

# 잔차입력 RBF 신경망을 사용한 냉방기 고장검출 알고리즘

한 도 영<sup>†</sup>, 류 병 진<sup>\*</sup>

국민대학교 기계·자동차공학부, \*국민대학교 기계공학과 대학원

## The Fault Detection of an Air-Conditioning System by Using a Residual Input RBF Neural Network

Doyoung Han<sup>†</sup>, Byoungjin Ryoo<sup>\*</sup>

Department of Mechanical and Automotive Engineering, Kookmin University, Seoul 000-000, Korea

<sup>\*</sup>Graduate School of Mechanical Engineering, Kookmin University, Seoul 000-000, Korea

(Received January 6, 2005; revision received June 23, 2005)

**ABSTRACT:** Two different types of algorithms were developed and applied to detect the partial faults of a multi-type air conditioning system. Partial faults include the compressor valve leakage, the refrigerant pipe partial blockage, the condenser fouling, and the evaporator fouling. The first algorithm was developed by using mathematical models and parity relations, and the second algorithm was developed by using mathematical models and a RBF neural network. Test results showed that the second algorithm was better than the first algorithm in detecting various partial faults of the system. Therefore, the algorithm developed by using mathematical models and a RBF neural network may be used for the detection of partial faults of an air-conditioning system.

**Key words:** Mathematical models(수학적 모델), Parity relations(기우관계), RBF(Radial Basis Function) Neural network(RBF 신경망), Compressor valve leakage(압축기 밸브누설), Refrigerant pipe partial blockage(냉매배관 부분막힘), Condenser fouling(응축기오염), Evaporator fouling(증발기오염)

### 기 호 설 명

$h$  : RBF 활성화함수

$P_h$  : 압축기 출구압력 [kgf/cm<sup>2</sup>]

$P_l$  : 압축기 입구압력 [kgf/cm<sup>2</sup>]

$R$  : 잔차

$T_{con}$  : 응축온도 [°C]

$T_{evain}$  : 증발기 입구온도 [°C]

$T_h$  : 압축기 출구온도 [°C]

$T_{in}$  : 실내온도 [°C]

$T_l$  : 압축기 입구온도 [°C]

$T_{out}$  : 실외온도 [°C]

$w$  : 신경망 연결강도

### 1. 서 론

냉방기의 지속적인 보급으로 인해 국가 전력소비에서 냉방기가 차지하는 비중이 해마다 더욱 확대되고 있으며 이로 인해 냉방기의 불필요한 에너지 소모를 줄일 수 있는 기술에 대하여 많은

<sup>†</sup> Corresponding author

Tel.: +82-2-910-4675; fax: +82-2-910-4839

E-mail address: dyhan@kookmin.ac.kr

연구가 진행되고 있다. 그중 냉방기의 부분고장 상태에서의 운영은 불필요한 전력소모의 주요 원인이 될 뿐만 아니라 냉방기 수명 감소에도 큰 영향을 미치므로 냉방기의 고장을 사전에 방지하고 처리할 수 있는 고장검출 및 진단방법에 대한 연구가 필요하다.<sup>(1)</sup>

국의 냉동 분야에서의 고장검출 및 진단에 관한 연구는 Braun et al.<sup>(1,2)</sup>이 패키지 에어컨에 관한 고장별 비용조사를 통해 고장검출의 필요성과 고장에 따른 시스템 파라미터의 변화경향을 연구하였으며 Riemer et al.<sup>(3)</sup>은 냉동기를 대상으로 시간 급수방법을 적용한 고장검출시스템에 대한 연구를 수행하였다. 공조 분야에서의 고장검출 및 진단에 관한 연구는 Peitsman et al.<sup>(4,5)</sup>이 ARX와 인공신경망을 사용한 블랙박스 모델을 사용하여 공조시스템에서 발생 가능한 고장에 대한 검출을 시도하였으며 McIntosh et al.<sup>(6)</sup>은 수학적 모델을 이용하여 고장검출 및 진단방법에 대하여 연구를 수행하였다. 인공신경망을 사용한 고장검출 및 진단에 관한 연구에 있어 Frank<sup>(7)</sup>는 자기 학습과 패턴 분류 능력을 가지고 있는 인공신경망을 고장검출 및 진단에 사용 가능하다고 주장하였으며 Ch'ng et al.<sup>(8)</sup>은 신경망 이론을 이용하여 전자제품 생산라인에서 제품의 고장을 분류하는 연구를 수행하는 등 연구가 활발히 진행되고 있다. 국내

에서 Han et al.이 냉동 분야<sup>(9,10)</sup>와 공조 분야<sup>(11,12)</sup>를 대상으로 관심을 갖고 지속적으로 연구를 진행하고 있으나 국외에 비해 상대적으로 많은 연구가 필요한 실정이다.

본 논문에서는 5RT 용량의 멀티형 냉방기에서 발생할 수 있는 다양한 고장 중 압축기 밸브 누설, 냉매배관 부분막힘, 응축기오염, 증발기오염에 대한 부분고장을 검출할 수 있도록 기우관계를 사용한 고장검출 알고리즘<sup>(13)</sup>과 RBF 신경망을 사용한 고장검출 알고리즘<sup>(14)</sup>을 개발한 후, 고장모사 실험장치를 사용한 성능실험을 수행하여 고장검출 정확도를 확인하는 것을 목적으로 한다.

## 2. 고장모사장치

고장검출 알고리즘의 성능을 확인하기 위하여 R407C를 냉매로 사용한 5RT 용량의 멀티형 냉방기를 수정하여 고장모사장치로 사용하였다. 고장모사장치는 Fig.1과 같이 압축기, 응축기, 응축기팬, 유분리기, 액분리기, 수액기로 구성된 한 대의 실외기와 전자팽창밸브, 증발기, 증발기팬으로 구성된 네 대의 실내기로 구성되어 있으며 구체적인 사양은 Table 1에 나타내었다. 압축기 밸브 누설, 냉매배관 부분막힘, 응축기오염, 증발기

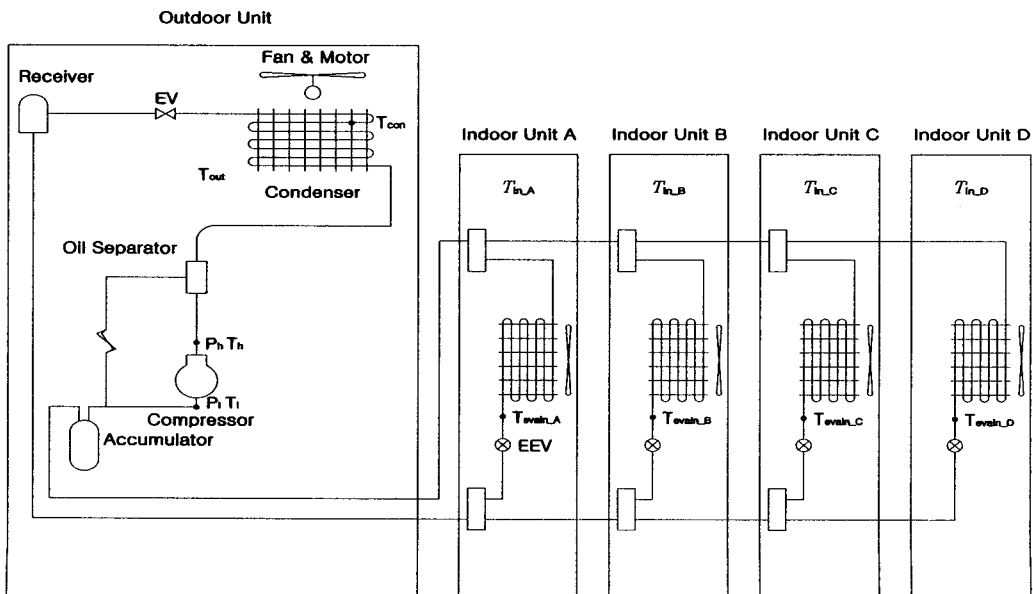


Fig. 1 Fault simulation facility.

Table 1 Specification of a multi-type system

Component		Specification
Outdoor unit	Compressor	Scroll type, 15.2 kW
	Fan	Axial fan, 60 m <sup>3</sup> /min
	Coil	φ9.52×2 row×34 step
	EV	1~2 phase, 5000 pulse
Indoor units	Fan	A, C, D Turbo fan, 9 m <sup>3</sup> /min
		B Turbo fan, 6 m <sup>3</sup> /min
	Coil	φ6.4×2 row×14 step
	EEV	1~2 phase, 480 pulse

오염에 대한 부분고장을 모사하기 위하여, 압축기 밸브누설 고장의 경우 인버터용 압축기를 사용하여 인버터출력에 따라 압축률을 단계적으로 낮추어 토출냉매량을 조절함으로써 부분고장을 모사하였고, 냉매배관 부분막힘 고장의 경우 응축기 이후의 액냉매 배관에 스테핑 모터로 구동되는 전자밸브를 설치하여 냉매의 유동을 단계적으로 차단함으로써 부분고장을 모사하였으며, 응축기오염 고장과 증발기오염 고장의 경우 실외기와 실내기의 전체 열교환 면적을 일정 비율 차단하여 부분고장을 모사하였다.

고장모사장치는 실외 온습도조건을 -5~40℃

±1.0℃, 20~90%±2.0%로, 실내 온습도조건을 15~40℃±1.0℃, 20~90%±2.0%로 제어할 수 있는 한 대의 실외 환경조성챔버와 네 대의 실내 환경조성챔버에 설치하여 사용하였으며 고장모사장치와 환경조성챔버의 각종 데이터를 수집하고 제어하기 위하여 Fig.2와 같은 데이터 수집 및 제어 시스템을 사용하였다. PC #1을 통하여 고장모사장치의 온도, 습도 등의 각종 계측 데이터를 수집하였으며 환경조성챔버의 온도, 습도 등을 측정하여 제어를 수행하였다. PC #2를 통하여 고장모사장치의 온도, 압력, 전력, 냉매유량 등 각종 데이터를 측정하여 고장모사장치의 전자팽창밸브, 압축기, 고장모사용 전자밸브, 실외팬, 실내팬 등을 제어하였다. 온도측정을 위해 T형 열전대를, 압력측정을 위해 4~20 mA 출력의 압력 변환기를 사용하였다.

### 3. 고장검출 알고리즘

압축기 밸브누설, 냉매배관 부분막힘, 응축기오염, 증발기오염에 대한 부분고장을 검출하기 위하여 압축기 입구와 출구의 온도  $T_l$ ,  $T_h$ , 응축온도  $T_{con}$ , 증발기 입구온도  $T_{evain}$ , 압축기 입구와 출구의 압력  $P_l$ ,  $P_h$ 를 고장검출 파라미터로 선정하였다. 고장검출방법으로 기우관계를 사용한 검출방법과 RBF 신경망을 사용한 검출방법을 고려하였다.

#### 3.1 수학적 모델과 잔차

무고장 상태에서의 실외온도와 실내온도에 따른 고장검출 파라미터의 예측값을 얻기 위하여 실외온도 32℃에서 38℃ 사이와 실내온도 25℃에서 31℃ 사이로 유지하면서 정상상태 실험을 실시한 후 실험결과를 토대로 구축한 데이터베이스를 이용하여 수학적 모델을 개발하였다. 개발된 수학적 모델이 Table 2에 제시되어 있으며 수학적 모델로부터 예측된 값과 실험값과의 절대오차의 평균값은  $T_h$ 의 경우 0.12℃,  $T_l$ 의 경우 0.09℃,  $T_{con}$ 의 경우 0.05℃,  $T_{evain}$ 의 경우 0.03℃,  $P_h$ 의 경우 0.02 kg/cm<sup>2</sup>,  $P_l$ 의 경우 0.03 kg/cm<sup>2</sup>이었다.

센서를 통해 실제 시스템에서 측정된 값과 수학적 모델을 통해 예측된 값의 차를 식(1)에서 식(6)과 같이 잔차로 정의하였으며 여기서  $R$ 은 잔차,  $T$ 는 온도,  $P$ 는 압력을 의미하며 첨자  $r$ 은

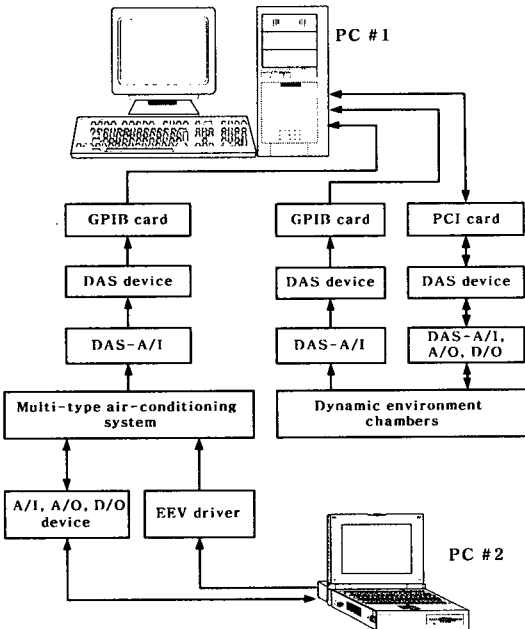


Fig. 2 Data acquisition and control system.

Table 2 Mathematical models for no fault

$y$	$T_h$ (°C)	$T_l$ (°C)	$T_{con}$ (°C)	$T_{evain}$ (°C)	$P_h$ (kgf/cm <sup>2</sup> )	$P_l$ (kgf/cm <sup>2</sup> )
A1	-57.2404	-69.5031	-59.5930	-14.8549	-4.8710	-13.0417
A2	6.1598	3.3894	4.4404	0.6922	0.7609	0.8192
A3	1.4884	1.8246	1.2835	-0.1240	0.0026	0.1306
A4	-0.0686	-0.0382	-0.0539	-0.0099	-0.0041	-0.0098
A5	-0.0061	-0.0167	-0.0102	0.0020	0	-0.0001
A6	-0.1763	-0.0160	-0.0074	0.0141	0.0009	-0.0025

$$y = A1 + A2 \times X1 + A3 \times X2 + A4 \times X1^2 + A5 \times X2^2 + A6 \times X1 \times X2$$

(X1 : Outdoor temp., X2 : Indoor temp., y : Output)

센서를 통해 측정된 값,  $ev$ 는 수학적 모델을 통해 구한 예측값을 의미한다.

$$R_{T_h} = T_{h,r} - T_{h,ev} \quad (1)$$

$$R_{T_l} = T_{l,r} - T_{l,ev} \quad (2)$$

$$R_{T_{con}} = T_{con,r} - T_{con,ev} \quad (3)$$

$$R_{T_{evain}} = T_{evain,r} - T_{evain,ev} \quad (4)$$

$$R_{P_h} = P_{h,r} - P_{h,ev} \quad (5)$$

$$R_{P_l} = P_{l,r} - P_{l,ev} \quad (6)$$

### 3.2 기우관계를 사용한 고장검출

Fig. 3에서 보듯이 기우관계를 사용하여 고장을 검출하기 위하여 먼저 잔차를 계산하였으며 계산된 잔차가 Table 3과 같이 실외조건 35°C, 41%, 실내조건 27°C, 50%인 냉방표준조건에서 실험을 통해 선정된 무고장잔차범위 안에 있으면 '0', 무고장잔차범위의 최대한계값보다 클 경우 '+1', 무고장잔차범위의 최소한계값보다 작을 경우 '-1'로 기우관계를 변화시킨 후 Table 4와 같이 각 고장에 대해 제시된 기준기우관계와 비교하여 각




Fig. 3 Fault detection algorithm by using mathematical models and parity relations.

Table 3 Residual boundaries for no-fault (Outdoor 35°C, Indoor 27°C)

	$R_{T_h}$ (°C)	$R_{T_l}$ (°C)	$R_{T_{con}}$ (°C)	$R_{T_{evain}}$ (°C)	$R_{P_h}$ (kgf/cm <sup>2</sup> )	$R_{P_l}$ (kgf/cm <sup>2</sup> )
Upper	0.23	0.19	0.42	0.09	0.15	-0.03
Lower	-0.64	-0.31	-0.23	-0.24	-0.2	-0.16

Table 4 Parity relations on various faults

Fault	Variable					
	$T_h$	$T_l$	$T_{con}$	$T_{evain}$	$P_h$	$P_l$
No fault	0	0	0	0	0	0
Compressor valve leakage	-1	-1	-1	+1	-1	+1
Refrigerant pipe blockage	+1	0	0	-1	-1	-1
Condenser fouling	+1	-1	+1	+1	+1	+1
Evaporator blockage	-1	-1	0	0	0	0




Fig. 4 Fault detection algorithm by using mathematical models and a RBF neural network.




Fig. 5 Generalized RBF network.

중 고장종류를 검출하고 제시된 기준기우관계와 다른 경우에는 알 수 없는 고장으로 분류하였다.

성함수는 식(7)에 의해 결정된다.

3.3 RBF 신경망을 사용한 고장검출

$$f_k(X_i) = \sum_{j=1}^m w_{kj} h_j(X_i) \tag{7}$$

RBF 신경망을 사용하여 고장을 검출하기 위하여 Fig.4와 같이 잔차를 입력으로 하는 RBF 신경망을 사용해 고장을 검출하였다.

여기서  $m$ 은 은닉뉴런의 개수,  $w_{kj}$ 은 은닉뉴런  $j$ 와 출력뉴런  $k$  사이의 연결강도,  $h_j$ 은 은닉뉴런  $j$ 의 활성화함수를 나타내고 식(8)과 같은 가우스형 함수를 이용하며

고장검출을 위해 입력데이터 모두를 RBF 중심으로 사용하여 네트워크가 복잡해지는 전통적인 RBF 네트워크의 단점을 보완하기 위해, 입력데이터보다 적은 개수의 중심을 사용하는 일반화된 RBF 네트워크를 선택하였으며 Fig.5에 네트워크의 구조를 보여준다. 그림에서 보듯이 입력층, 1개의 은닉층 그리고 출력층으로 구성되어 있고 입력층과 은닉층 사이에는 연결강도가 존재하지 않는다. 은닉층과 출력층 사이에는 연결강도가 존재하며 출력뉴런의 활성화함수는 선형이다.

$$h_j(X_i) = \exp\left(-\sum_{i=1}^n \frac{(X_i - c_{ji})^2}{r_{ji}^2}\right) \tag{8}$$

여기서  $c_{ji}$ 는 체택필드 영역의 중심,  $r_{ji}$ 는 체택필드의 폭을 나타낸다.

$i$  번째 입력벡터  $X_i = [R_{T_s}, R_{T_r}, R_{T_{rom}}, R_{T_{evm}}, R_{P_s}, R_{P_r}]^T$ 에 대한 출력뉴런의 RBF 네트워크 활

은닉뉴런의 최적 개수를 결정하기 위해 Fig.6과 같은 Forward Selection(FS) 알고리즘을 사용하였다. 그림에서 보듯이 FS 알고리즘은 먼저 목표값과 허용오차를 설정한 후 네트워크를 시뮬레이션하며 가장 큰 오차를 갖는 입력벡터를 파악

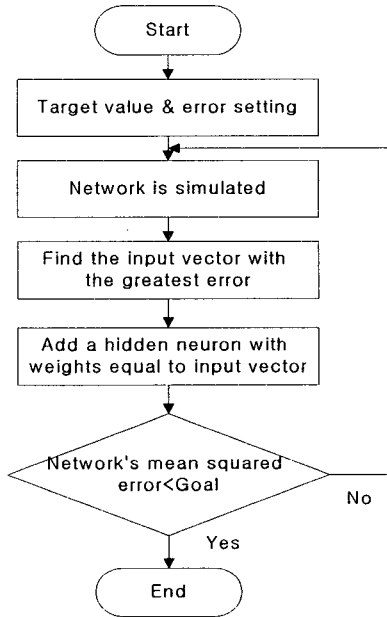


Fig. 6 Forward selection algorithm.

하여 그것과 동일한 연결강도를 갖는 은닉뉴런을 은닉층에 추가한다. 초기에는 은닉층은 뉴런이 없는 상태로 시작하며 알고리즘의 반복에 따라 한번에 하나씩 은닉뉴런이 추가된다. 은닉뉴런이 추가됨에 따라 평균제곱오차는 줄어들며 마침내 허용오차 이하로 수렴하면 알고리즘은 멈추게 구성되어 있다.

고장검출 신경망학습을 위하여  $R_{T_h}$ ,  $R_{T_c}$ ,  $R_{T_{con}}$ ,  $R_{T_{evm}}$ ,  $R_{P_h}$ ,  $R_{P_c}$ 를 입력 파라미터로 선택한 후 실외온도 32~38℃, 실내온도 25~31℃에서 실시된 실험결과를 토대로 증발기오염 고장의 경우 12개의 데이터 세트를, 나머지 고려된 고장의 경우 24개의 데이터 세트를 선정하여 총 84개로 구성된 데이터 세트를 입력으로 사용하였고, 출력으로 4개의 뉴런이 선정되었다. 목표값으로 압축기 밸브누설 고장일 경우  $[0 \ 0 \ 1 \ 0]^T$ , 냉매배관 막

힘부분 고장일 경우  $[0 \ 0 \ 0 \ 1]^T$ , 응축기오염 고장일 경우  $[0 \ 1 \ 0 \ 0]^T$ , 증발기오염 고장일 경우  $[1 \ 0 \ 0 \ 0]^T$ 가 선정되었으며 허용오차로  $10^{-3}$ 을 선정하여 FS 알고리즘 사용한 결과 23개의 은닉뉴런이 선정되었다. Table 5는 학습된 네트워크의 연결강도 중 일부를 보여준다.

#### 4. 알고리즘의 고장검출 성능

고장검출 알고리즘의 고려된 부분고장에 대한 검출 성능을 평가하기 위해서 멀티형 냉방기를 수정한 고장모사장치를 사용하여 고장검출 실험을 수행하였다. 첫번째 실험에서는 실외의 온도와 상대습도를 35℃, 41%, 실내의 온도와 상대습도를 27℃, 50%로 유지하면서 시험시작 후 1,200초와 2,400초에 압축기 밸브누설 고장 10%, 20%를 모사하였고 4,920초와 6,000초에 냉매배관 부분막힘 고장 56%, 58%를, 8,640초와 9,840초에 응축기오염 고장 30%, 45%를, 11,040초에 증발기오염 고장 30%를 모사하였으며 고장종류를 전환시킬 때 1,200초 이상의 무고장 상태를 유지시켰다. 고장모사 적용 후 420초부터 고장검출 실험을 실시하였으며 노이즈 영향을 감소시키기 위해 매 3초마다 과거 측정된 10개의 측정값을 이동평균하여 고장검출의 입력값으로 사용하였다. 두번째 실험에서는 실외의 온도와 상대습도를 32℃, 41%, 실내의 온도와 상대습도를 27℃, 50%로 유지하면서 첫번째 실험과 유사한 방법으로 시험시작 후 1,380초와 2,580초에 압축기 밸브누설 고장 10%, 20%를 모사하였고 5,280초와 6,600초에 냉매배관 부분막힘 고장 56%, 58%를, 9,780초와 11,040초에 응축기오염 고장 30%, 45%를, 13,500초에 증발기오염 고장 30%를 모사하여 실험을 수행하였다. Fig. 7, Fig. 9, Fig. 11, Fig. 12는 첫번째 실험결과를 보여주고, Fig. 8, Fig. 10, Fig. 13, Fig. 14는 두번째 실험결과를 보여준다. Fig. 7과

Table 5 Weights between the hidden layer and the output layer

$W_{kj}$		$j$					
		1	2	3	...	22	23
$k$	1	-21.1659	9.1132	70.4756	...	-35.5625	-45.6332
	2	11.0709	-9.4414	-29.5712	...	-18.7887	39.3580
	3	11.1274	-8.1673	-38.8499	...	15.1501	28.4694
	4	-1.0325	8.4954	-2.0544	...	39.2011	-22.1942




Fig. 7 Measured data (Outdoor 35°C, Indoor 27°C).




Fig. 8 Measured data (Outdoor 32°C, Indoor 27°C).




Fig. 9 Residuals (Outdoor 35°C, Indoor 27°C).




Fig. 10 Residuals (Outdoor 32°C, Indoor 27°C).

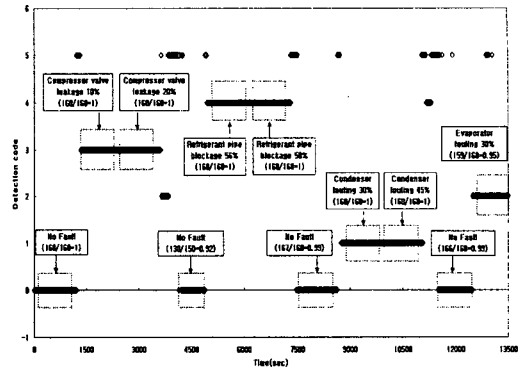


Fig. 11 Fault detection result by using parity relations (Outdoor 35°C, Indoor 27°C).

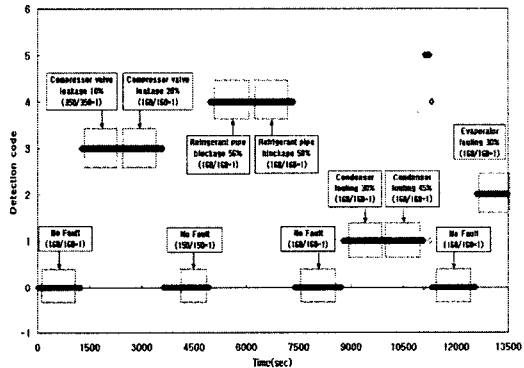


Fig. 12 Fault detection result by using a RBF neural network (Outdoor 35°C, Indoor 27°C).

Fig. 8에는 고장검출 파라미터 측정값  $T_h$ ,  $T_i$ ,  $T_{con}$ ,  $T_{evain}$ ,  $P_h$ ,  $P_i$ 를 보여주며 Fig. 9와 Fig. 10은 고장검출 파라미터의 잔차값  $R_{T_a}$ ,  $R_{T_i}$ ,  $R_{T_{con}}$ ,  $R_{T_{evain}}$ ,  $R_{P_a}$ ,  $R_{P_i}$ 를 보여준다. Fig. 11과 Fig. 13은 기우관계를 사용한 고장검출 알고리즘을 적용한 결과를 보여주며, Fig. 12와 Fig. 14는 RBF 신경망을 사용한 고장검출 알고리즘을 적용한 결과를 보여준다. 그림에서 무고장의 경우는 '0', 응축기 오염 고장의 경우는 '1', 증발기 오염 고장의 경우는 '2', 압축기 밸브누설 고장의 경우는 '3', 냉매배관 부분막힘 고장의 경우는 '4', 고려된 네 가지 고장 이외의 알 수 없는 고장의 경우는 '5'로 고장검출 결과를 나타내었다.

Fig. 11과 Fig. 12에서 보듯이 실외조건 35°C, 41%, 실내조건 27°C, 50%인 냉방표준조건에서

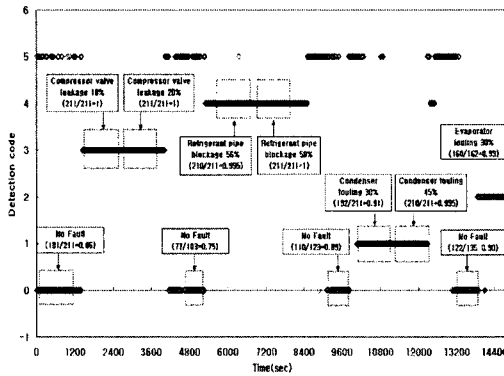


Fig. 13 Fault detection result by using parity relations (Outdoor 32°C, Indoor 27°C).




Fig. 14 Fault detection result by using a RBF neural network (Outdoor 32°C, Indoor 27°C).

Table 6 Residual boundaries for no-fault (Outdoor 32°C, Indoor 27°C)

	$R_{T_h}$ (°C)	$R_{T_l}$ (°C)	$R_{T_{com}}$ (°C)	$R_{T_{con}}$ (°C)	$R_{P_h}$ (kgf/cm <sup>2</sup> )	$R_{P_l}$ (kgf/cm <sup>2</sup> )
Upper	0.59	0.33	0.09	0.35	0.29	0.13
Lower	-1.52	-0.03	-0.3	-0.08	-0.02	-0.02

기우관계를 사용한 고장검출 알고리즘의 검출정확도는 무고장의 경우 97.7%, 압축기 밸브누설 고장의 경우 100%, 냉매배관 부분막힘 고장의 경우 100%, 응축기오염 고장의 경우 100%, 증발기오염 고장의 경우 94.6%이었고, RBF 신경망을 사용한 고장검출 알고리즘의 검출정확도는 각 고장 모두 100%로 두 가지 고장검출 알고리즘 모두 평균 98% 이상의 정확도를 갖고 고장을 검출하였으나, Fig. 13과 Fig. 14에서 보듯이 실외조건 32°C, 41%, 실내조건 27°C, 50%에서 기우관계를 사용한 고장검출 알고리즘의 검출정확도는 무고장의 경우 85.7%, 압축기 밸브누설 고장의 경우 100%, 냉매배관 부분막힘 고장의 경우 99.8%, 응축기오염 고장의 경우 95.3%, 증발기오염 고장의 경우 98.8%로써 RBF 신경망을 사용한 고장검출 알고리즘의 검출정확도 100%, 100%, 95.8%, 99.5%, 97.6%보다 고장검출정확도가 평균 6% 정도 낮은 것을 알 수 있었다. 이러한 고장검출정확도의 차이는 기우관계를 사용한 고장검출 알고리즘에서 Table 6과 같은 실외조건 32°C, 41%, 실내조건 27°C, 50%에서 얻은 달라진 무고장잔차범위를 사용하지 않고 Table 4와 같이 냉방표준조건에서 얻은 무고장잔차범위를 사용하였기 때문이다. 기우관계를 사용한 고장검출 알고리즘에서

무고장잔차범위는 고장검출정확도에 매우 민감하게 작용하며 검출정확도를 보다 높이기 위해 각종 고장에 따라 다양한 조건에서 기준기우관계에 맞는 각각의 적절한 무고장잔차범위를 구해 사용할 수 있으나 각각의 최적 무고장잔차범위를 구하는 데 많은 시간과 노력이 요구된다. 반면에 RBF 신경망을 사용한 고장검출 알고리즘에서는 각종 고장에 따라 다양한 조건에서 얻은 고장검출 파라미터의 잔차를 사용하여 각각의 조건에 대한 입력의 특징을 학습을 통해 보다 쉽게 반영할 수 있으며 입력을 단순히 +1, 0, -1의 세 영역으로 나누는 것이 아니라 전체 영역에 대한 특징을 학습을 통해 반영할 수 있기 때문에 보다 나은 검출정확도를 유지할 수 있다.

### 5. 결론

멀티형 냉방기에서 발생할 수 있는 여러 가지 고장들 중 압축기 밸브누설, 냉매배관 부분막힘, 응축기오염, 증발기오염 등의 네 가지 부분고장을 선택하여 고장검출을 효과적으로 수행할 수 있도록 기우관계를 사용한 고장검출 알고리즘과 RBF 신경망을 사용한 고장검출 알고리즘을 개발하였다. 개발된 두 가지 알고리즘 모두 냉방시스



템의 무고장 상태로부터 얻은 수학적 모델에서의 출력과 실제 시스템에서 측정된 측정값과의 차인 잔차를 입력으로 사용하였으며, 기우관계를 사용한 고장검출 알고리즘에서는 실험을 통해 얻은 기준기우관계를 사용하였고 RBF 신경망을 사용한 고장검출 알고리즘에서는 잔차를 입력으로 하는 RBF 신경망을 사용하였다.

고장모사 실험장치를 통한 성능실험에서 개발된 두 가지 고장검출 알고리즘이 모두 적절하게 고장을 검출하였음을 검증하였지만, 실외환경이 변했을 때 RBF 신경망을 사용한 고장검출 알고리즘이 기우관계를 사용한 고장검출 알고리즘에 비해 상대적으로 보다 높은 검출정확도를 보임을 알 수 있었다.

따라서 잔차를 입력으로 하는 RBF 신경망 고장검출 알고리즘을 실제 시스템에 적용하면 보다 유효하게 고장을 검출할 수 있음을 확인하였다.

## 후 기

본 연구는 2005년도 국민대학교 교내연구비 지원에 의해 수행되었다.

## 참고문헌

1. Breuker, M. S. and Braun, J. E., 1998, Common faults and their impacts for rooftop air conditioners, HVAC&R Research, Vol. 4, No. 3, pp. 303-318.
2. Breuker, M. S. and Braun, J. E., 1998, Evaluating the performance of a fault detection and diagnostic system for vapor compression equipment, ASHRAE HVAC&R Research, Vol. 4, No. 4, pp. 401-425.
3. Riemer, P. L., Mitchell, J. W. and Beckman, W. A., 2002, The use of series analysis in fault detection and diagnosis methodologies, ASHRAE Transactions, 2002, V. 108, Pt. 2.
4. Peitsman, H. C. and Bakker, V. E., 1996, Application of black-box models to HVAC systems for fault detection, ASHRAE Transactions, pp. 628-640.
5. Peitsman, H. C. and Soethout, L. L., 1997, ARX models and real-time model-based diagnosis, ASHRAE Transactions, pp. 657-671.
6. McIntosh, I. B. D., Mitchell, J. W. and Beckman, W. A., 2000, Fault detection and diagnosis in chillers, ASHRAE Transactions 2000, V. 106, Pt. 2.
7. Frank, D. and Pletta, J. B., 1992, Neural network sensor fusion for security application, Intelligent Engineering Systems through Artificial Neural Networks, Vol. 2, pp. 745-750.
8. Ch'ng, C. G. and Yak, A. S., 1998, Neural networks for process diagnosis, ICARCV, pp. 494-498.
9. Han, D. and Lee, H., 2002, Partial fault detection of air-conditioning system by neural network algorithm using data preprocessing method, Korean Journal of the SAREK Vol. 14, No. 7, pp. 560-566.
10. Han, D. and Hwang, J., 2003, The partial fault detection of an air-conditioning system by the neural network algorithm using normalized input data, Korean Journal of the Air-Conditioning and Refrigeration Engineering, Vol. 15, No. 3, pp. 159-165.
11. Han, D. and Joo, M., 2002, Fault detection & diagnosis of an air handling unit based on rule bases, Korean Journal of the Air-Conditioning and Refrigeration Engineering, Vol. 14, No. 7, pp. 552-559.
12. Han, D. and Kim, J., 2004, An experimental study on the rule based fault detection and diagnosis system for a constant air volume air handling unit, Korean Journal of the Air-Conditioning and Refrigeration Engineering, Vol. 16, No. 9, pp. 872-880.
13. Han, D. and Ryoo, B., 2003, Partial fault diagnosis of the air-conditioning system by using curve fitting model and neural network algorithm, Proceedings of the SAREK, pp. 577-582.
14. Han, D. and Ryoo, B., 2004, Fault detection and diagnosis of the air-conditioning system by using a fuzzy algorithm and a RBF neural network, Proceedings of the SAREK, pp. 795-800.