

신경망무고장모델과 이중퍼지로직을 사용한 냉방기 고장진단 알고리즘

한도영[†], 정남철^{*}

국민대학교 기계·자동차공학부, *국민대학교 기계공학과 대학원

Fault Diagnosis Algorithm of an Air-conditioning System by using a Neural No-fault Model and a Dual Fuzzy Logic

Doyoung Han[†], Namchul Jung^{*}

School of Mechanical and Automotive Engineering, Kookmin University, Seoul 136-702, Korea

*Graduate School of Mechanical Engineering, Kookmin University, Seoul 136-702, Korea

(Received October 4, 2005; revision received September 1, 2006)

ABSTRACT: The fault diagnosis technologies may be applied in order to decrease the energy consumption and the maintenance cost of an air-conditioning system. In this paper, a fault diagnosis algorithm was developed by using a neural no-fault model and a dual fuzzy logic. Five different faults, such as the compressor valve leakage, the liquid line blockage, the condenser fouling, the evaporator fouling, and the refrigerant leakage of an air-conditioning system, were considered. The fault diagnosis algorithm was tested by using a fault simulation facility. Test results showed that the algorithm developed for this study was effective to detect and diagnose various faults. Therefore, this algorithm may be practically used for the fault diagnosis of an air-conditioning system.

Key words: Fault diagnosis algorithm(고장진단 알고리즘), Neural no-fault model(신경망무고장 모델), Dual fuzzy logic(이중퍼지로직), Compressor valve leakage(압축기밸브누설), Liquid line blockage(액배관막힘), Condenser fouling(응축기오염), Evaporator fouling(증발기오염), Refrigerant leakage(냉매누설)

기 호 설 명

b : 바이어스
 C : 압축기 회전수 [Hz]
 P : 압력 [kg/cm^2]
 R : 잔차
 S : 전자팽창밸브 개도 [step]

T : 온도 [$^{\circ}\text{C}$]
 w : 신경망 연결강도

하첨자

con : 응축기 출구
 h : 압축기 출구
 l : 압축기 입구
 out : 실외공기
 tot : 총합

[†] Corresponding author

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

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

1. 서 론

국가 경제가 성장함에 따라 보다 쾌적한 실내 환경에 대한 요구가 증가하고 있으며, 이에 따라 여름철 전력수요 중 냉방기가 차지하는 비중이 매우 빠르게 증가하고 있다. 제한된 국가에너지를 효율적으로 사용하기 위해 냉방기의 신뢰성과 성능향상을 위한 연구가 진행되고 있으며, 특히 최근 진행되고 있는 연구들 중 냉방기 부분고장을 사전에 진단할 수 있는 고장진단시스템이 실용화된다면 부분고장으로부터 오는 불필요한 에너지 사용을 억제하고 심각한 고장을 미연에 방지할 수 있어 사용자의 불편과 경제적 부담을 최소화시킬 수 있다.

고장 검출 및 진단에 관한 연구는 주로 냉방 분야 외 타 분야에서 활발히 수행되어 왔다. Frank et al.⁽¹⁾는 자기학습과 패턴분류 능력을 갖고 있는 신경망을 이용하여 고장 검출 및 진단 시스템의 사용 가능성을 보였고, Fuente et al.⁽²⁾은 화학공정의 고장을 검출하는 연구를 수행하였으며, Yu et al.⁽³⁾은 RBF 신경망을 이용한 센서 고장 검출에 관한 연구를 수행하였다. 냉방 분야에서 Braun et al.^(4,5)은 부분고장이 미치는 에너지 손실과 부분고장이 각종 변수에 미치는 영향에 대해서 연구하였고, McIntosh et al.⁽⁶⁾은 수학적 모델을 사

용한 고장 진단방법에 대하여 연구를 수행하였다. Han et al.은 퍼지 알고리즘,⁽⁷⁾ 신경망 알고리즘^(8,9)을 사용하여 냉방기 고장 검출 및 진단에 대하여 연구를 수행하였고, 또한 공조기를 대상으로 퍼지 알고리즘^(10,11)을 사용한 고장 검출 및 진단에 관한 연구를 수행하였다. 그러나 다양한 운전조건에서 운전되는 냉방시스템의 복잡성 때문에 간단하면서 효과적인 고장 검출 및 진단방법이 아직 실용화되지 못했고 이를 위해 보다 많은 연구가 필요한 실정이다.

본 논문에서는 멀티형 냉방기의 압축기밸브누설, 응축기오염, 증발기오염, 액배관막힘, 냉매누설에 대한 고장을 진단할 수 있는 신경망무고장 모델과 이중퍼지회로를 사용한 고장진단 알고리즘을 개발한 후 고장모사실험을 수행하여 개발된 고장진단 알고리즘의 유효성을 확인하는 것을 목적으로 한다.

2. 고장모사장치

개발된 고장 진단 알고리즘의 타당성을 확인하기 위해 R22 냉매를 사용한 5RT 용량의 멀티형 냉방기를 고장모사장치로 사용하였다. 고장모사장치는 Fig.1과 같이 압축기, 오일분리기, 응축기, 응축기팬, 수액기, 액분리기로 구성된 한 대

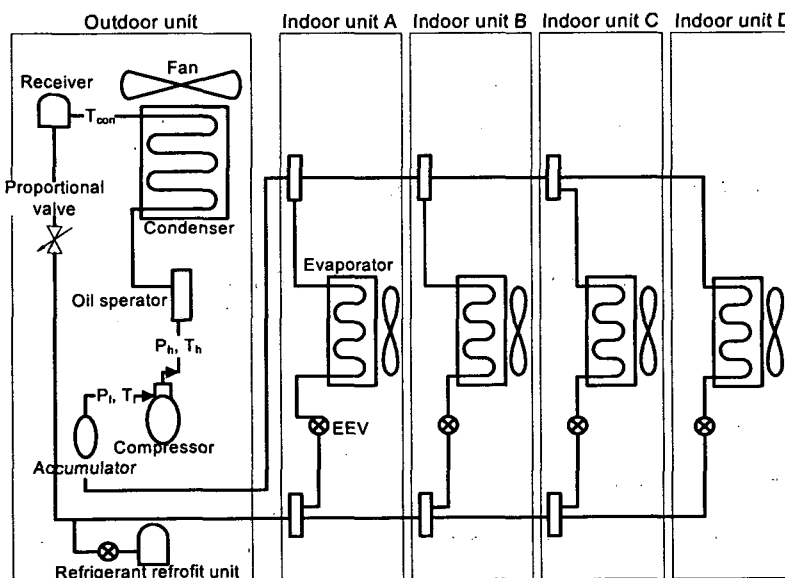


Fig. 1 Fault simulation system.

Table 1 Specification of a multi-type system

Component		Specification
Outdoor unit	Compressor	Scroll type, 14.5 kW
	Fan	Propeller fan, 90 m ³ /min
	Coil	Φ7 × 2 row × 52 step
	EEV	1-2 phase, unipolar
Indoor unit	Fan	Cross flow fan, 7.5 m ³ /min
	Coil	Φ7 × 2 row × 12 step
	EEV	2 phase, unipolar

의 실외기와 전자팽창밸브, 증발기, 증발기팬으로 구성된 네 대의 실내기를 사용하였으며, Table 1 에는 구체적인 사양을 나타내었다. 압축기밸브누설은 불순물질이 압축기내로 유입되어 압축기 밸브를 손상시켜 고압의 냉매가 흡입라인으로 누설되어 전체 냉매순환량이 감소하는 현상으로 이를 모사하기 위해 압축기의 회전수를 조절하였으며, 증발기오염 및 응축기오염은 시스템 내의 불순물질이나 시스템 밖의 먼지나 낙엽과 같은 이물질에 의해 전열능력이 감소하는 현상으로 실내의 열교환기의 전열면적을 일정부분 차단하여 고장을 모사하였다. 액배관막힘은 불순물질이 유입되어 압축기, 배관, 밸브 등에 적층되어 냉매유동을 방

해하는 현상으로 액배관에 비레벨브를 설치하여 냉매 통과면적을 조절하여 고장을 모사하였으며, 냉매누설은 밀폐된 시스템 내부에서 외부로 냉매가 누설되는 현상으로 냉매회수기를 이용하여 시스템의 냉매를 추출하여 고장을 모사하였다.

실험에 요구되는 환경을 조성하기 위해 실외온 습도조건을 -5~40±1.0℃, 20~90±2.0%로 제어할 수 있는 한 대의 실외환경조성챔버와 네 대의 실내환경조성챔버를 사용하였으며, 고장모사장치와 환경조성챔버의 각종 데이터를 수집하기 위하여 Fig.2와 같은 데이터 수집 및 제어시스템을 사용하였다. PC #1을 통하여 고장모사장치의 온도, 습도 등의 각종 계측데이터를 수집하였으며, 환경조성챔버의 온도, 습도 등을 측정하여 항온조성챔버를 제어하였다. PC #2를 통하여 고장모사장치의 온도, 압력, 전력 등 각종 데이터를 측정하여 고장모사장치의 전자팽창밸브, 압축기, 실외팬, 실내팬 등을 제어하였다. 온도측정을 위해 T형 열전대를 압력측정을 위해 4~20 mA 출력의 압력변환기를 사용하였다.

3. 고장진단 알고리즘

멀티형 시스템의 압축기밸브누설, 응축기오염, 증발기오염, 액배관막힘, 냉매누설고장을 진단하기 위한 고장진단 알고리즘은 무고장상태에서의 시스템 변수를 예측할 수 있는 신경망무고장모델과, 측정값과 신경망무고장모델에서 계산된 예측값을 사용하여 각종 고장을 진단할 수 있는 이중퍼지로직 알고리즘으로 구성되어 있다.

3.1 신경망무고장모델

Fig. 3는 무고장상태에서의 시스템 모델로 사용된 3×9×11×5구조의 다층 신경망을 보여준다.⁽¹²⁾ 신경망에서 입력변수로 사용된 측정값 T_{out} , C , S_{tot} 은 평균값과 표준편차를 이용하여 정규화시켜 사용하였으며, 신경망 출력변수로 사용된 모델예측값 T_h , T_l , T_{con} , P_h , P_l 은 정규화되어 계산된 값을 평균값과 표준편차를 이용하여 환원하여 사용하였다. 첫번째 은닉층, 두번째 은닉층의 활성화함수로 탄젠트 시그모이드함수(tangent sigmoid function)를 사용하였고, 출력층의 활성화함수로 선형 활성화함수를 사용하였다.

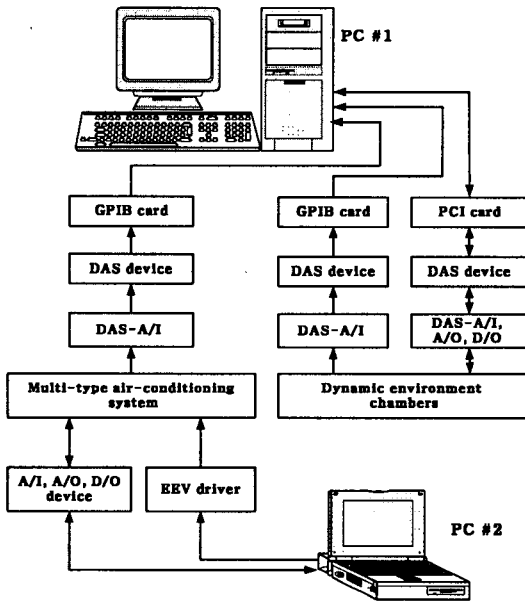


Fig. 2 Data acquisition and control system.




Fig. 3 Neural no-fault model.

신경망모델의 학습을 위해 29, 32, 35, 38, 41°C의 T_{out} , 40, 45, 50 Hz의 C , 그리고 주어진 T_{out} 과 C 에서 압축기 흡입 과열도를 10°C와 15°C로 유지시키기 위한 S_{tot} 를 입력변수값으로 선택하여 무고장 실험을 수행하면서 출력변수값 $T_h, T_l, T_{con}, P_h, P_l$ 을 측정하였으며 보다 많은 학습데이터를 확보하기 위해 실험에서 얻은 측정값을 보정하여 사용하였다.

학습 방법으로는 모멘텀 역전파 알고리즘(moment momentum backpropagation algorithm)⁽¹³⁾을 사용하였으며, 학습률은 0.46, 모멘텀 상수는 0.88, 학습오차 허용범위로 1×10^{-3} 을 선택하였다. Table 2는 학습된 신경망 연결강도와 바이어스의 일부를 보여준다.

Table 2 Weights and biases of neural no-fault model

$w^1(i,j)$		j										
		1	2	3	4	5	6	7	8	9		
i	1	0.4591	-0.5128	-1.2415	-1.4139	-0.9290	-2.2651	1.5341	-1.0532	0.8823		
	2	-0.1641	0.2161	-2.3593	2.0028	-2.1809	-1.0277	1.5708	2.6452	-2.2784		
	3	1.7508	1.9082	-0.3413	-0.8960	0.2151	0.4458	-1.6039	-1.2567	-0.6116		
$w^2(i,j)$		j										
		1	2	3	4	5	6	7	8	9	10	11
i	1	0.1970	0.6161	-0.0482	-0.0012	0.6354	0.0426	1.4591	-0.7389	0.5886	0.8654	-2.1762
	2	-0.7240	-0.1821	-0.4005	0.5822	1.7542	-1.0535	0.6357	0.5478	-0.4662	0.6300	1.6062
	3	-0.0946	1.7918	-1.0084	0.2567	0.5936	0.0045	0.1492	1.1059	-2.3009	-0.7283	-0.6004

	7	-1.1155	-1.4494	0.4512	0.5797	-0.5864	0.7871	-2.2634	0.0587	1.0270	0.8525	0.3780
	8	0.5428	-0.1887	-1.1814	-0.4954	1.5539	1.2936	-0.6085	0.3180	0.5079	0.9155	-1.4350
9	-0.9265	-1.0579	-0.0287	1.1096	-1.7484	-0.5281	-0.6425	1.2106	-1.0023	0.6156	0.4730	
$w^3(i,j)$		j										
		1	2	3	4	5						
i	1	-0.8038	-1.8118	-0.8682	-0.7660	0.3223						
	2	0.0986	-2.0803	0.0769	0.7284	0.7754						
	3	-0.8080	-0.0510	0.3748	0.0728	1.6919						
						
	9	0.7537	-1.4975	0.6191	1.1975	0.0984						
	10	-0.5575	1.0811	0.2581	0.4337	0.6667						
11	1.8103	1.7212	-1.0707	-1.3092	-0.8954							
		j										
		1	2	3	4	5	6	7	8	9	10	11
b1		-2.5269	1.2403	1.9252	1.6002	-0.6453	0.8883	-0.4572	-1.6742	3.1398		
b2		1.3790	0.2958	1.2211	0.2044	0.0436	0.2889	-0.5382	-0.9814	0.1242	0.3858	-0.3694
b3		0.1187	0.0614	1.3051	1.4998	0.0857						

3.2 이중퍼지로직 알고리즘

멀티형 시스템의 고장을 진단하기 위하여 T_h , T_l , T_{con} , P_h , P_l 의 잔차를 이중퍼지로직의 입력 변수로 사용하였다. 잔차란 센서를 통해 측정된 측정값과 신경망무고장모델에서 예측된 예측값의 차이를 의미한다. Table 3은 실험을 통해 얻은 고장에 대한 잔차의 경향을 보여주며, 여기서 +는 잔차가 양수로서 큰 경우, -는 잔차가 음수로서 작은 경우, 0은 잔차가 0에 가까운 경우를 의미한다.

잔차경향을 이용하여 하나의 퍼지로직보다 룰베이스를 간소화시킨 퍼지로직 #1과 퍼지로직 #2로 구성된 이중퍼지로직 알고리즘을 개발하였다. 고장의 종류에 따라 변하는 잔차의 경향, 변화폭, 반응속도를 고려하여 퍼지로직 #1에서는 T_h , P_h 잔차를 입력으로 사용하여 고장을 진단하였고, 퍼지로직 #2에서는 T_l , T_{con} , P_l 의 잔차를 입력으

로 사용하여 고장을 진단하였으며, 퍼지로직 #1의 진단결과와 퍼지로직 #2의 진단결과가 일치될 경우에만 진단된 고장으로 분류하였고 다른 경우에는 알 수 없는 고장으로 분류하였다.

퍼지로직 #1의 룰베이스는 Table 4에, 입력변수 R_{T_h} , R_{P_h} 의 멤버십 함수(memberhip function)는 Fig. 4, Fig.5에, 출력변수 멤버십 함수는 Fig.6에 보여준다. 여기서 F_1은 압축기밸브누설, F_2는 증발기오염, F_3은 응축기오염, F_4는 액배관막힘, F_5는 냉매누설고장, No fault는 무고장, Unknown는 알 수 없는 고장을 각각 의미하며 하첨자는 무고장상태를 기준으로 각 고장 정도를 백분율로 나타낸 수치를 의미한다. 퍼지로직 #2의 룰베이스는 Table 5에, 입력변수 R_{T_l} , $R_{T_{con}}$, R_{P_l} 의 멤버십 함수는 Fig. 7, Fig. 8, Fig. 9에, 출력변수 멤버십 함수는 Fig.10에 나타내었다. 퍼지로직의 추론방법으로 최대최소법을, 비퍼지화 방법으로 무게중심법을 사용하였다.

Table 3 Trends of input variable residuals

Fault	Variable				
	R_{T_h}	R_{T_l}	$R_{T_{con}}$	R_{P_h}	R_{P_l}
Compressor valve leakage	-	-	-	-	+
Evaporator fouling	-	-	0	0	0
Condenser fouling	+	0	+	+	+
Liquid line blockage	+	+	-	-	-
Refrigerant leakage	+	+	0	0	-

Table 4 Rules-base for fuzzy logic #1

Fault type		R_{P_h}		
		Small	Middle	Large
R_{T_h}	Smaller	F_140	F_2	Unknown
	Small	F_120	F_2	Unknown
	Middle	Unknown	No fault	Unknown
	Large	F_4	F_510	F_3
	Larger	F_4	F_520	F_3




Fig. 5 Membership for R_{P_h} .




Fig. 4 Membership for R_{T_l} .




Fig. 6 Output membership for fuzzy logic #1.

Table 5 Rule-bases for fuzzy logic #2

	RTcon	R_{T_i}				
		Smaller	Small	Middle	Large	Larger
R_{P_i} (small)	Small	Unknown	Unknown	Unknown	F_40	F_45
	Middle	Unknown	Unknown	Unknown	F_5	F_5
	Large	Unknown	Unknown	Unknown	Unknown	Unknown
	Larger	Unknown	Unknown	Unknown	Unknown	Unknown
R_{P_i} (middle)	Small	Unknown	Unknown	Unknown	Unknown	Unknown
	Middle	F_250	F_230	No fault	Unknown	Unknown
	Large	Unknown	Unknown	Unknown	Unknown	Unknown
	Larger	Unknown	Unknown	Unknown	Unknown	Unknown
R_{P_i} (large)	Small	F_1	F_1	Unknown	Unknown	Unknown
	Middle	Unknown	Unknown	Unknown	Unknown	Unknown
	Large	Unknown	Unknown	F_330	Unknown	Unknown
	Larger	Unknown	Unknown	F_340	Unknown	Unknown




Fig. 7 Membership for R_{T_i} .




Fig. 8 Membership for $R_{T_{con}}$.




Fig. 9 Membership for R_{P_i} .




Fig. 10 Output membership for fuzzy logic #2.

4. 고장진단 시스템 성능분석

4.1 무고장신경망모델의 정확도

사용된 학습데이터값과 무고장신경망모델로부터 계산된 값과의 평균 오차값과 최대 오차값을 계산한 결과 T_h 의 경우 0.136°C , 0.24°C , T_i 의 경우 0.033°C , 0.08°C , T_{con} 의 경우 0.198°C , 0.55°C , P_h 의 경우 0.037 kg/cm^2 , 0.08 kg/cm^2 , P_i 의 경우 0.007 kg/cm^2 , 0.02 kg/cm^2 을 보여주었다. 따라서 T_{out} , C , S_{tot} 의 다양한 시스템 운전조건에 따라 무고장상태에서의 T_h , T_i , T_{con} , P_h , P_i 를 주어진 오차범위 내에서 예측할 수 있는 모델로 사용할 수 있음을 확인하였다.

4.2 고장진단 성능시험

개발된 고장진단 알고리즘에 의한 고장진단 결과를 평가하기 위하여 고장모사장치를 사용하여 고장진단실험을 수행하였다. 실내온도와 상대습도를 27°C , 50%로 고정시킨 상태에서 실외온도와 압축기회전수, 전자팽창밸브의 개도를 변화시키면서 5종류 고장에 대해 모사실험을 수행하였다.

시험시작 후 4,900초까지 실외온도와 상대습도를 35°C , 41%, 압축기회전수와 전자팽창밸브 개도를 50 Hz, 1,030 step으로 유지하면서 930초에서 2,735초 사이에는 20% 압축기밸브누설 고장실험,

2,735초에서 4,900초 사이에는 40% 압축기밸브누설 고장실험을 수행하였다. 4,905초에서 10,565초까지 실외온도와 상대습도 35℃, 41%, 압축기회전수 45 Hz, 전자팽창밸브 개도 985 step을 유지하면서, 7,750초에서 8,970초 사이에는 30% 증발기오염 고장실험, 8,975초에서 10,660초 사이에는 50% 증발기오염 고장실험을 수행하였다. 13,050초에서 17,060초까지 실외온도와 상대습도 29℃, 41%, 압축기회전수 45 Hz, 전자팽창밸브 개도 1,010 step을 유지하면서, 13,980초에서 15,500초 사이에는 30% 응축기오염 고장실험, 15,505초에서 17,055초 사이에는 40% 응축기오염 고장실험을 수행하였다. 17,870초에서 23,215초까지 실외온도와 상대습도 29℃, 41%, 압축기회전수 45 Hz, 전자팽창밸브 개도 1,095 step을 유지하면서 19,815초에서 20,885초 사이에는 40% 액배관막힘 고장실험, 20,890초에서 23,215초 사이에는 45% 액배관막힘 고장실험을 수행하였다. 또한 23,520초에서 29,560

초까지 실외온도와 상대습도 32℃, 41%, 압축기회전수 40 Hz, 전자팽창밸브 개도 1,030 step을 유지하면서 25,285초에서 26,305초 사이에는 10% 냉매누설 고장실험, 26,310초에서 29,560초 사이에는 20% 냉매누설 고장실험을 수행하였다.

Fig. 11, Fig. 12, Fig. 13, Fig. 14에는 고장에 따른 시스템 변수의 변화를 보여준다. Fig. 11에는 센서를 통해 측정된 압축기 출구온도, 압축기 입구온도, 응축기 출구온도를 보여주고, Fig. 12에는 압축기 출구압력, 압축기 입구압력을 보여준다. Fig. 13과 Fig. 14에는 센서를 통해 측정된 측정값과 무고장신경망모델에서 계산된 예측값과의 잔차를 보여준다. Fig. 15, Fig. 16, Fig. 17에는 고장진단 결과를 나타내었다. Fig. 15에서 보듯이 퍼지로직 #1을 사용하여 고장을 진단한 결과, 무고장상태에서의 각 운전조건별 고장진단 정확도는 100%, 83%, 100%, 91%, 100%이었으며, 평균 93%의 진단정확도를 보여주었다. 또한 20%와 40




Fig. 11 Measured data for T_h , T_{con} and T_l .




Fig. 13 Residuals for R_{T_h} , R_{T_l} and $R_{T_{con}}$.




Fig. 12 Measured data for P_h and P_l .




Fig. 14 Residuals for R_{P_h} and R_{P_l} .

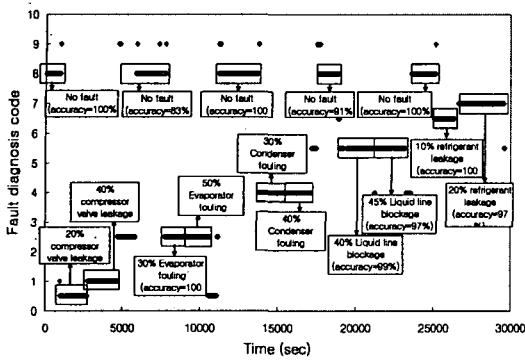


Fig. 15 Fault diagnosis results from the fuzzy logic #1.

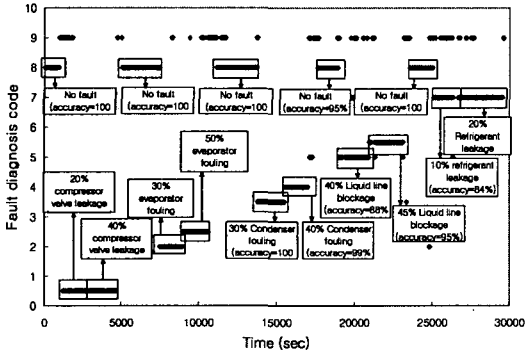


Fig. 16 Fault diagnosis results from the fuzzy logic #2.

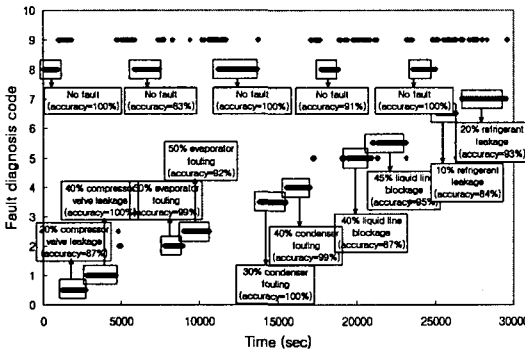


Fig. 17 Fault diagnosis results from the dual fuzzy logic.

% 압축기 밸브누설은 100%, 100%의 정확도, 30%와 50% 증발기오염은 100%, 96%의 정확도, 30%와 40% 응축기오염은 100%, 100%의 정확도, 40%

%와 45% 액배관막힘은 99%, 97%의 정확도, 그리고 10%와 20% 냉매누설 고장의 경우 100%, 97%의 고장진단 정확도를 보여주었다. Fig. 16에서 보듯이 퍼지로지 #2를 사용하여 고장을 진단한 결과, 무고장상태에서의 각 운전조건별 고장진단 정확도는 100%, 100%, 100%, 95%, 100%이었으며, 평균 99%의 진단정확도를 보여주었다. 10%와 20% 압축기밸브누설은 87%, 100%의 정확도, 30%와 50% 증발기오염은 99%, 92%의 정확도, 30%와 40% 응축기오염은 100%, 99%의 정확도, 40%와 45% 액배관막힘은 88%, 95%의 정확도, 그리고 10%와 20% 냉매누설은 84%, 93%의 고장진단 정확도를 보여주었다. 따라서 최종 고장진단 결과는 Fig. 17에서 보듯이 무고장의 경우 각 운전조건별 100%, 83%, 100%, 91%, 100%를 보여주었고 평균 93%의 진단정확도를 보여주었으며, 20%와 40% 압축기밸브누설은 87%, 100%의 정확도, 30%와 50% 증발기오염은 99%, 92%의 정확도, 30%와 40% 응축기오염은 100%, 99%의 정확도, 40%와 45% 액배관막힘은 87%, 95%의 정확도, 그리고 10%와 20% 냉매누설은 84%, 93%의 정확도를 보여주었다.

5. 결 론

멀티형 냉방기의 응축기오염, 증발기오염, 압축기밸브누설, 액배관막힘, 냉매누설의 부분 고장에 대한 고장진단 알고리즘을 개발한 후 개발된 고장진단 알고리즘의 성능을 확인하기 위해 고장모사실험을 수행하였으며 실시한 실험 결과 다음과 같은 결과들을 얻을 수 있었다.

- (1) 실외온도, 압축기회전수, 전자팽창밸브 개도를 입력변수로 하고 압축기 출구온도, 압축기 흡입온도, 응축기 출구온도, 압축기 출구압력, 압축기 입구압력을 출력변수로 하는 3×9×11×5 구조의 신경망무고장모델을 개발하였다.
- (2) 압축기 출구온도, 압축기 출구압력의 잔차를 입력변수로 한 퍼지로지 #1과 압축기 입구온도, 응축기 출구온도, 압축기 입구압력의 잔차를 입력변수로 한 퍼지로지 #2를 사용하여 이중퍼지로지 알고리즘을 개발하였다.
- (3) 무고장신경망모델과 이중퍼지로지 알고리즘으로 구성된 고장진단 알고리즘을 고장모사장치에 적용하여 실험한 결과 무고장상태의 진단과

압축기벨브누설고장, 증발기오염고장, 응축기오염고장, 액배관막힘고장, 냉매누설고장의 부분 고장진단이 비교적 정확하게 진단되었음이 확인되었다.

따라서 본 연구에서 개발된 무고장신경망모델과 이중퍼지로직 알고리즘은 다양한 조건에서 운전되는 냉방기의 부분 고장진단에 효과적으로 적용할 수 있음을 알 수 있었다.

후 기

본 연구는 2006년도 국민대학교 교내 연구비 지원으로 수행되었으며 관계자 여러분께 감사드립니다.

참고문헌

1. 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.
2. Fuente, M.J. and Saludes, S., 2000, Fault detection and isolation in a nonlinear plant via neural networks, *Proc. of 4th IFAC Symp., Fault Detection, Supervision and Safety for Technical Processes*, Vol. 1, pp. 472-477.
3. Yu, D.L., Gomm, J.B. and Williams, D., 1999, Sensor fault diagnosis in a chemical process via RBF neural networks, *Control Engineering Practice*, Vol. 7, No. 1, pp. 1410-1420.
4. 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.
5. Che, B. and Braun, J.E., 2001, Simple rule-based methods for fault detection and diagnostics applied to packaged air conditioners, *ASHRAE Transactions*, Vol. 107, Pt. 1, Paper #AT-01-14-2.
6. McIntosh, I.B.D., Mitchell, J.W. and Beckman, W.A., 2000, Fault detection and diagnosis in chillers, *ASHRAE Transactions* 2000, Vol. 106, Pt. 2, Paper #4395.
7. Han, D. and Ha, S., 2000, Fault detection and diagnosis of air-conditioning system by using curve fitted type fuzzy algorithm, *Proceedings of the SAREK Winter Annual Conference*, Vol. 1, pp. 302-307.
8. 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 Air-Conditioning and Refrigeration Engineering*, Vol. 15, No. 3, pp. 159-165.
9. Han, D. and Ryoo, B., 2005, Fault detection of an air-conditioning system by using a residual input RBF neural network, *Korean Journal of Air-Conditioning and Refrigeration Engineering*, Vol. 17, No. 8, pp. 780-788.
10. Han, D. and Joo, M., 2002, Fault detection and 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.
11. 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.
12. Simon, H., 1999, *Neural networks*, Prentice-Hall, pp. 156-255.
13. Madan, M.G., Liang, J. and Noriyasu, H., 2003, *Static and dynamic neural networks*, 1st ed., Wiley-Interscience, pp. 144-170.