

# 신경망을 이용한 실시간 고장 진단 시스템

정희원 김문성\* 유승선\*\* 소정훈\*\* 박훈성\*\*\*

## On-Line Fault Diagnosis System using Neural Network

Moon-seong Kim\*, Seung-sun Yoo\*\*, Jung-hoon So\*\*, Hoon-sung Kwak\*\*\* *Regular Members*

### 요 약

본 논문에서는 신경망을 이용한 실시간 고장 검출 및 진단(FDD : Fault Detection and Diagnosis) 시스템을 제안한다. 제안된 시스템은 공조 시스템(AHU : Air Handling Unit)에서 발생 가능한 여러 고장들을 검출하고 진단할 수 있다. 고장 검출 및 진단 기법으로 3층 구조의 전방향(feed-forward) 신경망을 사용하였고, 여기에 사용된 학습 방법은 역전파(back-propagation) 학습 알고리즘이다. 공조 시스템에 적용된 실시간 고장 검출 및 진단 시스템은 비주얼 C++와 비주얼 베이직을 사용하여 구현하였다. 제안된 고장 검출 및 진단 시스템을 실제 운전 중인 공조 시스템에 적용하여 실험하였고, 정확한 고장 검출 및 진단이 수행됨을 실험 결과로서 입증하였다.

### ABSTRACT

In this paper, we propose an on-line FDD(Fault Detection and Diagnosis) system based on the three layer feed-forward neural network which is trained by the back-propagation learning algorithm. We implement the on-line fault detection and diagnosis system by Visual C++ and Visual Basic.

The proposed FDD system is applied to an air handling unit in operation. Experimental results show the high performance of our system in the task of fault detection and diagnosis.

### I. 서론

자동화, 대형화, 복잡화를 중심으로 한 기술 집약적인 시스템의 발전이 가속화되면서 공조 시스템의 대량 생산과 생산 경비의 절감을 가능하게 하였지만, 고장 발생에 따른 경제적 손실과 위험성은 증폭되었을 뿐만 아니라 고장 발생과 발생 위치 등의 신속한 원인 규명이 이루어지지 못하므로 시스템의 안정성과 신뢰성 확보가 어렵게 되었다. 따라서 이러한 시스템의 안정성과 신뢰성 개선을 위해서 새로운 개념의 고장 검출 및 진단 기법의 필요성이 요구되고 있다.

고장 검출 및 진단 시스템은 시스템의 운전 상황을 감시하고, 고장이 발생된 시스템의 성능 저하를 미리 검출하거나 이상 동작의 원인이 되는 고장과 위치를 신속히 검출하여 고장의 정도를 분석하여

진단함으로써 운영자에게 적절한 처리 방법에 대한 정보를 제공하는데 있다<sup>1-3)</sup>.

고장 검출 및 진단 기술은 항공, 발전, 화학공정 등의 안정성이 요구되는 분야에서 활발한 연구가 이루어지고 있는 기술이지만, 최근에는 각종 산업공정과 경제성 제고를 위해서 적용이 점차 확대되고 있으며, 적용 기술이 매우 다양하므로 도입 효과를 극대화하기 위해서는 대상 프로세스의 구성요소, 동특성, 수학적 모델의 유무, 측정 가능한 변수와 오경보율, 검출율 등의 고장 검출 및 진단시스템의 성능, 선정된 기법의 실현 경비 등 매우 많은 요인을 고려하여 적용되어야 한다<sup>4)</sup>.

본 논문에서는 신경망을 이용한 고장 진단 기법을 실제 운전 중인 공조 시스템에 적용하여 고장 검출 및 진단 기법의 정확성 및 적용 가능성을 분석하였다. 고장 진단 시스템은 데이터 인터페이스부,

\* 대원과학기술대학교 컴퓨터정보통신과(kms@daewon.ac.kr)  
논문번호: 010120-0524, 접수일자: 2001년 5월 24일

\*\* 한국에너지기술연구소,

\*\*\* 전북대학교 컴퓨터공학과

정상 상태 검출부, 고장 검출 및 진단부로 구성하였고, 고장 진단에는 3층 전방향 구조의 신경망 모델을, 학습 과정은 개선된 역전파 학습 알고리즘을 적용하였다<sup>[5]</sup>.

신경망 학습에 사용된 고장 정보는 고장 모델을 만들어 특정 시간 동안 급격한 고장 신호를 공조 시스템에 적용한 결과를 이용하여 구축하였다. 실험 결과, 제한한 실시<sup>Nonondal room</sup> 고장 진단 기법의 실제 적용<sup>Utility room</sup> 가능성을 확인하였다.

## II. 실험 장치

시험 주택 내 비온돌 실험실과 환경 실험실에 고장 검출 진단 실험 용 가변풍량(Variable Air Volume) 시스템을 구성하였다. 그림 1은 철근콘크리트 라멘조 구조로 종합적인 성능 실험을 수행할 수 있는 시험 주택의 구조를 보여준다. 그림 2는 가변풍량(Variable Air Volume) 시스템의 구성과 제어대상 입·출력신호의 구성을 보여준다. 공조 시스템은 냉·난방을 1개의 공조기로 수행하고, 급기 송풍기의 정압 제어와 순환 송풍기의 풍량 차 제어를 위해서 가변속 제어가 가능하도록 하여 경제성 및 에너지 절약 평가를 수행할 수 있도록 하였고, 실내 온도와 풍속 변화 시 실내로 공급되는 풍량의 제어




그림 1. 시험주택의 구조

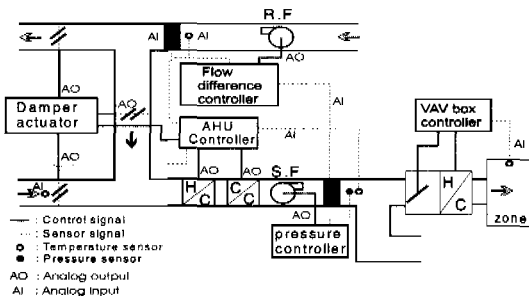


그림 2. 가변풍량(VAV) 공조시스템의 구성

를 위해서 각 공간에 VAV(Variable Air Volume) 박스를 설치하였다.

그림 3은 가변풍량(VAV) 공조 시스템의 자동 운전을 위해서 설치된 현장 제어기와 공조 제어 패널을 보여준다. 공조 제어 패널에는 급기 송풍기, 순환 송풍기의 출력을 가감속할 수 있는 가변속 인버터, 냉난방용 제어장치, 덕싱박스의 댐퍼 제어장치 등이 설치되어 있다.





그림 3. 실험장치

## III. 고장 진단 시스템

### 1. 적용 기법

고장 검출 및 진단은 관측 대상의 측정치와 모델 예측치의 차이값 즉, 잔차를 추출한 후 이를 분석하여 고장의 발생 여부를 판단하고 식별된 고장의 원인, 파급 효과, 고장의 정도 등을 산정하는 과정을 의미한다. 그림 4는 고장 검출 및 진단 적용 기법의 흐름도를 보여준다. 고장 검출 및 진단을 위한 공정 감시 기법은 검출, 진단, 판단 및 처리의 순서로 구성되어 있다. 첫 번째 단계인 고장 검출은 감시되는

시스템의 실제 성능과 예측된 성능이 차이가 있을 때 고장을 지시하는 과정이다. 두 번째 과정인 진단은 고장의 원인이나 위치를 지정하는 과정이다. 고장 검출 및 진단 적용은 다음의 단계를 통해서 이루어진다.

- ① 잔차 발생(Residual Generation)
- ② 고장 검출 논리
- ③ 고장 진단 정보(특정값)의 추출 알고리즘
- ④ 고장 진단 논리와 추론 알고리즘 및 모델 검증

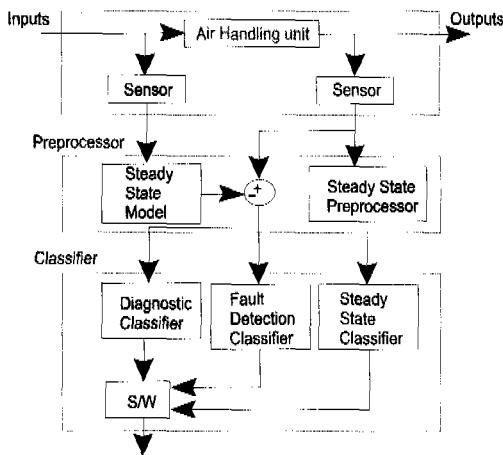


그림 4. 고장검출 및 진단기법의 흐름도

## 2. 역전파 신경망 모델

본 논문에서 사용된 고장 진단 기법은 입력층, 은닉층, 출력층으로 구성된 3층 구조의 전방향 신경망과 학습 방법으로는 역전파 학습 알고리즘을 사용하였다. 역전파 학습 알고리즘은 다층 전방향 퍼셉트론의 실제 출력과 기대되는 출력 간의 오차가 최소화되도록 설계된 일종의 반복적 기울기 알고리즘으로 입력 노드의 값을 합산하여, 처리 노드의 출력 값을 만들기 위해 임의의 활성화 함수를 통해 전달되




그림 5. 3층 구조의 전방향 신경망

는데 주로 많이 사용하는 활성화 함수는 시그모이드 함수이다. 그림 5는 3층 구조의 전방향 신경망의 구성을 보여준다.

역전파 알고리즘을 이용한 신경망의 학습 방법은 다음의 단계로 이루어진다.

(1) 연결 가중치  $w_{ji}$ 와 고유 바이어스  $\theta_j$ 를 작은 값을 갖는 임의의 수로 초기화한다.

(2) 입력 벡터와 기대되는 출력 벡터를 제시한다.

연속값의 입력 벡터  $x_0, x_1, \dots, x_{n-1}$ 을 제시하고 기대되는 출력  $d_0, d_1, \dots, d_{M-1}$ 을 지정한다. 고장 진단을 위해서 입력 패턴의 부류에 해당하는 출력을 제외한 모든 출력을 0으로 설정하고 기대되는 출력만을 1로 설정한다. 입력 패턴은 연결 가중치가 안정될 때까지 반복적으로 제시한다.

(3) 실제 출력값을 계산한다.

시그모이드 비선형 함수와 식으로 출력  $y_0, y_1, \dots, y_{M-1}$ 을 계산한다.

(4) 실제 출력값과 기대되는 출력값의 오차를 계산한다.

(5) 이 오차값을 최소화하도록 네트워크의 연결 가중치를 조정한다.

연결 가중치의 조정은 기본 델타 학습 법칙과 같은 다음 식에 의해서 결정된다.

$$w_{ji}(t+1) = w_{ji}(t) + \eta \delta_j x_i \quad (1)$$

여기서,  $w_{ji}(t)$ 는 시간  $t$ 에서 은닉층의 유닛  $i$  또는 입력에서 유닛  $j$ 로의 연결 가중치이고,  $x_i$ 은 유닛  $i$ 의 출력값 또는 입력값이다.  $\eta$ 는 이득률이고,  $\delta_j$ 는 유닛  $j$ 에 대한 오류값이다.  $j$ 가 출력 유닛이면  $\delta_j$ 는 다음의 식으로 주어진다.

$$\delta_j = y_j(1 - y_j)(d_j - y_j) \quad (2)$$

여기서,  $d_j$ 는 유닛  $j$ 의 기대되는 출력이고  $y_j$ 는 실제 출력이다. 오차값을 구한 후에 활성화 함수인 시그모이드 함수의 미분값과 곱해서 값을 구한다. 유닛  $j$ 가 은닉층의 유닛이면  $\delta_j$ 는 출력층의 오차를 층별로 역전파시켜서 각 층의 연결 강도를 조정하는 방법으로 학습하여 다음의 식으로 구한다.

$$\delta_j = x_j(1 - x_j) \sum_k \delta_k w_{jk} \quad (3)$$

(6) 전체 학습 패턴의 오차가 임계치보다 작아질 때까지 각 학습 패턴에 대해서 단계 2에서 5까지의 단계를 반복한다.

### 3. 고장 진단 시스템

공조 시스템의 운영을 통해서 수집된 고장 정보와 신경망을 사용한 진단 알고리즘을 Visual C++, Visual Basic 환경의 고장 진단 시스템으로 구현하였다. 시스템은 통합 감시 운영 제어 시스템과 고장 진단 시스템을 독립적으로 구성하여 시스템 간의 데이터 인터페이스를 통해서 실시간 고장 진단에 필요한 정보를 서로 공유할 수 있도록 하였다.

그림 6은 실시간 고장 검출 및 진단 시스템을 보여준다. 프로그램 구성은 고장 검출 및 진단을 위한 통합 감시 제어 운영 시스템과의 데이터 인터페이스부, 정상 운전 상태 감시부, 각 설비의 고장을 총괄 감시하는 고장 검출부, 고장 발생과 동시에 고장 정보 데이터를 기초로 고장 원인을 분석 추론하여 제시하는 고장 진단부로 이루어진다. 데이터 인터페이스부는 Ethernet TCP/IP를 이용하여 통합 감시 운영 제어 시스템으로부터 운전 데이터를 네트워크를 통해서 자동으로 고장 검출 및 진단을 수행할 수 있도록 필요한 데이터를 텍스트 파일 모드로 수집한다. 공조 시스템의 성능 향상 및 운전 특성 분석을 위해서 추가로 구동기와 센서의 설치 시 각 장치에 대한 입·출력신호 특성값을 입력 파일에 추가시켜 저장할 수 있도록 파일 구조를 유연성 있게 하여 시스템 보수, 설계 변경 혹은 제어 로직 등의 변화 시 보다 쉽고 빠르게 적용할 수 있도록 구성되었다. 그리고 실시간 고장 검출 및 진단에 필요한 정보 즉, 시스템의 초기 입력 파일 샘플링 시간과 샘플링 적산 시간, 저장 방식 등을 설정 및 변경할 수 있게 하였다.




그림 6. 고장검출 및 진단시스템

### 4. 시스템 구현

공조 시스템의 감시 운영 제어는 주컴퓨터에서의

감시 제어(Supervisory control)와 현장 제어(Local loop control)에서 이루어진다. 본 논문에서는 시험 주택의 공조 시스템의 자동 제어를 위한 통합 감시 운영 제어 시스템과 고장 검출 및 진단 시스템을 독립적으로 구성하여 그림 7과 같이 구현하였다.




그림 7. 시스템 구현

통합 현장 제어기와 감시 운영 시스템의 데이터는 Ethernet TCP/IP를 사용한 데이터 인터페이스를 통해 실시간으로 데이터의 감시 및 분석이 이루어져 개별 시스템 별로 운전 데이터가 파일로 저장된다. 고장검출 및 진단 시스템은 주컴퓨터인 자동화(BAS) 서버와 네트워크로 연결하여 실시간으로 시스템의 고장검출 및 진단에 필요한 정보를 수집하여 수행된다. 현재의 감시 운영 제어 시스템을 재구성할 필요없이 고장 검출 및 진단에 필요한 정보만을 독립적으로 처리할 수 있게 하였다.

## IV. 실험 결과 및 고찰

### 1. 시스템 성능 특성

공조 시스템의 실시간 고장 검출 및 진단 시스템을 개발하기에 앞서 시스템의 모델링에 필요한 데이터와 고장 정보를 조사·분석하기 위해서 설치된 공조 시스템의 종합적인 성능 특성을 평가하였다. 제어 대상인 급기 송풍기의 급기 정압 제어, 순환 송풍기의 풍량 차 제어, 냉·난방 코일의 급기 온도 제어 및 VAV 박스의 실내 온도 제어 등에 대해서 통합 감시 운영 제어 시스템을 사용하여 시스템을 자동 운전하였다. 운영을 통해서 시스템 별 센서, 구동기의 성능을 개선하였고, 제어기 성능 특성은 지속적인 튜닝 작업을 통해서 제어기의 성능을 향상시켜 실험을 수행하였다.

공조 시스템을 실내 온도 24°C, 급기 송풍 정압

25mmAq, 급기 온도 35°C로 설정한 후 통합 감시 운영 제어 시스템을 사용하여 공조 시스템의 전체적인 성능 특성을 시험 평가하였다. 그림 8은 외기 조건과 실내 부하가 변할 때 공조 시스템의 시동부터 정지까지의 운전 특성을 보여준다. 그림에서 알 수 있듯이 시동 시를 제외한 정상 운전 기간 동안 설정값과 실제값과의 차가 미소하고, 정확하게 설정치로 제어되고 있음을 알 수 있다.

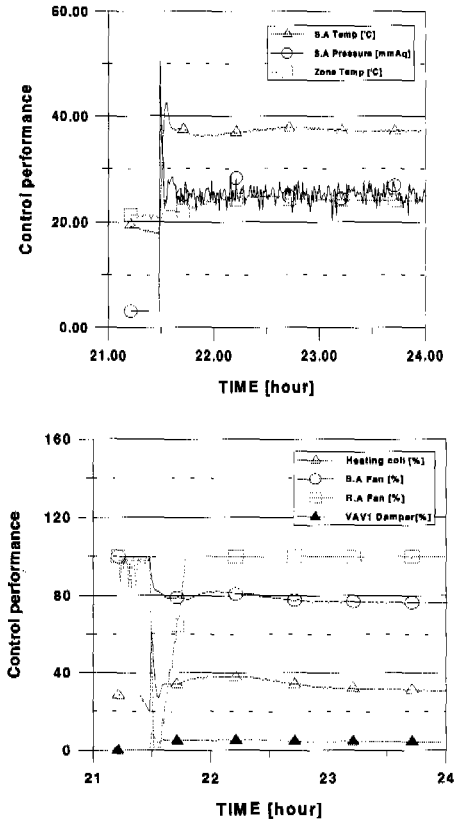


그림 8. 가변풍량 공조시스템의 제어성능

그림 9는 외기 및 실내 부하 변동에 따른 시스템의 운전 특성을 보여준다. 운전 결과로 수집된 운전 데이터는 실시간 고장 검출 및 진단 시스템을 개발하는데 중요한 기초 자료가 된다.

## 2. 고장 정보

공조 시스템에 적용되는 고장 검출 및 진단 기법을 평가하기 위해서는 시스템의 운전을 통해 고장 검출 및 진단 기법의 시험과 개선 방법을 개발하여야 한다. 수집된 시스템 별 정상 운전 및 고장 정보는 공조 시스템에 적용되는 고장 검출 및 진단 기

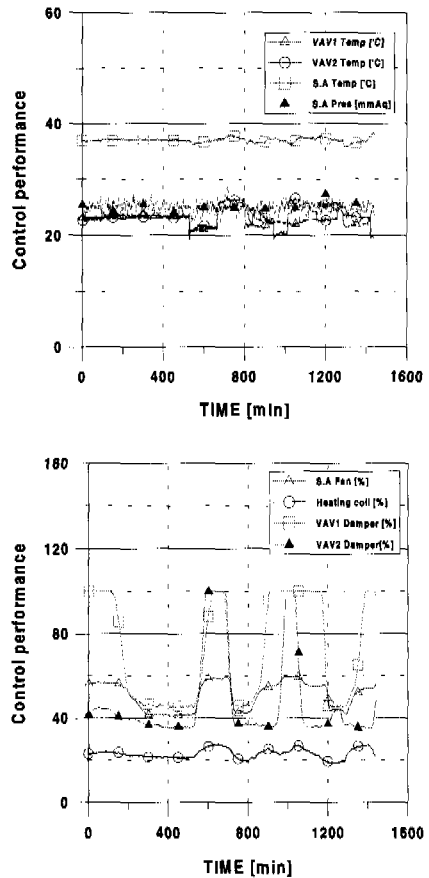


그림 9. 부하 변동에 따른 운전 특성

법을 개발할 때 중요한 사항이다. 시스템에서 발생 가능한 고장 유형은 3가지 유형으로서 자연적, 인위적, 가상 고장들이 그것이다. 가상 고장들은 가상 및 에뮬레이터 프로세스에서, 인위적, 자연적 고장들은 에뮬레이터 및 실제 프로세스에서 발생한다. 고장 검출 및 진단시스템의 개발에 있어 각 고장 유형 및 프로세스 유형이 중요하고, 시스템의 성능 저하 혹은 자연적 마모에 따라 발생한 고장들을 사용하여 시스템을 시험하여야 한다. 그러나 이 경우는 실제 특별한 경우에만 가능하다. 만약 고장 검출 및 진단 시스템을 시험하기 위해 고장을 발생시키면 전형적인 모든 고장들을 시험하기 위해서 많은 시간이 필요하다.

본 실험에서 사용된 고장 발생은 장시간의 성능 저하 혹은 자연적 마모에 따른 고장들은 고려하지 않았고, 보편적인 방법인 특정 시간 동안 시스템의 급격한 고장 모델을 만들어 이로 인해 발생하는 고장 정보들을 수집하였다. 즉, 실제 공조 시스템에서

일시적인 혹은 장시간의 송풍기, 댐퍼와 구동기, 센서 고장 등이나 출력 신호의 급격한 변화로 인한 구동기 마모, 시스템 손상 등을 막기 위해서 특정 시간 동안 정상 운전 범위를 벗어나는 부분적인 고장 신호를 적용하였다. 그림 10, 그림 11은 공조 시스템의 정상 운전 중에 특정 시간 동안의 인위적인 급격한 고장 신호를 적용하였을 경우 공조 시스템의 정상 운전 시 평균 신호와 고장 발생 시 고장 신호의 운전 특성을 비교한 결과를 보여준다.

그림 10은 급기 압력 제어용 송풍기의 출력이 정상 운전 상태에서 시스템에서 자동적으로 특정 시간 동안 급격한 고장 신호 즉, 40% 출력 감소 신호를 시스템에 적용하였을 경우 풍량, 급기 온도, 급기 정압, 제어 신호 등의 정상 운전 시 평균값과 고장 발생 시 고장 신호의 운전 특성을 비교한 결과를 보여준다.


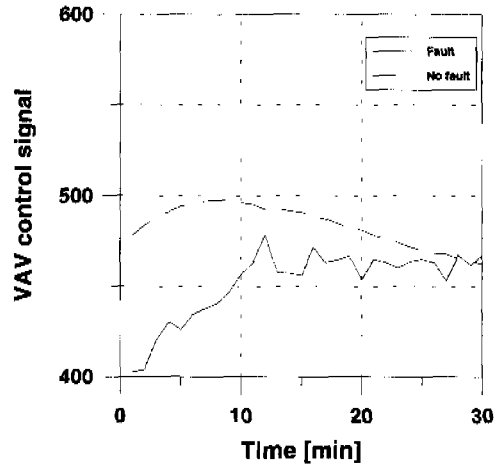




그림 10. 송풍기 고장 시 운전 특성

그림 11은 공조 설비의 제어 대상 입력인 급기 온도 센서에 특정 시간 동안 고장 신호를 적용하였을 경우 정상운전 시와 고장 발생 시의 공조 설비의 운전 특성을 보여준다. 센서들은 프로세스와 센서의 특성에 의해서 미리 성능 범위를 알 수 있으므로 센서의 측정 범위가 벗어나는 경우 고장을 쉽게 검출할 수 있다.

그림 12는 실험을 통해서 수집된 결과를 토대로 시스템 동적 모델을 설계하여 정확도를 비교·분석하였다. 급기 정압 제어용 급기 송풍기, 실내 환경 개선 및 적절한 외기의 공급을 위한 풍량차 제어용 순환 송풍기, 실내 환경 및 온도 제어용 VAV 박스의 동적 모델을 구성하여 모델의 예측값과 실제 출력값에서 발생하는 오차 범위를 비교·분석하였다.

그림에서 보듯이 모델의 예측값과 실제 출력값 사이의 오차 범위가 크게 벗어나지 않고 양호한 결과를 얻을 수 있다.

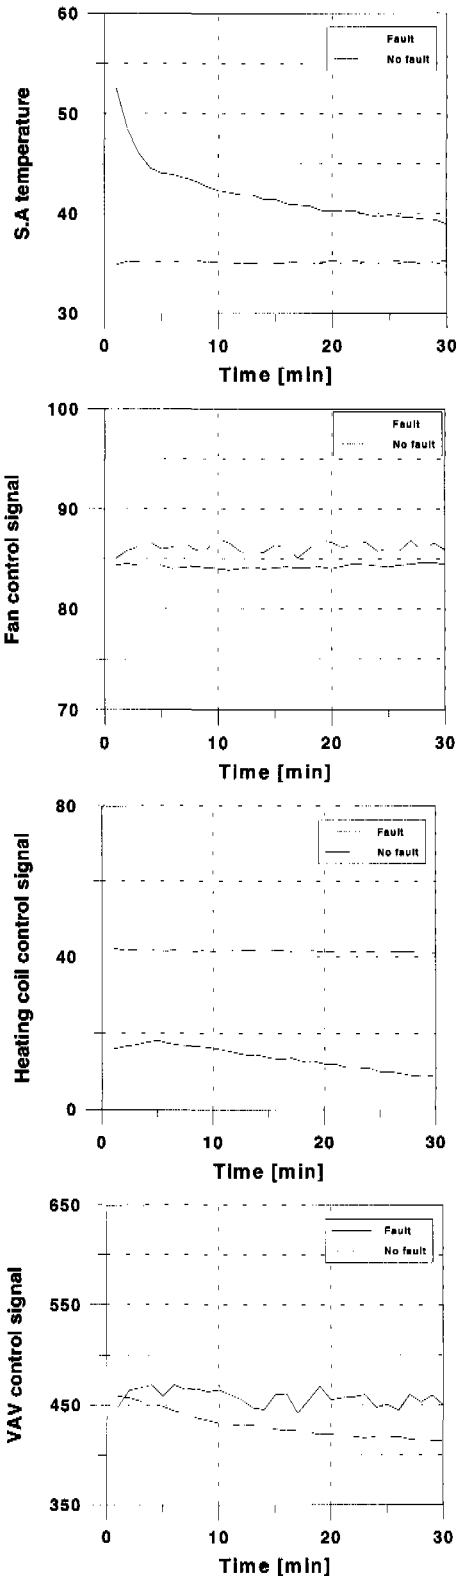


그림 11. 급기온도 센서 고장 시 운전 특성




그림 12. 시스템 모델의 정확도 비교·분석

### 3. 고장 진단

수집된 공조 시스템의 정상 운전 및 고장 데이터를 분석하여 주요 고장과 현상들의 관계를 IF-THEN 규칙을 적용한 통계적 패턴 인식 기법인 신경망을 사용하여, 이들 고장에 대한 반복적인 학습 과정을 통해 신경망을 훈련시켜 얻은 학습 결과를 공조시스템의 고장 진단에 적용하였다. 신경망의 학습을 위한 입력으로는 고장 검출 시 시스템 별 잔차 변화를 관측하여, 잔차의 변화를  $\pm 1$ 과 0으로 정규화시켰다. 신경망의 입력 패턴은  $\pm 1$ 과 0로 정규화된 탄시그모이드, 출력 패턴은 1과 0로 정규화된 로그시그모이드 활성화 함수를 사용하여 수행하였다. 신경망 학습 과정의 이상적인 입·출력 학습 패턴은 표 1과 같다( $d_{T1}$  : Zone1 Temp,  $d_{T2}$  : Zone2 Temp,  $d_T$  : S.A Temp,  $d_P$  : S.A Pressure,  $d_H$  : H/C control signal,  $d_{D1}$ ,  $d_{D2}$  : VAV box control signal,  $d_{RF}$  : Return Fan control signal,  $d_{SF}$  : Supply Fan control signal). 입력 패턴은 관측된 시스템 변수의 잔차를 이용하였으며, 출력 패턴은 실

표 1. 이상적인 신경망 입·출력 학습패턴

Input									Output									Fault			
d <sub>r1</sub>	d <sub>r2</sub>	d <sub>r</sub>	d <sub>p</sub>	d <sub>RF</sub>	d <sub>H</sub>	d <sub>SF</sub>	d <sub>D1</sub>	d <sub>D2</sub>													
0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	Steady-state
0	0	0	1	0	0	1	1	1	0	1	0	0	0	0	0	0	0	0	0	0	S.A fan
0	0	1	0	0	1	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	Heating coil valve
0	0	0	0	0	0	0	-1	0	0	0	0	1	0	0	0	0	0	0	0	0	VAV1 damper
-1	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	VAV1 temperature sensor
0	0	0	0	0	0	1	-1	0	0	0	0	0	0	1	0	0	0	0	0	0	VAV1 flow scnsor
0	-1	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	VAV2 temperature sensor
0	0	0	0	0	0	0	0	-1	0	0	0	0	0	0	1	0	0	0	0	0	VAV2 flow sensor
0	0	-1	0	0	1	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	S.A temperature sensor
0	0	0	-1	0	0	1	1	1	0	0	0	0	0	0	0	0	1	0	0	0	S.A pressure sensor
0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	R.A fan

제 발생된 고장/증상들의 관계를 이용하여 10개의 고장과 1개의 정상 상태를 구분한 11×11 행렬 구조로 처리하였다. 관측된 시스템 변수의 잔차는 학습이 완료된 신경망의 입력으로 고장 진단을 수행하기 위해서 잔차에 대한 정규화가 필요하다. 잔차의 정규화 방정식은 다음과 같이 정의하여 사용하였다.

$$d_T = \frac{T_m - T_{b,sp}}{|T_m - T_{b,sp}|_{max}} \quad (4)$$

$T_m$  : 관측치,  $T_{p,sp}$  : 설정치 혹은 예측치

공조 시스템의 고장 진단을 위한 신경망의 입·출력 패턴은 그림 5와 같이 역전파 알고리즘을 사용한 3층 구조의 전방향 신경망을 사용하여 반복적인 학습을 수행하였다. 본 논문에서는 입력층이 9, 은닉층이 8, 그리고 출력층이 11인 9×8×11의 신경망 모델을 사용하였다. 학습 방법은 반복 회수가

5000회 혹은 최소 자승 오차가 0.000001이하가 될 때까지 반복적인 학습을 수행하였다.

표 2의 정규화된 잔차를 신경망에 적용한 결과, 표 3과 같이 거의 완벽하게 주어진 고장을 진단하는 것을 알 수 있고, 실험 결과를 통해서 이상적인 훈련 패턴과 실제 패턴 사이에서 잔차의 크기가 차이가 있더라도, 가장 유사한 패턴으로 진단을 수행하는 것을 알 수 있다. 신경망을 이용하면 진단에 필요한 학습 과정은 오프라인으로 수행할 수 있으므로 학습된 결과를 이용하는 진단에는 연산 시간이 거의 필요하지 않다. 따라서 실시간 진단에 유효하게 사용될 수 있다. 본 논문에서는 신경망을 이용한 고장 진단의 적용 가능성을 보여주기 위해서 비교적 구분이 쉬운 급격한 10가지의 손상에 대해서만 고려하였지만, 신경망은 복잡한 비선형 관계도 학습시킬 수 있으므로 성능 저하와 같은 미소 고장에 대해서도 효과적으로 적용할 수 있을 것이다.

표 2. 고장진단을 위한 정규화된 잔차

	Fault	d <sub>r1</sub>	d <sub>r2</sub>	d <sub>r</sub>	d <sub>p</sub>	d <sub>RF</sub>	d <sub>H</sub>	d <sub>SF</sub>	d <sub>D1</sub>	d <sub>D2</sub>
1	Steady-state	-0.02	-0.03	-0.09	-0.16	-0.14	-0.11	-0.11	0.10	0.16
2	S.A fan	-0.02	-0.03	-0.10	0.89	-0.26	-0.11	0.98	0.76	0.95
3	Heating coil valve	0.01	-0.04	0.17	-0.18	-0.05	1.00	-0.04	-0.20	-0.15
4	VAV1 damper	0.02	0.01	-0.07	0.28	-0.06	-0.11	-0.06	-0.71	0.18
5	VAV1 temperature sensor	1.00	0.04	-0.06	-0.19	-0.06	-0.07	0.80	-1.00	0.15
6	VAV1 flow sensor	0.02	0.03	-0.06	-0.42	0.18	-0.07	-0.04	0.17	0.10
7	VAV2 temperature sensor	0.02	-1.00	-0.05	0.10	0.05	-0.06	-0.04	-0.17	1.00
8	VAV2 flow sensor	0.02	-0.02	-0.05	-0.38	-0.16	-0.06	-0.05	-0.23	0.18
9	S.A temperature sensor	0.02	-0.06	-1.00	-0.25	-0.14	0.86	1.00	-0.56	0.69
10	S.A pressure sensor	-0.03	-0.05	-0.06	-1.00	-0.07	-0.04	0.05	-0.20	-0.18
6	R.A fan	-0.03	-0.01	-0.06	-0.09	-1.00	0.11	0.05	-0.20	-0.18



표 3. 고장진단 결과

Fault	Result										
	0.98	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
Steady-state	0.98	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
S.A fan	0.00	0.99	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
Heating coil valve	0.00	0.00	0.98	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
VAV1 damper	0.00	0.00	0.00	0.99	0.00	0.00	0.00	0.00	0.00	0.00	0.00
VAV1 temp sensor	0.00	0.00	0.00	0.00	0.99	0.00	0.00	0.00	0.00	0.00	0.00
VAV1 flow sensor	0.00	0.00	0.00	0.00	0.00	0.99	0.16	0.00	0.00	0.00	0.00
VAV2 temp sensor	0.00	0.00	0.00	0.00	0.01	0.00	0.99	0.00	0.00	0.00	0.00
VAV2 flow sensor	0.00	0.00	0.00	0.00	0.00	0.01	0.00	0.99	0.00	0.00	0.00
S.A temp sensor	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.99	0.00	0.00
S.A pressure sensor	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.99	0.00
R.A fan	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.99

V. 결론

본 논문에서는 공조 시스템에서 발생하는 고장들을 검출하고 진단하기 위해서 고장과 현상들의 관계를 IF-THEN 규칙을 적용한 통계적 패턴 인식 기법인 신경망을 사용한 실시간 고장 진단 시스템을 제안하였다.

제안한 시스템을 실제 운전중인 공조 시스템에 적용한 결과, 고장 발생 시 거의 완벽하게 고장들을 검출하고 진단함으로써 제안한 진단 기법의 적용 가능성을 확인하였다. 본 논문에서는 비교적 구분이 인위적인 다소 급격한 고장에 대해서만 적용하였지만, 향후 목표는 지속적인 실험을 통해 고장 발생 시 고장 정보 데이터베이스 구축 및 각 시스템의 성능 특성을 비교·분석하여 성능 저하와 같은 미소 고장뿐만 아니라 발생 가능한 고장들을 미리 검출하고 진단한 후 사후 처리를 자동으로 수행할 수 있는 시스템을 개발하는 것이다.

참고 문헌

[1] Isermann, R., 1983, Process fault detection based on the mautomatica, Vol. 20, 387-404

[2] Hyvarinen, J., Kohonen, R.(eds.), "Building optimization and fault diagnosis system concept", 1993, Espoo: VTT, Laboratory of heating and ventilation, (IEA, Annex 25). ISBN, 952-9601-16-6


[3] Kit, C.C., Roes, Ronald, J.M.M., Doe, 1993, Shewhart-type control charts for individual observation, Journal of quality technology, Vol.25, No.3., pp188-198

[4] Pakanen, Jouko, "A demonstration system for on-line diagnostic tests", Working Paper, presented in the third Annex 34 Meeting in Boulder, Colorado 29.9-1.10, 1997.

[5] Stornetta, W. S., and Huberman, B. A., 1987, An improved three-layer backpropagation algorithm, In Proceedings of the IEEE first International Conference on Neural Network

김 문 성(Moon-seong Kim)

정회원



1993년 2월: 한남대학교

물리학과 졸업

1995년 2월: 한남대학교

컴퓨터공학과 석사

1996년 3월~현재: 전북대학교

컴퓨터공학과 박사과정

1997년 3월~현재: 대원과학대학 컴퓨터정보통신과 조교수

<주관심 분야> Image Processing, Control Performance, Computer Simulation

유 승 선(Seung-sun Yoo)

정회원



1988년 2월: 한남대학교

전자계산학과 졸업

1994년 2월: 한남대학교

전자계산공학과 석사

1997년 3월~현재: 전북대학교

영상정보공학과

박사과정

1988년 6월~2001년 5월: 한국에너지기술연구소 연구원

2001년 6월~현재: (주)비맥 기술이사

<주관심 분야> Neural Network, Image Processing

