

## 공조설비용 고장진단시스템의 실시간 진단실험

소 정 훈<sup>†</sup>, 유 승 선, 경 남 호, 신 기 석

한국에너지기술연구원

### The On-Line Diagnostic Test of Fault Diagnosis System for Air Handling Unit

J. H. So<sup>†</sup>, S. S. Yoo, N. H. Kyong, G. S. Shin

Energy Conservation Research Department, KIER, Taejon 305-343, Koera

(Received March 14, 2001; revision received May 10, 2001)

**ABSTRACT:** An experimentation on the on-line fault detection and diagnosis (FDD) system has been performed with HVAC system in the experimental building constructed inside the large scale environmental chamber. Personal computer with a home-made FDD program by pattern recognition method utilizing artificial neural network was connected on-line via Ethernet TCP/IP to the supervisory control server for HVAC system. The FDD program monitored the HVAC system by 1 minutes interval. The results showed that the FDD program detected the sudden or abrupt faults such as those in fans, sensors and heater, etc.

**Key words:** Fault detection and diagnosis(고장검출진단), Neural network(신경망), Variable air volume(가변풍량), Building automation system(건물자동화시스템)

#### 기 호 설 명

$d_T$  : 대상변수 잔차

$T_m$  : 관측치

$T_{p,sp}$  : 설정치 혹은 예측치

#### 1. 서 론

컴퓨터를 이용한 자동화 기술의 발전이 가속화 되면서 건물의 정보화에 대한 관심이 높아지고 있지만, 정보화 건물의 운전은 설비시스템이 대형화, 복잡화되면서 이에 따른 고장발생시의 경제적 손실과 위험성을 증폭시켰을 뿐만 아니라 고장발생과 발생위치 등의 신속한 원인규명이 이루어지지 못하므로 시스템의 안정성과 신뢰성 확

보가 문제점이 되고 있다. 따라서, 이러한 시스템의 안정성과 신뢰성을 확보하기 위한 고장검출 및 진단시스템의 필요성이 요구되고 있다.<sup>(2,3)</sup>

고장검출 및 진단시스템은 전체 시스템의 운전 상황을 감시하고, 고장이 발생된 시스템의 성능 저하를 미리 검출하거나 이상동작의 원인이 되는 고장과 발생위치를 신속히 검출하여 고장의 정도를 분석하여 진단함으로써 운영자에게 적절한 처리방법에 대한 정보를 제공하는 데 있다.<sup>(2,6,7)</sup>

고장검출 및 진단기술<sup>(5,6)</sup>은 항공, 발전, 화학공정 등의 안정성이 요구되는 분야에서 활발한 연구가 되고 있는 기술이지만, 최근에는 각종 산업공정과 경제성 제고를 위해서 적용이 점차 확대되고 있으며, 적용기술이 매우 다양하므로 도입 효과를 극대화하기 위해서는 대상 프로세스의 구성요소, 동특성, 수학적 모델의 유무, 측정 가능한 변수와 검출률 등의 고장진단시스템의 성능, 선정된 기법의 실현 경비 등의 매우 많은 요인들을 고려하여 적용되어야 한다.

본 논문에서는 통계적 패턴인식기법<sup>(5)</sup>을 이용

<sup>†</sup> Corresponding author

Tel.: +82-42-860-3371; fax: +82-42-860-3202

E-mail address: jhso@kier.re.kr

한 고장진단기법을 실제 운전중인 공조시스템에 적용하여 고장검출 및 진단기법의 정확성 및 적용 가능성을 평가하였다.

고장검출 및 진단에 필요한 고장정보는 고장모델을 만들어 특정시간 동안 다소 급격한 고장신호를 공조시스템에 실제 적용하여 수집된 결과를 사용하였다. 진단실험 결과, 제안한 실시간 고장진단기법의 실제 적용 가능성을 확인하였다.

## 2. 고장진단시스템

### 2.1 적용기법

고장검출 진단처리기법은 검출, 진단, 판단 및 처리의 순서로 구성되어 있다.<sup>(4,6,7)</sup> 첫 번째 단계인 고장검출은 감시되는 시스템의 실제 성능과 예측된 성능이 차이가 있을 때 고장을 지시하는 과정이다. 두 번째 과정인 진단은 고장의 원인이나 위치를 지정하는 과정이다. Fig. 1은 고장검출 및 진단적용기법의 흐름도를 보여준다. 고장검출 및 진단적용은 다음의 단계를 통해서 이루어진다.

- (1) 잔차발생(Residual Generation)
- (2) 고장검출논리
- (3) 고장진단정보(특정값)의 추출알고리즘
- (4) 고장진단논리와 추론알고리즘 및 모델검증

### 2.2 뉴럴 네트워크 모델

뉴럴 네트워크의 학습알고리즘<sup>(6)</sup>은 다층 전방향 퍼셉트론의 실제 출력과 기대되는 출력간의 오차가 최소화되도록 설계된 일종의 반복적 기울기 알고리즘으로 입력노드의 값을 합산하여, 처리노드의 출력값을 만들기 위해 임의의 활성화함수를 통해 전달되는데 주로 많이 사용하는 활성화함수는 시그모이드(Sigmoid) 함수이다. 그러나, 역전파 학습방법은 뉴럴 네트워크의 층수가 복잡할 경우 학습속도가 느리고, 학습시 초기변수의 설정이 성능에 크게 영향을 미친다. 이러한 문제점을 완화하는 방법으로 전단계의 학습에서 계산된 가중치 수정량과 현재 수정량의 무계중심으로 정하는 방법과, 학습매개변수를 동적으로 적용시키는 매개변수방법을 사용하면 성능과 학습속도를 향상시킬 수 있다.

Fig. 2는 3층 구조의 전방향 뉴럴 네트워크 모

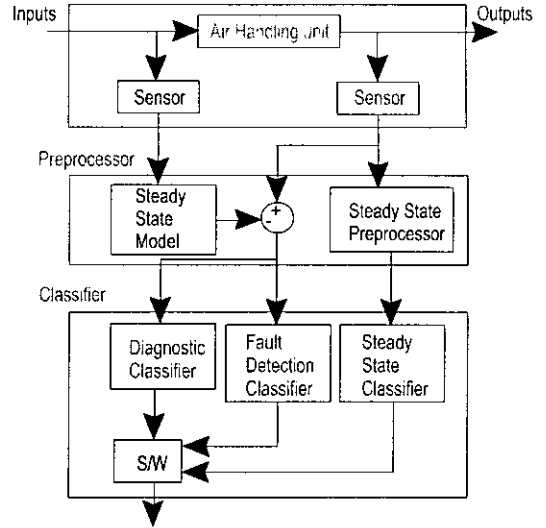


Fig. 1 The overview of fault detection and diagnosis technique.




Fig. 2 Three layer feedforward neural network.

델의 구성을 보여준다.

## 3. 실험장치

### 3.1 초에너지절약형 건물

공조설비의 실시간 진단실험<sup>(3,8)</sup>을 위한 적용대상건물인 초에너지절약형 건물은 컴퓨터를 사용한 중앙감시 운영제어시스템과 열원기기의 집약화 및 설비시스템을 단순화시켜 쾌적한 실내환경 및 설비시스템의 효율적인 유지관리를 함으로써 설비기능의 정확성 및 유연성 확보, 그리고 건물의 안정성 등의 기술들이 사용된 건물이다.

Fig. 3은 초에너지절약형 건물을 보여준다. 건물의 규모는 지상 3층, 지하 1층으로 구분되며 전체면적은 1,094 m<sup>2</sup>이고, 공조면적은 697 m<sup>2</sup>이다.




Fig. 3 Super low energy conservation building.

3.2 시스템 구성

Fig. 4는 실시간 고장진단시스템의 적용대상 건물인 초에너지절약형 건물의 가변풍량(VAV) 공조시스템의 구성을 보여준다. 설치된 공조시스템은 외기 및 실내의 온습도 조건에 따라서 냉, 난방을 1개의 공조기로 가능하게 설계되었다. 급기송풍기의 정압제어와 순환송풍기제어를 위해서 가변속(VVVF)제어가 가능하도록 하여 경제성 및 에너지 절약평가를 수행할 수 있고, 에너지절약 효과와 건물의 내부부하변동에 따른 각 실내로 공급되는 공기량을 제어하기 위해서 VAV(Variable Air Volume) 박스를 설치하였다. 적용건물

의 모든 설비에 대한 운전 및 자료수집은 자동 제어시스템에서 수행된다.

3.3 고장진단시스템

본 논문에서는 공조시스템의 운전을 통해서 수집된 고장정보와 패턴인식기법을 사용한 진단알고리즘을 고장진단시스템으로 구현하였다. 시스템은 통합감시 제어시스템과 고장진단시스템을 독립적으로 구성하여 Ethernet TCP/IP에 의한 시스템간의 데이터 인터페이스를 통해서 실시간 고장진단에 필요한 정보를 서로 공유할 수 있도록 하였다.

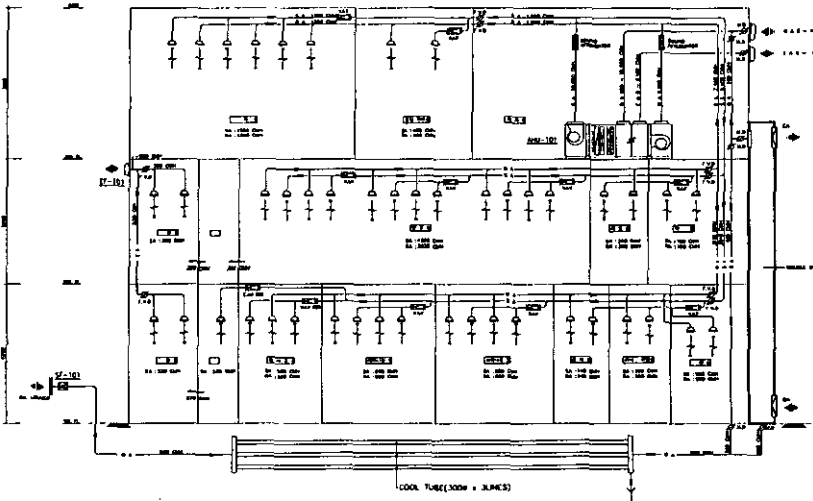


Fig. 4 Schematic diagram of VAV AHU system.

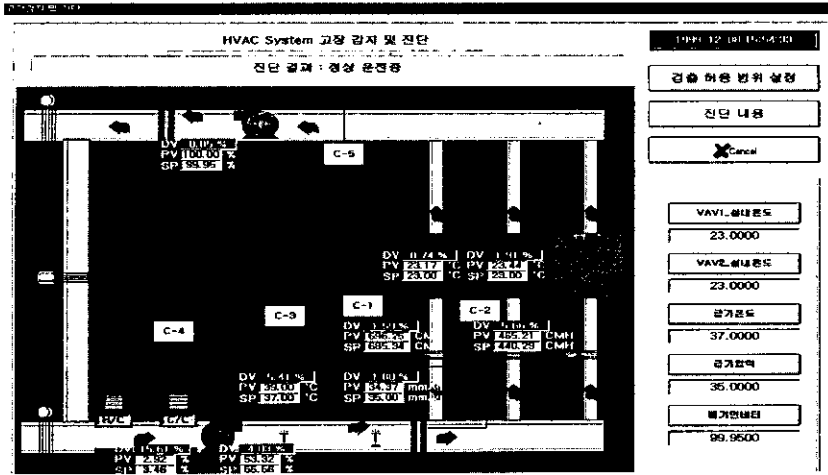


Fig. 5 Fault detection and diagnosis system.

Fig. 5는 실시간 고장진단시스템을 보여준다. 고장진단시스템은 고장검출진단을 위한 통합감시 제어시스템과의 데이터 인터페이스부, 정상운전 상태감시부, 각 설비의 고장을 통괄 감시하는 고장검출부, 고장발생과 동시에 고장정보데이터를 기초로 고장원인을 분석 추론하여 제시하는 고장 진단부로 구성되어 있다.

3.4 시스템 구현

공조시스템의 감시운영제어는 주컴퓨터에서의 감시제어(Supervisory control)와 현장제어(Local loop control)가 Ethernet TCP/IP를 통해서 이루어진다. 본 논문에서는 시험주택의 공조시스템의 자동제어를 위한 통합감시 제어시스템과 고장진

단시스템을 네트워크로 독립적으로 연결하여 실시간으로 고장검출 및 진단에 필요한 정보를 수집, 분석하여 진단을 수행한다. Fig. 6은 통합감시 제어시스템과 고장진단시스템의 실제 구성을 보여준다.

4. 실험결과 및 고찰

4.1 고장정보

고장검출 및 진단기법을 공조시스템에 적용하기 위해서는 시스템의 실제 운영을 통해 고장검출 및 진단기법의 시험과 개선방법을 개발하여야 한다. 수집된 시스템별 정상운전 및 고장정보는 고장검출 진단기법을 개발할 때 중요한 사항이다. 시스템에서 발생 가능한 고장유형은 3가지 유형 즉 자연적, 인위적, 가상 고장들이다. 가상 고장들은 가상 및 에뮬레이터 프로세스에서, 인위적, 자연적 고장들은 에뮬레이터 및 실제 프로세스에서 발생한다. 고장진단시스템의 개발에 있어 각 고장유형 및 프로세스 유형이 중요하고, 시스템의 성능저하 혹은 자연적 마모에 따라 발생한 고장들을 사용하여 시스템을 시험하여야 한다. 그러나 이 경우는 실제 특별한 경우에만 가능하다. 만약 고장진단시스템을 시험하기 위해 고장을 발생시키면 전형적인 모든 고장들을 시험하기 위해서는 많은 시간이 필요하다.

본 실험에서 사용된 고장발생은 장시간의 성능저하 혹은 자연적 마모에 따른 고장들은 고려하

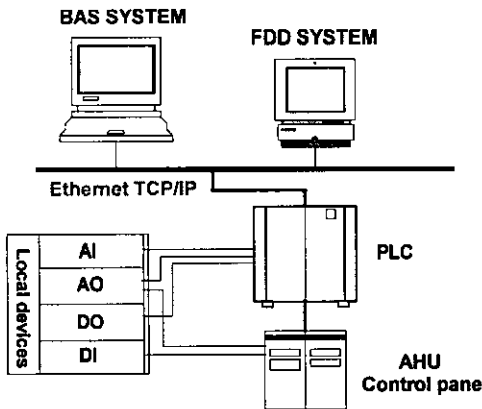


Fig. 6 System realization.

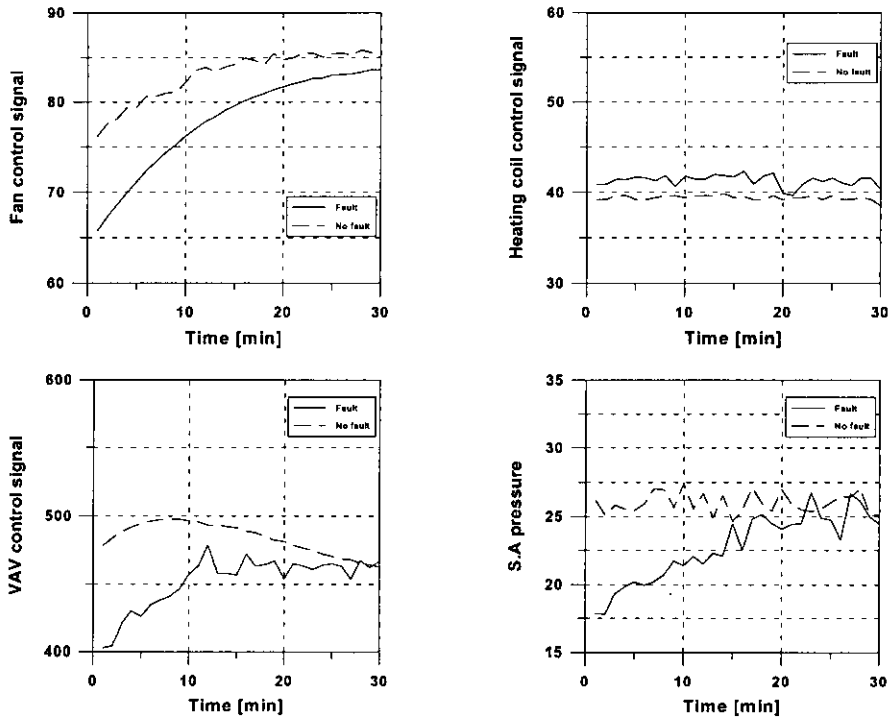


Fig. 7 Operation characteristics at supply fan fault.

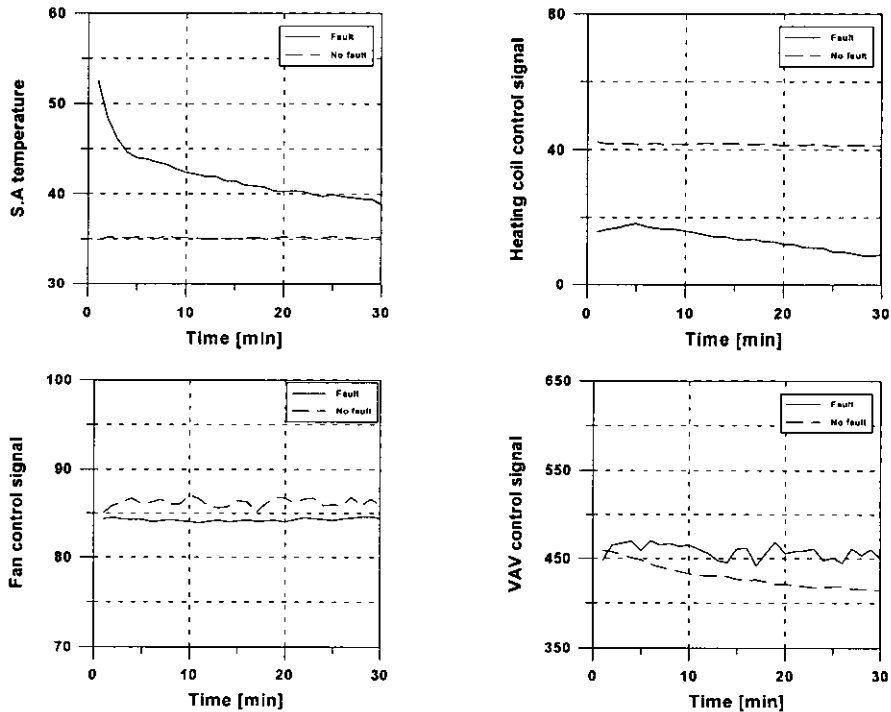


Fig. 8 Operation characteristics of AHU at supply air sensor fault.

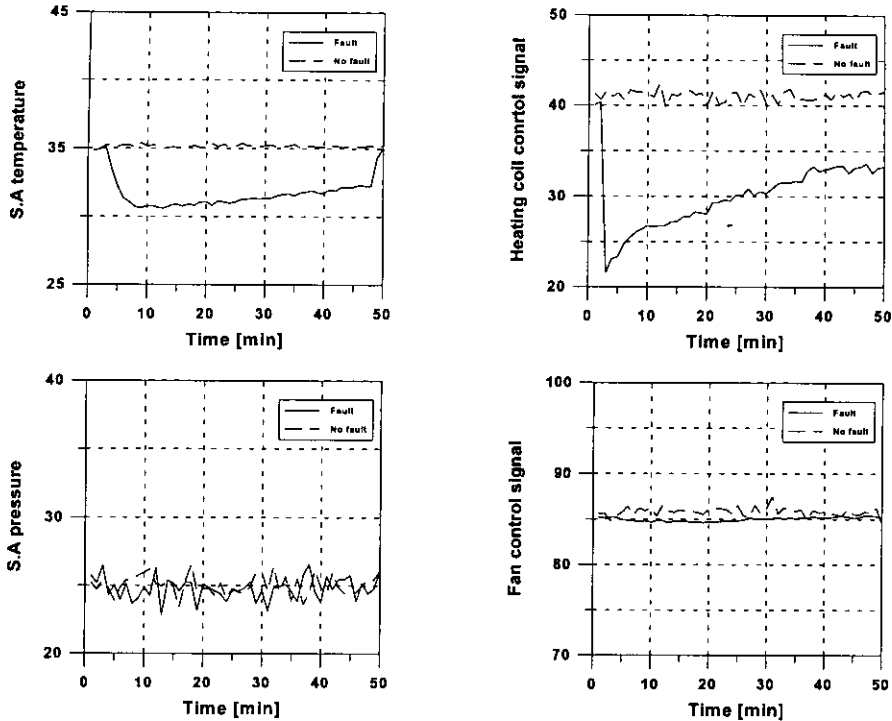


Fig. 9 Operation characteristics at heating coil fault.

지 않았고, 보편적인 방법인 특정시간 동안 시스템의 급격한 고장모델을 만들어 이로 인해 발생하는 고장정보들을 수집하였다. 즉, 실제 공조시스템에서 일시적인 혹은 장시간의 송풍기, 담퍼와 구동기, 센서고장 등이나, 출력신호의 급격한 변화로 인한 구동기 마모, 시스템 손상 등을 막기 위해서 특정시간 동안 정상운전범위를 벗어나는 부분적인 고장신호를 적용하였다.

Fig. 7, Fig. 8, Fig. 9는 공조시스템의 정상운전에서 특정시간 동안의 인위적인 급격한 고장신호를 적용하였을 경우 공조시스템의 정상운전시 평균신호와 고장발생시 고장신호의 운전 특성을 비교한 결과를 보여준다.

Fig. 7은 정압제어용 급기송풍기의 출력이 정상운전에서 시스템에서 자동으로 특정시간 동안 급격한 고장신호, 즉 40% 출력감소신호를 시스템에 적용하였을 경우, 풍량, 급기온도, 급기정압, 제어 신호 등의 정상운전시 평균값과 고장발생시 고장신호의 운전 특성을 비교한 결과를 보여준다.

Fig. 8은 급기온도센서에 특정시간 동안 고장신호를 적용하였을 경우 정상운전시와 고장발생시의 공조설비의 운전 특성을 보여준다. 센서들

은 프로세스와 센서의 특성에 의해서 미리 성능범위를 알 수 있으므로 센서의 측정범위가 벗어나는 경우 고장을 쉽게 검출할 수 있다.

Fig. 9는 정상운전에서 난방코일에 특정시간 동안 고장신호를 적용하였을 경우 정상운전시와 고장발생시의 시스템의 운전 특성을 보여준다.

그림에서 보듯이 실험을 통한 각각의 구성장치에 대한 고장시험을 통해서 고장발생시 각 구성장치의 운전 특성이 다르다는 것을 알 수 있다. 즉, 고장발생시 운전데이터를 이용하면 시스템에서 발생하는 여러 고장들을 검출하고 진단할 수 있다는 것을 보여주고 있다.

#### 4.2 고장진단

수집된 공조시스템의 정상운전 및 고장데이터를 분석하여 주요 고장과 현상들의 관계를 IF-THEN 규칙을 적용한 통계적 패턴인식 기법<sup>(3,9)</sup>인 뉴럴 네트워크를 사용하여, 이들 고장에 대한 반복적인 학습과정을 통해 뉴럴 네트워크를 훈련시켜 얻은 학습 결과를 공조시스템의 고장진단에 적용하였다. 고장을 검출하기 위해서 대상변수의

Table 1 Idealized training patterns of neural network

Input										Output										Fault	
$d_{T1}$	$d_{T2}$	$d_T$	$d_P$	$d_{RF}$	$d_H$	$d_{SF}$	$d_{D1}$	$d_{D2}$													
0	0	0	0	0	0	0	0	0	0	1	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	0	0	1	0	0	0	0	0	0	VAV1 damper
-1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	VAV1 temperature sensor
0	0	0	0	0	0	1	-1	0	0	0	0	0	0	0	0	1	0	0	0	0	VAV1 flow sensor
0	-1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	VAV2 temperature sensor
0	0	0	0	0	0	0	0	-1	0	0	0	0	0	0	0	0	1	0	0	0	VAV2 flow sensor
0	0	-1	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	S.A temperature sensor
0	0	0	-1	0	0	1	1	1	0	0	0	0	0	0	0	0	0	0	1	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

$d_{T1}$  : zone1 Temp.,  $d_{T2}$  : zone2 Temp.,  $d_T$  : S.A Temp.,  $d_P$  : S.A Pressure,  
 $d_{RF}$  : Return fan control signal,  $d_H$  : H/C control signal,  $d_{SF}$  : Supply fan control signal,  
 $d_{D1}$ ,  $d_{D2}$  : VAV box control signal

잔차와 표준편차를 이용한 허용값 검사<sup>(1)</sup>를 사용하였다. 잔차는 아래와 같은 방정식으로 정의하여 사용하였다.

$$d_T = T_m - T_{p,sp} \quad (1)$$

여기서,  $T_m$  은 관측치,  $T_{p,sp}$  은 설정치 혹은 예측치를 나타낸다.

뉴럴 네트워크의 학습을 위한 입력으로는 고장 검출시 대상변수의 잔차변화를 관측하고, 시그모이드 활성화함수를 사용하였다. 뉴럴 네트워크 학습과정의 이상적인 입출력 학습패턴은 Table 1과 같다. 입력패턴은 시스템 대상변수의 잔차를 이

용하였으며, 출력패턴은 실제 발생된 고장/증상들의 관계를 이용하여 10개의 고장과 1개의 정상상태를 구분한 11×11 행렬구조로 처리하였다. 시스템 대상변수의 잔차가 학습이 완료된 뉴럴 네트워크의 입력으로 고장진단을 수행하기 위해서는 잔차에 대한 정규화가 필요하다. 잔차의 정규화 방정식은 다음과 같이 정의하여 사용하였다.

$$d_T = \frac{T_m - T_{p,sp}}{|T_m - T_{p,sp}|_{max}} \quad (2)$$

공조시스템의 고장진단을 위한 뉴럴 네트워크의 입출력 패턴은 Fig. 2와 같이 역전파 알고리

Table 2 Normalized residuals for fault diagnosis

	Fault	$d_{T1}$	$d_{T2}$	$d_T$	$d_P$	$d_{RF}$	$d_H$	$d_{SF}$	$d_{D1}$	$d_{D2}$
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	-0.06	-0.20	0.12
6	VAV1 flow sensor	0.02	0.03	-0.06	-0.42	0.18	-0.07	0.80	-1.00	0.15
7	VAV2 temperature sensor	0.02	-1.00	-0.05	0.10	0.05	-0.06	-0.04	0.17	0.10
8	VAV2 flow sensor	0.02	-0.02	-0.05	-0.38	-0.16	-0.06	-0.04	-0.17	1.00
9	S.A temperature sensor	0.02	-0.06	-1.00	-0.25	-0.14	0.86	-0.05	-0.23	-0.18
10	S.A pressure sensor	-0.03	-0.05	-0.06	-1.00	-0.07	-0.04	1.00	-0.56	0.69
6	R.A fan	-0.03	-0.01	-0.06	-0.09	-1.00	0.11	-0.05	-0.20	-0.18

Table 3 Fault diagnosis results

Fault	Result										
	0.99	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
Steady-state	0.99	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	0.99	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 temperature 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 temperature 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 temperature 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

즘을 사용한 3층 구조의 전방향 뉴럴 네트워크를 사용하여 반복적인 학습을 수행하였다. 본 논문에서는 입력층이 9, 은닉층이 8, 그리고 출력층이 11인  $9 \times 8 \times 11$ 의 뉴럴 네트워크 모델을 사용하였다. 학습방법은 반복회수가 5,000회, 혹은 최소자승오차가  $10^{-6}$  이하가 될 때까지 반복적인 학습을 수행하였다.

Table 2의 정규화된 잔차를 뉴럴 네트워크에 적용한 결과, Table 3과 같이 거의 완벽하게 주어진 고장을 진단하는 것을 알 수 있고, 실험결과를 통해서 이상적인 훈련패턴과 실제패턴 사이에서 잔차의 크기가 차이가 있더라도, 가장 유사한 패턴으로 진단을 수행하는 것을 알 수 있다. 뉴럴 네트워크를 이용하면 진단에 필요한 학습과정은 오프라인(off line)으로 수행할 수 있으므로 학습된 결과를 이용하는 진단에는 연산시간이 거의 필요하지 않다. 따라서, 실시간 진단에 유효하게 사용될 수 있다. 본 논문에서는 뉴럴 네트워크를 이용한 고장진단의 적용 가능성을 보여주기 위해서 비교적 구분이 쉬운 급격한 10가지의 손상에 대해서만 고려하였지만, 뉴럴 네트워크는 복잡한 비선형 관계도 학습시킬 수 있으므로, 성능저하와 같은 미소 고장에 대해서도 효과적으로 적용할 수 있을 것이다.

## 5. 결론 및 향후 연구

본 논문에서는 공조시스템에서 발생하는 고장들을 검출하고 진단하기 위해서 고장과 현상들의 관계를 IF-THEN 규칙을 적용한 통계적 패턴 인

식기법인 뉴럴 네트워크를 사용한 실시간 고장진단시스템을 제안하였다.

제안한 시스템을 실제 운전중인 공조시스템에 적용한 결과, 고장발생시 거의 완벽하게 고장들을 검출하고 진단함으로써 제안한 진단기법의 적용 가능성을 확인하였다. 본 논문에서는 비교적 구분하기 쉬운 인위적인 급격한 고장에 대해서만 적용하였지만, 향후에는 계속적인 실험을 통해 고장발생에 따른 고장정보의 데이터베이스 구축 및 각 시스템의 성능특성을 비교 분석하여 성능저하와 같은 미소 고장뿐만 아니라 발생 가능한 고장들을 자동으로 미리 검출하고 진단할 수 있는 시스템을 개발하고자 한다.

## 참고문헌

1. Kit, C. C. Roes. and Ronald, J. M. M. Does., 1993, Shewhart-type control charts for individual observation, Journal of quality technology, Vol. 25, No. 3, pp. 188-198.
2. Lee, W. Y., Park, C. and Kelly, G. E., 1996, Fault detection of an air-handling unit using residual and recursive parameter identification methods, ASHRAE Transactions, Vol. 102, pp. 528-539.
3. Seem, J. E., House, J. E. and Monroe, R. H., 1997, On-line monitoring and fault detection of control system performance, Proceedings of CLIMA 2000 Conference.
4. Isermann, R., 1983, Process fault detection



- based on the modeling and estimation methods—a survey, *Automatica*, Vol. 20, pp. 387-404.
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*.
  6. Rossi, T. and Braun, J., 1993, Classification of fault detection and diagnostic methods, Preparation phase report: IE.
  7. Hyvarinen, J. and Kohonen, R., 1993, Building optimization and fault diagnosis system concept, Espoo: VTT, Laboratory of heating and ventilation (IEA, Annex 25), ISBN, 952-9601-16.
  8. Pakanen, J., 1997, A demonstration system for on-line diagnostic tests, Working Paper, presented in the third Annex 34 Meeting in Boulder, Colorado.
  9. Breuker, M. and Braun, J., 1997, Demonstration & evaluation of a statistical rule-based FDD method, Working Paper, presented in the third Annex 34 Meeting in Boulder, Colorado.