

## 신경망을 이용한 터보제트 엔진의 고장 진단

### Sensor Fault Detection and Isolation of a Turbojet Engine Using Neural Network

김종선\*, 이강웅\*, 김진곤\*, 부준홍\*, 유상신\*, 민성기\*\*

Jong-Sun Kim\*, Kang-Woong Lee\*, Jin-Gon Kim\*, Joon-Hong Boo\*,  
Sang-Sin Yoo\*, and Seong-Ki Min\*\*

#### 요 약

본 논문에서는 터보제트 엔진 제어기의 신뢰성을 향상시키기 위한 지능형 고장진단 알고리즘을 제안하였다. 제안된 기법은 다중 신경망을 이용한 고장진단 기법으로 서로 다른 종류의 센서들 사이의 기능적 종속관계를 추정하여 고장 부위를 규명하고 처리한다. 고장센서 신호는 역전파 알고리즘을 이용한 훈련된 신경망을 통하여 추정한다. 실험데이터에 기초한 터보제트 엔진의 선형공간 모델에 적용한 시뮬레이션을 통하여 제안된 알고리즘의 구현 가능성을 검증한다.

#### Abstract

In this paper, we designed an intelligent fault detection and isolation algorithm for improving reliability of turbojet engine controller. The proposed method uses multilayer neural network to detect and accommodate sensor failure from the functional relationship of dissimilar sensors. Signals of failure sensors are estimated from neural network trained by backpropagation algorithm. Simulation results on the state-space model of a turbojet engine illustrate that the proposed algorithm achieves the desired performance.

#### I. 서 론

디지털 전자식 엔진제어기의 신뢰성 확보는 시스템 성능의 최적화에 앞서 고려해야 할 중요한 측면이다. 신뢰성을 향상시키기 위해서는 센서와 액츄에이터 또는 시스템으로부터 발생하는 결함을 발생 초기에 감지하여 원인규명과 동시에 적절한 제어규칙의 조정에 따라 사고발생을 미연에 방지하는 지능형 제어기술의 확보가 중요하다.

이를 위해서는 운전 중에 고장의 감지와 예측, 규명과 적절한 조치를 포함하는 고장진단기술(Fault Detection and Isolation Scheme:FDIS)의 개발이 선행되어야 한다<sup>[1],[2]</sup>.

고장진단기술은 크게 하드웨어적인 방법과 소프트웨어적인 방법이 있다. 하드웨어적인 방법은 이분법적인 판단에 의한 단순한 방법이며 소프트웨어적인 방법은 프로그램에 의해 고장원인 규명과 조치를 취하는 방법으로 고장발생에 대한 판단과 원인규명 과정들이 변수들간의 복잡한 수학적 관계를 갖게 되

\* 한국항공대학교(Hankuk Aviation Univ.)

\*\* 국방과학연구소(Agency for Defence Development)

· 논문번호 : 99-1-4

· 접수일자 : 1999년 6월 29일

· 본 연구는 국방과학연구소의 연구비 지원으로 수행되었습니다.

며, 운전조건에 따른 동적 모델의 변화와 점진적인 부품의 노화에 따른 출력의 변화 등을 고려해야 한다.

센서와 액츄에이터를 추가하는 하드웨어 여유(Hardware redundancy)에 의해 신뢰성을 증가시키려는 방법은 비용 및 중량의 증가가 큰 문제로 지적되었다. 특히 2배수 또는 3배수의 동일 목적의 센서를 사용할지라도 수명에 따른 고장발생이 거의 동시에 일어나 많은 센서류를 거의 같은 시기에 교체해야 하는 문제가 종종 발생하게 된다.

최근 소프트웨어적으로 센서나 액츄에이터, 시스템 변수들 사이의 기능적 관계(Functional redundancy)를 이용해 고장이 발생된 것으로 판단되는 부분을 규명하고 제어규칙을 변경하는 연구가 활발히 진행되고 있다<sup>[3]</sup>. 기능적 종속관계를 이용한 고장진단기술은 방대한 양의 센서신호를 실시간으로 디지털 신호 처리하는 기술에 기반을 둔 소프트웨어 기술로서 상태변수의 추정, 매개변수의 추정 및 다양한 디지털 논리연산으로 구성되어 있다. 특히 운전조건에 따른 동적모델의 변화, 외란에 의한 상태변수 및 센서출력의 갑작스런 변화 등을 효과적으로 수용해야 한다. 이를 위해서는 지능형 고장진단 기술에 대한 연구가 필요하다.

측정변수들 사이의 기능적 종속관계를 실시간으로 구현하기 위해 종래에는 작동점 부근에서 선형화된 동적 모델에 기초하여 Kalman 필터와 선형 제어시스템이론을 이용한 연구가 진행되어 왔으나<sup>[4]</sup>. 다양한 작동상태와 환경변화에 효과적으로 대응하기는 어렵다. 따라서 개인성과 적응성을 동시에 갖춘 고장진단기술이 필요하며 이 문제를 해결하기에 가장 적합한 이론으로 도입된 것이 신경망을 이용한 방법이다<sup>[5],[6]</sup>.

본 논문에서는 기존의 논문들이 동종의 센서를 2중 또는 3중으로 배치하여 여유 하드웨어를 이용하는데 반해 이종(Dissimilar)의 센서를 배치하고 이들 사이의 기능적 종속관계를 추정하여 고장 부위를 규명하고 처리하는 방법을 제시한다. 센서들 사이의 관계를 규명하기 위한 알고리즘으로 비선형성과 다양한 환경 변화를 수용할 수 있는 고장진단 알고리즘을 다층 신경망(Multi-layer neural network)과

디지털 알고리즘으로 구현하고 실험데이터에 기초한 시뮬레이션을 통하여 제안한 방법의 실현 가능성 을 검증한다.

## II. 엔진 제어시스템 모델

본 논문에서 다루는 엔진 제어시스템은 센서 부시스템(Sensor and instrument subsystem), 액츄에이터 부시스템(Actuator subsystem), 및 엔진 동역학 시스템(Main engine system)으로 구성된다. 센서류는 회전속도, 압축기와 터빈의 입구와 출구에서의 온도와 압력 등의 물리량을 측정하는 부분이며 액츄에이터는 연료유량을 제어하는 서어보 밸브이며 동역학 시스템은 연료유량에 따른 엔진의 동역학 특성이다.

본 연구에서 사용하고자 하는 센서신호는 엔진 회전속도(RPM), 배기가스 온도(T5), 터빈 입구 온도(T4), 압축기 출구압력(P3), 터빈 출구압력(P5), 터빈 입구압력(P4)와 압축기 출구온도(T3) 등 7개이다.

엔진 모델은 DYNGEN 프로그램<sup>[7]</sup>을 이용하여 얻은 선형 상태방정식으로 표현되며 다음과 같다.

$$\begin{aligned} \frac{dx_i(t)}{dt} &= A_i x_i(t) + B_i u(t) \\ y(t) &= C_i x_i(t) \quad i=1, 2, \dots, N \end{aligned} \quad (1)$$

여기서  $N$ 은 선형화를 위해 설정한 작동점의 수로 RPM이 100%일 때를 설계점을 기준으로 40%, 50%, 60%, 70%, 80%, 90%, 100% 등 7개를 취하였으므로  $N=7$ 이다. 상태변수는 7개이며 출력변수도 7개이고 입력변수는 1개이다.

스텝응답과 주파수응답을 이용해 선형 모델을 분석한 후 내부균형법을 이용해 모델 축차를 수행하였다. 그럼 1의 Hankel 특이값과 특이값 선도를 보면 4차 모델로 축차하여도 오차가 크지 않으므로 4차 축차 모델을 사용하기로 한다. 이는 7개의 센서중에서 3개의 센서는 다른 센서와 기능적인 종속관계(Analytical redundancy)가 있음을 의미하며 이 관계를 이용해 최대 3개의 센서가 동시에 고장이 발생

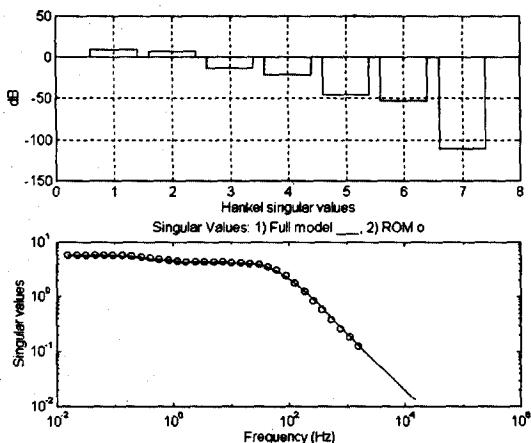


그림 1. Hankel 특이값과 특이값 선도

Fig. 1. Hankel singular value and singular value plots.

할 때라도 거의 오차없이 모든 센서신호를 재구성할 수 있을 뿐만 아니라 제어기의 재구성을 통해 고장 방지를 위한 조치를 취할 수 있음을 의미한다.

축차된 선형 모델의 운동방정식은 다음과 같다.

$$\begin{aligned} \frac{dz_i(t)}{dt} &= a_i z_i(t) + b_i u(t) \\ y(t) &= c_i z_i(t), \quad i=1, 2, \dots, N \end{aligned} \quad (2)$$

여기서 상태벡터  $z_i(t)$ 는  $4 \times 1$  벡터이고 각각의 행렬은 여기에 상응하는 차원을 갖는다.

이렇게 구성된 축차모델에 대하여 ZOH(Zero-Order Hold) 샘플링을 이용한 이산 시스템은 다음과 같다.

$$\begin{aligned} z_i(k+1) &= a_i z_i(k) + \beta_i u(k) \\ y(k) &= \gamma_i z_i(k) \quad i=1, 2, \dots, N \end{aligned} \quad (3)$$

여기서  $a_i = \exp(a_i T)$ ,  $\beta_i = \int_0^T \exp(a_i s) b_i ds$ ,  $\gamma_i = c$ 이며  $T$ 는 샘플링 주기이다.

### III. 신경망을 이용한 고장진단

#### 3-1 고장진단 알고리즘

센서 결함(fault)은 크게 돌발적인 결함(cataleptic faults)과 서서히 진행되는 결함(evolving faults)으로 분류할 수 있다. 센서나 부품의 노화에 따른 결함 진행은 운전 중 실시간으로 규명하기보다는 오프라인(off-line)으로 주기적인 점검(periodic identification)에 의해 진단하는 것이 효율적이므로 본 논문에서는 전자의 결함 탐지 및 조치에 중점을 둔다. 돌발적인 결함의 발생은 빠른 시간내에 시스템에 전달되어 피드백 제어기의 고장에 이를 수 있으므로 제어기에서 실시간으로 결함 탐지 및 조치가 이루어 지도록 구현되어야 하며 제어기의 신뢰성 확보를 위해서도 중요하다. 그림 2의 FDIS프로그램을 기능적으로 도시하면 그림 3과 같다.

센서의 갯수가 상태변수 수보다 충분히 커서 여유분(redundancy)이 있다고 가정하면 잃어버린 일부의 센서 신호를 다른 센서 신호를 이용해 재구성 할 수 있다. 상태변수와 센서출력 사이의 수학적인 관계를 이용해 기능이 고장난 센서 출력을 재구성할 수 있으며 강인성(robustness)과 유연성(flexibility)이 우수한 다층 신경망을 이용해 센서신호의 정상작동 여부를 규명한다.

신경망은 그림 4와 같이 은닉층(hidden layer)이 1개인 2층 신경망을 2개 직렬로 연결한 구조로 되어 있으며 전 단계에서는 센서 신호로부터 상태변수를 추출해 내는 정보압축(Information compression) 기능을 하고 두 번째 단계에서는 추출된 상태변수로부터 센서출력을 추정해 내는 정보재생(Information regeneration) 역할을 한다. 그러므로 정상 작동시 신경망의 입력과 출력은 동일하게 되며 은닉층에 다수의 신경이 있어 잘못된 센서 신호를 걸러내는 작용을 하기 때문에 하나 또는 그 이상의 센서의 고장에도 비교적 정확한 센서의 출력을 추정해낸다.

그림 4는 제어입력신호를 배제한 출력신호만의 신경망이며, 그림 5는 제어입력을 추가한 변형된 신경망이다. 그림 4의 신경망이 센서들 사이의 정적인 기능관계에 의존한 반면 그림 5의 신경망은 이산화된 차분방정식의 동적 관계를 이용하므로 제어입력 센서의 고장여부도 판단할 수 있으며 신경망의 은닉층을 줄여 계산시간을 단축시켜 실시간 구현을 용이하도록 한다.

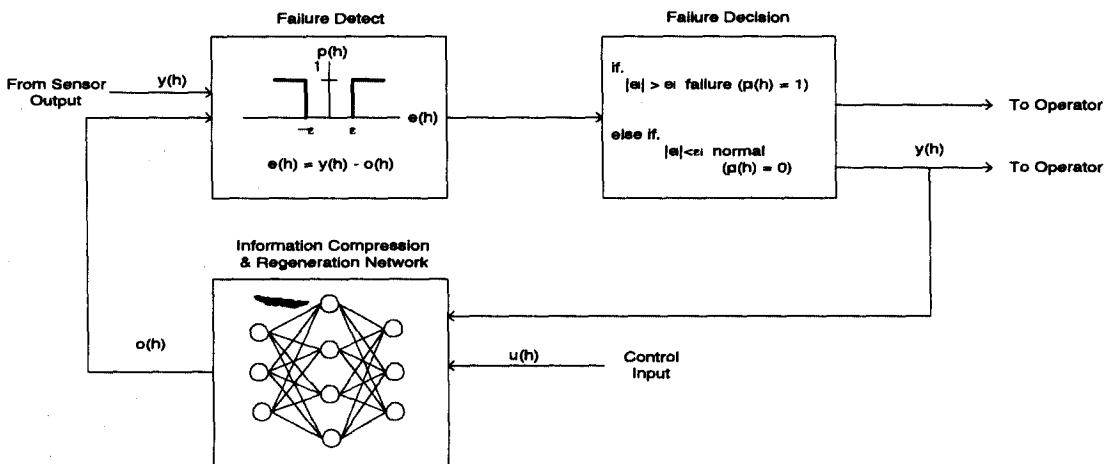


그림 2. 고장진단 시스템 블록선도

Fig. 2. Fault detection and isolation system block diagram.

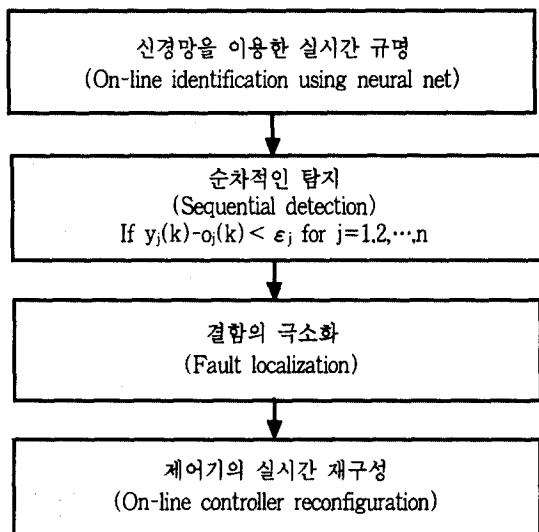


그림 3. 고장진단 알고리즘

Fig. 3. Fault detection algorithm.

### 3-2 신경망의 훈련

그림 4와 5의 신경망을 실시간으로 이용하기 위해 우선 각각의 은닉층에 있는 신경세포의 크기를 결정한 후 각각의 층을 연결하는 가중치의 값을 결정한다. 입력층은 전자의 경우 7개, 후자의 경우 8개이며 출력층은 모두 7개이다. 상태층은 4개이며 이는 축차모델의 차수와 같다. 결과적으로 상태층을

통과하면서 7개의 센서 정보가 4개로 압축되고 다시 출력층을 통과하면서 다시 7개의 정보로 재구성된다. 이 과정에서 여분의 정보는 고장진단을 위한 정보로 활용된다. 이는 최소자승법과 유사한 것으로 보이지만 최소자승법의 경우 7개 센서의 평균개념을 이용하는데 비해 이 방법은 학습에 필요한 자료만 충분히 제공되면 정상적인 센서에 영향을 주지 않고 고장난 센서의 완벽한 분리가 가능한 장점이 있다.

신경망이 고장난 센서의 신호를 효과적으로 분리하여 정확한 추정치를 주기 위해서는 정상작동상태에서 얻어진 데이터를 이용해 오프라인으로 신경망을 훈련시키는 것이 필요하다. 훈련과정은 다음과 같은 단계로 구성된다.

- ① 정상상태에서 가능한 전 운전영역에서 입출력 데이터의 수집
- ② 센서출력의 허용오차의 결정(고장난 경우와 정상인 경우의 출력의 허용범위)
- ③ 입력정보의 랜덤화(국부적인 최소점에 머물지 않기 위해 필요)
- ④ 특정한 센서고장에 대하여 잡음을 삽입하여 센서 고장을 시뮬레이션

학습 알고리즘은 역전파 알고리즘(backpropagation algorithm)을 이용하며 신경망의 가중치를 정상 데이터와 고장난 센서데이터를 이용해 조정한다. 신경망을 이용하는 가장 큰 이유가 정상작동시의 센서

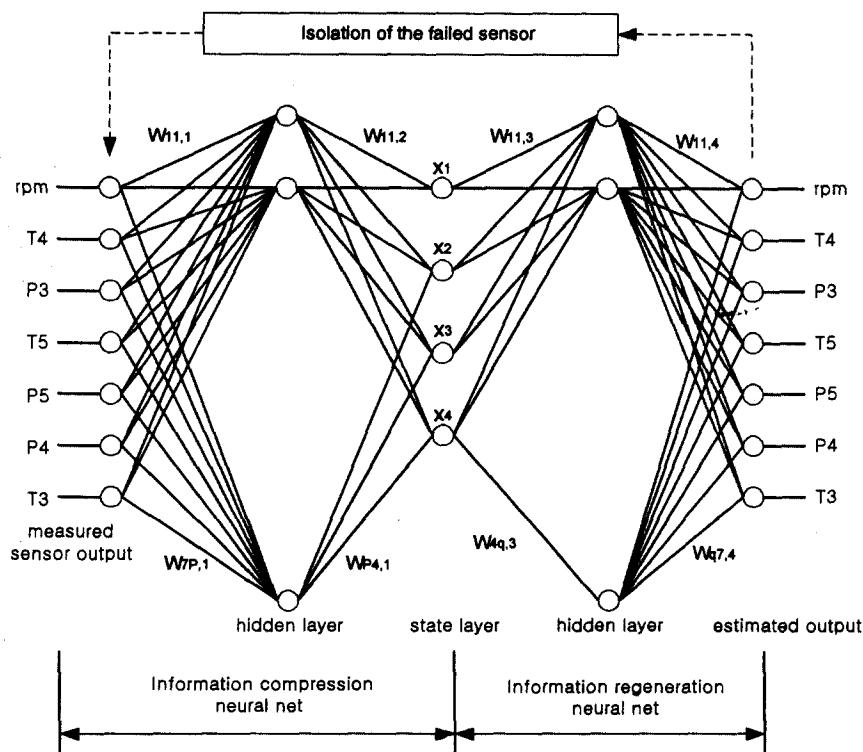


그림 4. 센서 검증을 위한 다층 신경망

Fig. 4. Multilayer neural network for sensor validation.

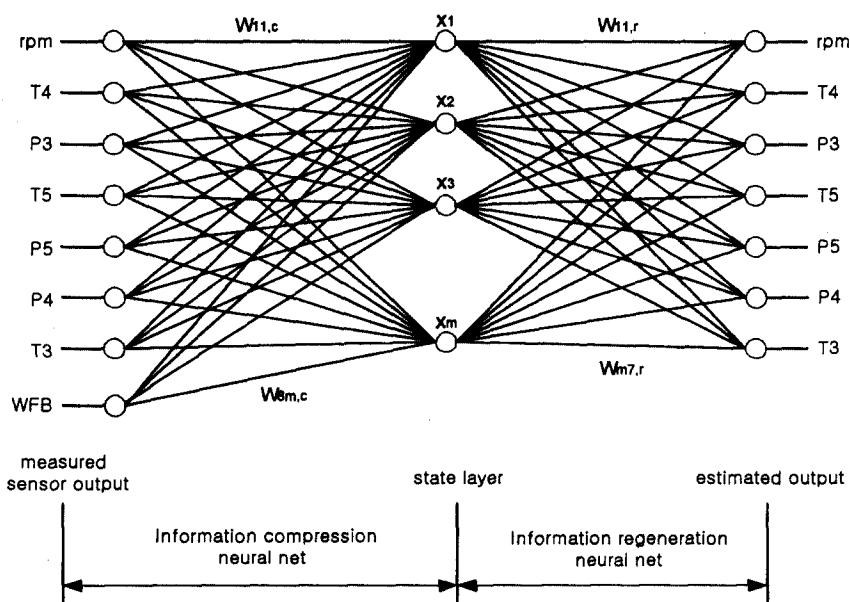


그림 5. 센서 검증을 위한 변형된 신경망

Fig. 5. Modified neural network for sensor validation.

출력 및 상태변수의 추정이 아니라 고장난 센서신호가 추정된 센서출력에 영향을 끼치지 못하게 하는 것이므로 훈련과정에서 이를 고려하는 것이 중요하다. 수렴도와 정확도를 개선하기 위하여 모멘텀(momentum)과 적응학습규칙을 사용하여 다음과 같다.

$$\Delta w_{new, ij, k} = \alpha \Delta w_{old, ij, k} + (1 - \alpha) l_r \cdot D_{i, k+1} P_{j, k} \quad (4)$$

$$w_{new, ij, k} = w_{old, ij, k} + \Delta w_{new, ij, k} \quad (5)$$

여기서,  $w, ij, k$ 는  $k$ 번째 신경층의  $j$ 번째 뉴런(neuron)과  $k+1$ 번째 신경층의  $i$ 번째 뉴런을 연결하는 가중치이며  $\alpha$ 는 모멘텀 상수로 보통 0.95 정도,  $l_r$ 은 학습률(learning rate)을 의미하며 수렴도에 따라 학습과정에서 적응 알고리즘 이용해 변화시킨다.  $D_{i, k+1}$ 는  $k+1$ 번째 층의 델타벡터,  $P_{j, k}$ 는  $k$ 번째 층의 입력벡터를 의미하며 출력층에서 입력층으로의 역전파 알고리즘을 이용하여 학습하게 된다. 신경세포는 탄젠트-시그모이드(tangent-sigmoid) 함수와 순수한 선형함수를 조합해 사용한다.

훈련된 신경망을 통해 재구성되는 센서출력은 다음과 같이 주어진다.

그림 4의 5층 신경망의 경우:

$$x_i = f_{i, 2} \left( \sum_{j=1}^m w_{ij, 2} f_{j, 1} \left( \sum_{k=1}^n w_{jk, 1} y_k \right) \right) \quad i = 1, 2, 3, 4 \quad (6)$$

$$o_l = f_{l, 4} \left( \sum_{m=1}^2 w_{lm, 4} f_{m, 3} \left( \sum_{k=1}^n w_{mk, 3} x_k \right) \right) \quad l = 1, 2, \dots, n \quad (7)$$

그림 5의 3층 신경망의 경우:

$$o_l = f_{l, 2} \left( \sum_{m=1}^1 w_{lm, 2} f_{m, 1} \left( \sum_{k=1}^n w_{mk, 1} y_k + w_{mu} u \right) \right) \quad l = 1, 2, \dots, n \quad (8)$$

여기서  $f_{i, k}$ 는  $k$ 번째 신경층의  $i$ 번째 신경세포의 함수이며,  $o_k$ 는 출력층의 출력벡터로 새로 재구성된 센서신호이다.

신경망을 통해 얻어진 신호  $o_k$ 와 측정신호  $y_k$

의 비교를 통해 다음과 같이 각각의 센서에 대한 고장신호  $s_k$ 를 발생시킨다.

$$\begin{aligned} \text{If } |y_k - o_k| < \epsilon_k, \text{ then } s_k = 0(\text{normal}) \\ \text{else if } |y_k - o_k| > \epsilon_k, \text{ then } s_k = 1(\text{fault}), \\ k = 1, 2, \dots, n \end{aligned} \quad (9)$$

여기서  $\epsilon_k$ 는  $k$ 번째 센서의 정확도를 고려한 허용 가능한 오차를 의미하며 센서의 상태에 관한 상태플래그벡터  $S$ 는 다음과 같이 구성된다.

$$S = [s_1, s_2, \dots, s_n] \quad (10)$$

식 (10)의 상태 플래그벡터  $S$ 를 조사하면 센서의 고장유무를 알 수 있으며, 동시에 샘플링 순간마다  $S$ 의 플래그벡터를 조사하여 플래그가 1인 센서에 대해서는 재어기의 입력신호를  $y_k$  대신  $o_k$ 로 대치시킨다.

#### IV. 시뮬레이션

DYNGEN을 이용해 연료유량이 40%일 때의 정상상태에서 얻은 선형 모델을 이용하여 시뮬레이션을 실시하였다. 입력은 연료유량 하나이고 출력은 회전속도(rpm), 터어빈 입구온도(T4), 압축기의 출구압력(P3), 터어빈의 출구온도(T5), 터어빈의 출구압력(P5), 터어빈의 입구압력(P4) 및 압축기의 출구온도(T3)이다. 7차의 상태공간 모델에 대하여 Hankel의 특이값을 구하면 그림 1과 같이 2,6643, 2.1925,  $1.9702 \times 10^{-1}$ ,  $8.2924 \times 10^{-2}$ ,  $5.0160 \times 10^{-3}$ ,  $2.3232 \times 10^{-3}$ ,  $3.1117 \times 10^{-6}$ 이므로 4차 축차모델로 표현하는 것이 가능하다. 축차모델링 방법은 내부균형법을 이용하였으며 출력 7개, 상태변수 4개이므로 센서의 여분이 존재하고 신경망을 이용한 센서신호의 적합성을 검증할 수 있다.

신경망의 학습은 50% 정상상태의 연료유량을 기준으로  $\pm 5\%$ (45%~55%)의 범위안에서 연료유량이 변할때의 정상상태 값을 기준으로 역전파 알고리즘을 이용해 가중치  $w_{ij, k}$ 를 구했으며 이때의 학습과정과 학습률에 대한 결과는 그림 6과 같다. 신경망은 약 3,000회의 반복수행을 거쳐 오차 제곱합이

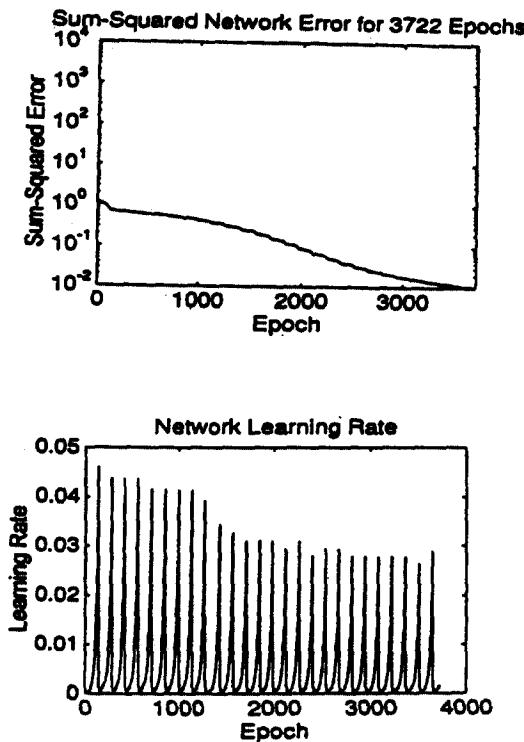


그림 6. 신경망 학습 결과

Fig. 6. Neural net training results.

설정치인 0.01이하가 되었으며 이렇게 훈련된 신경망을 이용한 추정된 센서신호를 참값과 함께 그림 7에 나타내었다. 그림에서 보면 센서가 정상작동할 때 측정치와 추정치가 거의 일치하는 것을 알 수 있다. 이는 정상작동시 신경망이 효과적으로 훈련되었음을 보여준다.

7개의 센서 출력 중 어느 하나의 센서가 고장을 일으켜 비정상적인 출력을 보일 때 이를 규명하는 예를 보이기 위해 회전속도(rpm)센서가 고장을 일으킨 예를 그림 8에 나타내었다. 그림 8에서 보인 바와 같이 센서가 고장을 일으켜 50% 정도의 비정상적인 값을 보일 때에도 다른 센서의 측정값에 영향을 주지 않으면서 고장난 센서의 출력값을 비교적 정확하게 추정해 내는 것을 알 수 있다. 기타 다른 센서들이 개별적으로 고장을 일으킨 경우도 비슷한 결과를 주며 오차는 훈련과정에서 고장발생별로 얼마나 충실한 데이터를 제공하느냐에 달려 있다.

마지막으로 두 센서가 동시에 고장을 일으킨 경

우를 시뮬레이션하였는데 그림 9에 보인 바와 같이 회전속도센서와 터빈입구 온도센서가 동시에 고장을 일으킨 경우에도 정상작동하는 나머지 5개의 센서를 포함한 모든 센서의 참값을 거의 오차없이 재생시키는 것을 알 수 있다. 이 경우 RPM센서는 50 스텝(1초) 후에 50% 증가된 센서신호가 발생된 후 75 스텝(1.5초) 후 50% 감소된 센서신호를 가상하였으며 터빈입구온도센서는 0.8초에서 50%증가, 1.3초에서 50% 감소시켜 서로 다른 시간에 각각 발생한 고장을 상정하였다. 이 알고리즘은 디지털 샘플링된 신호를 모델로 하였으므로 엔진 제어기에 디지털 알고리즘으로 쉽게 실시간 구현이 가능하다.

## V. 결 론

본 논문에서는 터보제트 엔진제어에 필요한 센서 결합을 감지하여 조치하기 위한 고장진단 알고리즘을 신경망을 이용하여 설계하였다. 제안된 알고리즘은 엔진상태를 측정하기 위한 다른 종류의 센서 사이의 기능적 종속관계를 고려한 다층 신경망 구조를 가지며 역전파 알고리즘을 이용하여 훈련된 신경망으로부터 센서출력이 얻어지도록 하였다. 실험데이터에 기초한 시뮬레이션을 통하여 센서가 고장을 일으킨 경우에도 센서의 참값을 고장없이 재생시킴을 확인하였으며 엔진제어를 위한 고장진단 알고리즘으로 적용될 수 있음을 검증하였다.

## 참 고 문 헌

- [1] E. Y. Chow and A. S. Willsky, "Analytical redundancy and the design of robust failure detection systems," *IEEE Auto. Contr.*, vol. AC-29, no. 7, pp. 603-614, July, 1984.
- [2] T. H. Kerr, "Decentralized filtering and redundancy management for multisensor navigation", *IEEE Transactions on Aerospace and Electronic Systems*, vol. AES-23, no. 1, pp. 83-119, Jan., 1987.
- [3] W. C. Merrill and J. C. Delaat, "A real-time simulation evaluation of an advanced detec-

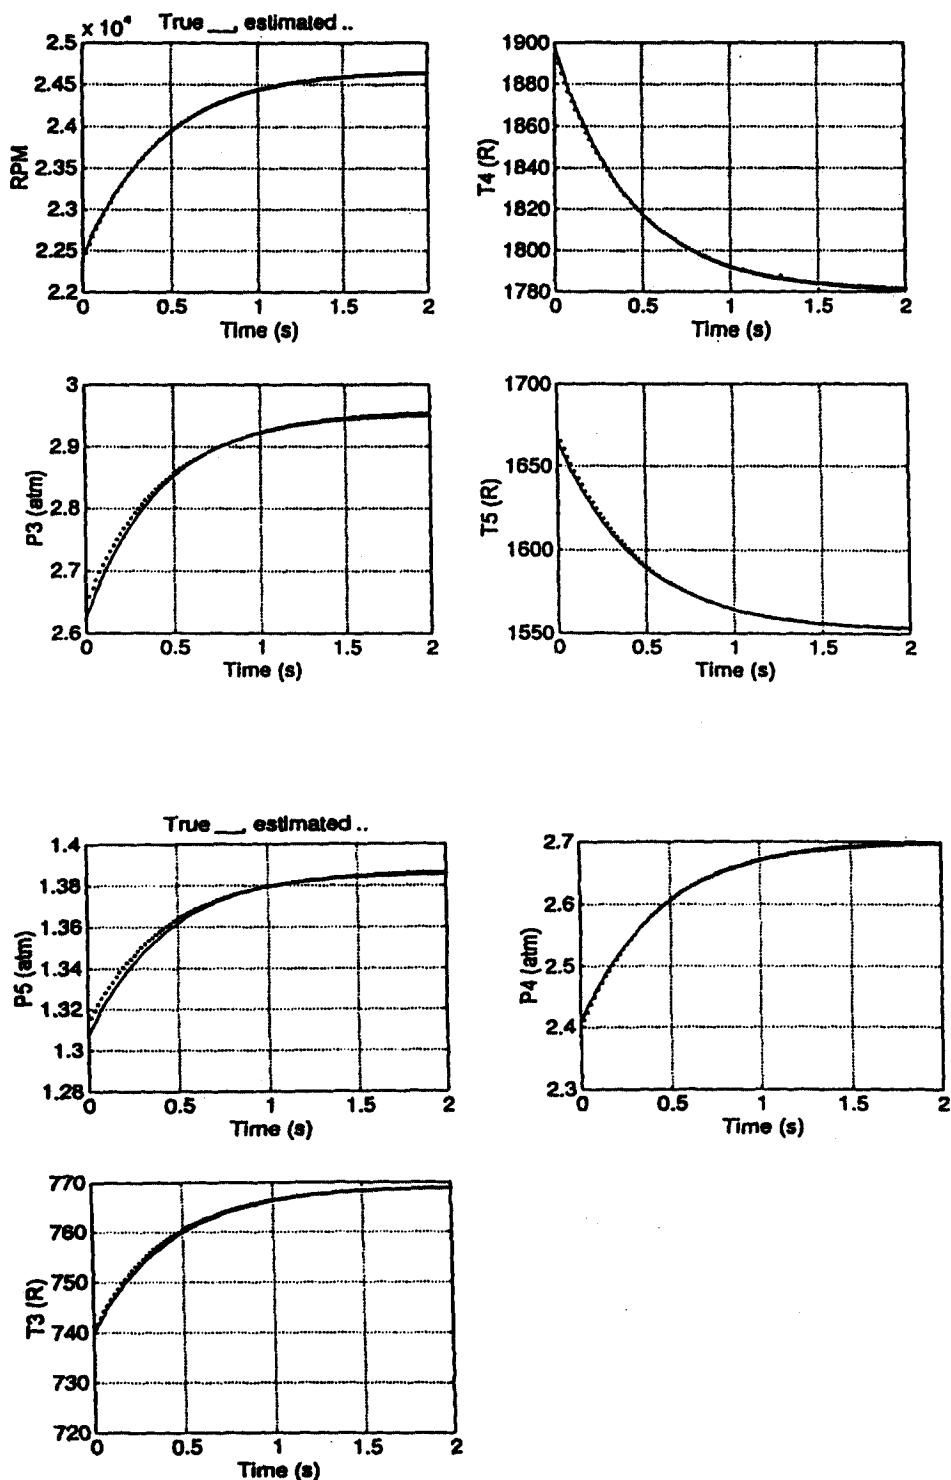


그림 7. 센서 검증 결과

Fig. 7. Sensor validation results.

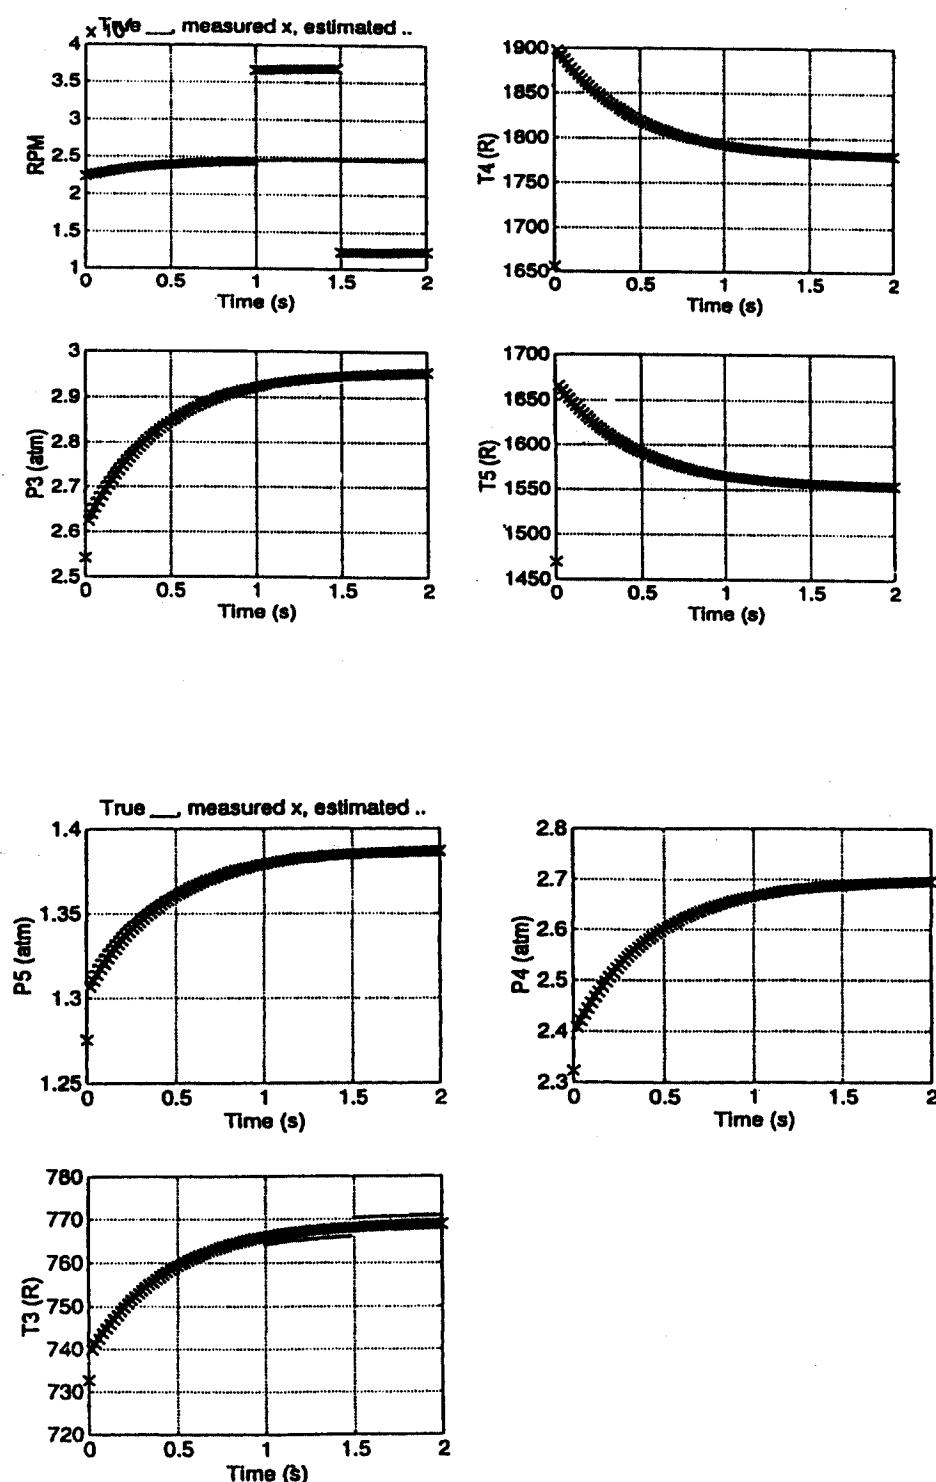


그림 8. 센서검증 결과(RPM 센서 고장)

Fig. 8. Sensor validation results(RPM sensor failure).

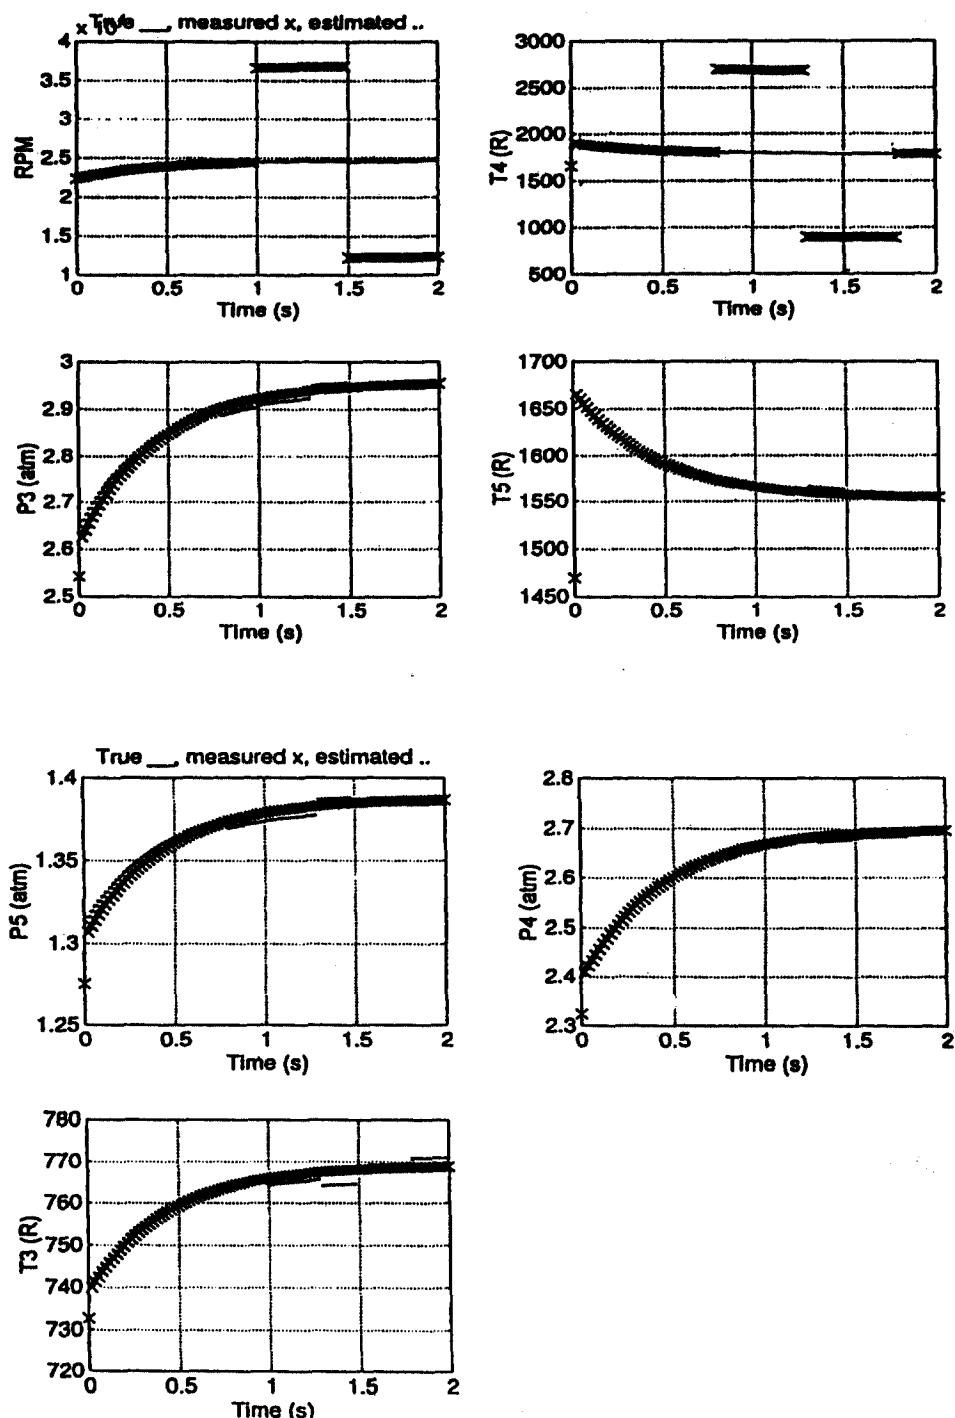


그림 9. 센서 검증 결과(RPM & T4 센서 고장)

Fig. 9. Sensor validation results(RPM & T4 sensor failure).

- tion, isolation and accommodation algorithm for sensor failures in turbine engines," NASA TM-87289, 1986.
- [4] L. J. Kerr, T. S. Nemec and G. W. Gallops, "Real-time estimation of gas turbine engine damage using a control-based Kalman filter algorithm," *J. of Engineering for Gas Turbine and Power*, vol. 114, pp.187-195, April, 1992.
- [5] Guo T. H. and Musgrave J., "Neural net
- work based sensor validation for reusable rocket engines", *Proc. of the American Control Conference*, pp. 1367-1372, 1995.
- [6] F. N. Chowdhury, "A neural approach to data fusion", *Proc. of the American Control Conference*, pp. 1693-1697, 1995.
- [7] 유상신, 부준홍, 이강웅, 김진곤, 김종선, "전자식 엔진 제어기 적용을 위한 실험연구(Ⅱ)", 국방과학연구소, 1996.

### 김 종 선(金鍾璣)

1983년 2월 : 서울대학교 기계공학과(공학사)  
 1985년 2월 : 한국과학기술원 기계공학과(공학석사)  
 1989년 8월 : 한국과학기술원 기계공학과(공학박사)  
 1989년 9월~1992년 2월 : 금오공과대학 기계공학과 조교수  
 1992년 3월~현재 : 한국항공대학교 기계설계학과 부교수  
 관심분야 : 진동제어, 신경망제어, 서보제어

### 이 강 웅(李康熊)



1980년 2월 : 한국항공대학교 항공전자공학과(공학사)  
 1982년 2월 : 서울대학교 전자공학과(공학석사)  
 1989년 8월 : 서울대학교 전자공학과(공학박사)  
 1983년 1월-1984년 2월 : 삼성전자(주) 연구원

1994년 1월-1995년 1월 : 미국 Michigan State Univ. 전기공학과 방문교수  
 1989년 9월~현재 : 한국항공대학교 항공전자공학과 부교수  
 관심분야 : 비선형제어, 강인제어, 적응제어, 로봇 제어, 전동기제어

### 김 진 곤(金津坤)



1976년 2월 : 고려대학교 기계공학과(공학사)  
 1979년 2월 : 인하대학교 기계공학과(공학석사)  
 1984년 6월 : 프랑스 Poitiers 대학(공학박사)  
 1980년~1991년 2월 : 대한항공 항공기술연구원 선임연구원  
 1991년 3월~현재 : 한국항공대학교 기계설계학과 부교수  
 관심분야 : 항공기 엔진, 안전

### 부 준 홍(夫俊洪)



1978년 2월 : 서울대학교 공과대학 기계공학과 졸업(공학사)  
 1984년 : 미국 Georgia Institute of Technology(기계공학 석사)  
 1989년 : 미국 Georgia Institute of Technology(공학박사)  
 1979년~1982년 : 공군사관학교 교수부 기계공학과 교관  
 1989년 3월~현재 : 한국항공대학교 항공기계공학과 교수  
 1994년 8월~1995년 8월 : 미국 Texas A&M University 연구교수  
 관심분야 : 가스터빈, 열전달, 히트파이프

## 유 상 신(柳常新)



1960년 2월 : 공군사관학교 졸업  
1964년 2월 : 서울대학교 기계공학과(공학사)  
1971년 : 미국 Univ. of Illinois 대학원(공학석사)  
1974년 : 미국 Univ. of Illinois 대학원(공학박사)  
1964년~1985년 : 공군사관학교 교수  
1985년~현재 : 한국항공대학교 기계설계학과 교수  
1993년~1995년 : 한국항공대학교 대학원장  
1994년 : 한국항공우주학회 회장  
1995년 : 대한기계학회 회장  
관심분야 : 유체공학, 열기관, 생체공학

## 민 성 기

1982년 2월 : 고려대학교 기계공학과(공학사)  
1987년 2월 : 고려대학교 기계공학과(공학석사)  
1992년 2월 : 고려대학교 기계공학과(공학박사)  
1992년 4월~현재 : 국방과학연구소 근무  
관심분야 : 제트엔진 운용시험평가, 연소기 연료노즐 설계 및 시험평가, 엔진제어