망 시뮬레이션에 사용된 신경회로망의 구조 및 파라미터이다. 표 1에 표시된 입력 파라미터의 수, 은닉층의 뉴런수, 학습률(learning rate) 등은 최적의 신경회로망을 구성하기 위하여 다양한 시뮬레이션의 결과로부터 추출한 것이다.




그림4. 신경회로망의 입력 1(함속)  
Fig. 4. Input 1 of neural network(speed)




그림5. 신경회로망의 입력 2(제어타각)  
Fig. 5. Input 2 of neural network(rudder angle)

## 1.2. 시뮬레이션 결과 및 분석

### 1.2.1. 고장 1에 대한 결과 및 분석

일반적으로 신경회로망의 학습은 목표값과 추정값의 차이가 일정 수치 이하일 때까지 계속되

표 1. 고장진단 및 극복 신경회로망의 구조  
Table 1. Structure of fault tolerant neural networks

item \ neural network	FD-NN	FA-NN
input parameter	1	2
data pattern(P)	2	3
number of hidden layer	1	1
number of neurons in hidden layer	4	12
number of neurons in output layer	1	1
learning rate	0.01	0.002
momentum coefficient	0.0	0.0

지만, 본 연구에서는 고장발생을 감지하는 온라인(on-line) 학습 신경회로망이므로 최소 학습 시간을 결정하고 최소 학습 시간 이후의 시간에 대하여 고장을 감지할 경우에 학습을 중지한다. 시뮬레이션에서는 최소 학습 시간을 1,000초, 고장 발생 시간을 2,200초로 하였다.

대체정보 생성 신경회로망의 학습을 2,200초에서 중단하였다는 것은 더 이상의 연결가중치 또는 신경회로망 파라미터에 대한 갱신 작업을 수행하지 않는다는 것이다. 즉 2,200초 이전의 시간 간격에서의 연결 가중치와 파라미터 값을 그대로 유지하면서 새로운 입력들에 대하여 출력을 생성한다.

방위변화율 센서고장 및 대체정보 생성에 대한 시뮬레이션에서 고장은 정상적인 센서값으로부터 일정량의 바이어스(7 deg/sec)와 균일 분포를 가지고 최대 변위가 2.5 deg/sec를 가지는 랜덤 함수를 사용하였다. 그림은 전시를 위하여 2,000초부터 500초 동안의 방위 변화율에 대해서만 기록하였다. 방위변화율 센서 고장 진단 및 추정 신




그림 6. 방위변화율(정상/추정/고장 1)  
Fig. 6. heading rates(normal/estimate/failure 1)

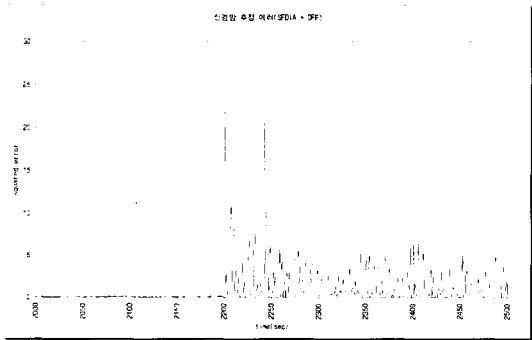


그림 7. 고장 1에 대한 추정 오차(SFDIA=off)  
Fig.7. Estimation error on the failure 1 (SFDIA=off)




그림 8. 고장 1에 대한 추정오차(SFDIA=on)  
Fig.8. Estimation error on the failure 1 (SFDIA=on)

경회로망의 시뮬레이션 결과는 그림 6, 그림 7 그리고 그림 8이다.

그림 6은 방위변화율의 시간에 대한 궤적으로서 센서 고장이 발생하지 않은 정상적인 경우와 센서 고장이 발생한 경우에 대하여 표현하였다. 그림에서 보듯이 대체정보 생성 신경회로망의 추정치가 고장이 발생한 이후에도 정상적인 센서값을 매우 잘 추정함을 알 수 있다. 그림6의 결과에서 보듯이 대하여 과거의 속도와 타각을 입력으로 가지는 대체정보 생성 신경회로망은 학습을 중지한 이후에도 목표값과 유사한 결과를 추정하므로 수중운동체의 운동 등과 같은 비선형 함수에 대한 학습 능력을 가진다고 할 수 있다.

그림 7은 고장진단 및 대체정보 생성기능을 수행하지 않았을 때(SFDIA=OFF)의 식(10)에 정의된 고장진단 신경회로망(FD-NN)의 추정오차의 신호이다. 이것은 고장이 발생한 시간(2,200초)에서 추정오차가 급격히 증가하고, 계속적으로 비정상적인 방위센서 값이 고장진단 신경회로망(FD-NN)의 입력으로 들어오므로 추정오차 신호가 계속 고장의 영향을 받고있다는 것을 의미한다.

그림 8은 식(10)에 표현된 고장을 감지하기 위한 고장진단 신경회로망에서의 추정오차 신호로서 고장진단 및 대체정보 생성기능이 수행되었을 경우(SFDIA=ON)이다. 만일 고장진단 및 대체정보 생성기능이 성공적이라면, 고장난 센서가 대체정보 생성 신경회로망의 추정값으로 대체되는 순간에 식 (10)의 추정오차는 매우 적은 값으로 수렴한다.

그림 8에서 고장이 발생한 시간(2,200 초)에서의 오차 신호가 다른 시간에 비하여 매우 크게 나타나므로 임계값을 적절히 설정하면 고장을 진단할 수 있고, 고장발생 이후의 추정오차는 매우 적으므로 대체정보 생성기능은 적절히 운용되었

다고 할 수 있다. 고장 발생 시간(2,220 초)에서 식(10)에 정의된 추정오차의 크기는 24.9이다. 따라서 고장 1에 대하여 고장 진단 및 대체정보 생성 신경회로망은 고장감지 능력 및 추정정확도가 매우 높다고 할 수 있다. 이러한 신경회로망은 최소 학습 시간(1,000 초)이 경과한 이후에 고장 진단 및 추정 기능을 사용할 수 있다. 그러나 이러한 단점은 이전에 저장된 데이터를 이용하는 오프라인(off-line) 학습을 통하여 최소 학습 시간을 단축시킬 수 있을 것으로 기대된다. 즉, 이전의 데이터를 이용하여 신경회로망을 학습시키고 학습된 신경회로망의 연결강도, 임계값 등의 수치들을 학습된 결과로써 저장하여 시스템 운용 시 초기 데이터로 이용할 수 있도록 하는 것이다. 그림 9는 학습시간에 따른 추정오차의 RMS(root mean square) 값의 추이를 나타내는 것으로서 학습시간이 길어질수록 추정오차의 크기는 점차 감소한다는 것을 알 수 있다.




그림 9. 학습시간에 따른 신경회로망의 추정 오차  
Fig.9. Estimation error curve due to learning time

1.2.2. 고장 2에 대한 결과 및 분석

센서가 완전히 고장난 것이라기 보다는 센서를 읽는데 약간의 오류가 있는 정도인 고장 2의 경우는 고장 1에 비하여 고장을 감지하고 확인하기가 더욱 어렵다. 이러한 형태의 전형적인 고장은

정상적인 센서값에 바이어스(bias)가 추가된 경우이다. 이러한 형태의 고장은 4.0deg/sec과 2.0deg/sec의 바이어스를 정상값에 더하는 것으로 시뮬레이션 하였다. 이러한 바이어스 값은 센서의 최대 범위차보다 적은 값을 임의로 선택하였으며 고장발생시각은 시뮬레이션 시작부터 2,200초 이후에 방위변화율 센서에 고장이 발생하도록 하였다. 고장 발생 이후에는 제안된 신경회로망 구조에 의하여 고장이 자동적으로 진단되고, 고장진단 후에는 센서출력 대신 대체정보 생성 신경회로망(FA-NN)의 추정출력을 이용하여 고장진단 신경회로망(FD-NN)을 학습시킨다.

그림 10과 그림 12에 센서 출력과 신경회로망 추정출력 및 고장 센서출력을 각각 나타내었다.

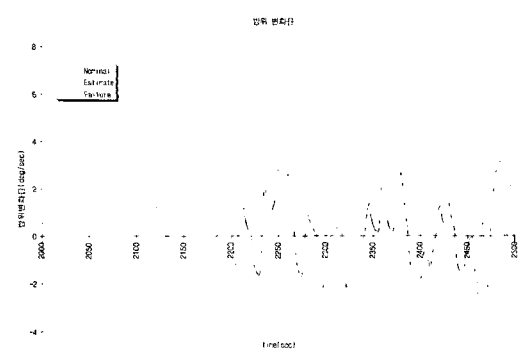


그림 10. 방위변화율(정상/추정/고장 2(4deg/sec))  
Fig.10. Heading rates(normal/estimate/failure 2)

그림 11과 그림 13은 각 경우에 대한 고장 2의 추정오차 신호이다. 고장이 발생한 시각에서의 오차가 다른 시간에 비하여 다소 크지만, 고장 1의 경우와 비교한다면 오차 신호가 매우 작음을 알 수 있다. 이는 고장 1에 비하여 고장 2와 같은 경우에 고장에 대한 잘못된 경보를 할 가능성이 높다는 것을 의미한다. 그러나 방위변화율 추정 신경회로망(대체정보 생성 신경회로망)의 추정



치가 정상값과 잘 일치하므로 큰 문제를 발생하지는 않는다.




그림 11. 고장 2(4deg/sec)에 대한 추정 오차  
Fig.11. Estimation error on the failure 2(4deg/sec)




그림 12. 방위변화율(정상/추정/고장 2(2deg/sec))  
Fig.12. Heading rates(normal/estimate/failure 2)

각각의 바이어스에 대하여 고장 발생 시각에서 식(10)에 정의된 추정오차의 크기는 각각 7.73과 1.87이다. 그림 13의 경우에는 2,029초에서 고장 진단 신경회로망의 추정 오차신호가 1.25로서 다소 크게 나타났지만 식(14)에 정의된 대체정보 생성 신경회로망(FA-NN)의 추정오차는 2,029초와 2,200초에 대하여 각각 0.0832와 2.45를 가지므로 대체정보 생성 신경회로망의 고장확인 기능에 의하여 2,029초에서의 고장은 무시된다. 고장 2에 대한 고장 감지 능력은 고장 1과 비교해서

다소 떨어짐에도 불구하고 신경회로망에 근거하지 않은 전통적인 센서 고장 진단 및 추정 알고리즘과 비교했을 때, 다음의 두 가지 요소에 대하여 고려할 가치가 충분히 있다. 첫째로 고장 진단 신경회로망과 추정 신경회로망의 추정오차가 미리 정해진 임계값 이상일 경우 고장을 진단한다. 이때 두 개의 신경회로망을 이용함으로써 고장에 대한 오경보율(false alarm rate)을 근본적으로 감소시킬 수 있다. 두 번째는 이러한 구조의 성능은 학습을 계속할수록 그 성능이 높아진다. 다르게 말하자면, 학습에 사용되는 데이터가 많을수록 고장을 찾아내는 신경회로망의 능력이 증대된다고 할 수 있다.

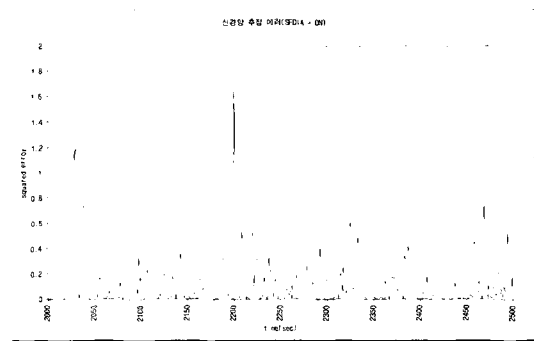


그림 13. 고장 2(2deg/sec)에 대한 추정 오차  
Fig.13. Estimation error on the failure 2(2deg/sec)

## 5. 결론

본 연구에서는 실제 센서 여유분을 사용하지 않고 신경회로망 기법을 사용하여 동적 시스템에 장착된 센서에 대한 고장을 진단하고 대체정보를 생성하는 방법을 수중운동체에 적용하였다. 적용된 기법은 하드웨어(센서)의 고장을 분석적 자료 처리 기법을 적용한 소프트웨어로써 극복하는 미래지향적 기술로서 수중운동체의 동특성을 신경

회로망이 학습할 수 있다는 특징을 가진다.

본 연구에서 제안한 수중운동체에 대한 센서 고장진단 및 대체정보 생성 방법은 병렬화하기 쉬운 인공 신경회로망 기술을 사용하였으므로 무인 잠수정이나 무인 항공기에서 센서정보를 이용한 실시간 제어에도 이용할 수 있으며, 실제 여유 센서를 사용하는 경우에도 고장진단기 등으로 사용할 수 있을 것으로 기대된다. 추후로 신경회로망의 효율적 구조설정, 추정센서에 대한 입력 파라미터 설정, 그리고 각종 파라미터들의 최적화 연구를 수행하여 고장난 센서에 대한 더욱 정확한 대체정보를 제공할 수 있는 방법에 관하여 연구를 수행할 계획이다.

參 考 文 獻

[1] R.Napolitano, Charles Neppach, etc. "Neural Network Based for Sensor Failure Detection, Identification, and Accommodation," J. of Guidance, Control and Dynamics, vol. 18, No. 6, Nov. 1995, pp. 1280~1286.

[2] R.Napolitano, I. Chen, Naylor, "Aircraft Failure Detection and Identification Using Neural Networks," J. of Guidance, Control and Dynamics, vol.16, No.6, Nov. 1993, pp. 999~1009.

[3] R. Napolitano, Charles Neppach, etc., "On-line Learning Neural Architectures and Cro-sscorrelation Analysis for

Actuator Failure Detection and Identification," Int. J. of Control, vol.63, No.3, Feb. 1996, pp. 433~455.

[4] R.Napolitano, I. Chen, Naylor. etc., "On-line Learning Nonlinear Direct Neuro-controllers for Restructurable Control Systems," Vol.18, No. 1, Jan.~Feb., 1995, pp. 170~176.

[5] 이균정 외, "잠수함 조종 시뮬레이터 설계연구(II)," NWSD-513-931065, 국방과학연구소, 1993.

[6] Cybenco, G., "Approximation by Superposition of Sigmoid Function," Mathematical of Controls Signals and Systems, vol. 2, No. 4, 1989. pp. 303 ~ 314.

[7] David E. Rumelhart, etc., Parallel Distributed Processing, The MIT Press, 1986.

[8] Patrick K. Simpson, "Foundations of Neural Networks," IEEE Technology Update Series - Neural Networks Theory, Technology, and Applications, 1996.

[9] James A. Freeman, Neural Networks Algorithm, Applications and Programming Techniques, Addison- Wesley,1991.

[10] John A.K. Suykens, etc., Artificial Neural Networks for Modelling and Control of Non-linear Systems, Kluwer, 1996.