

데이터 전처리방법을 적용한 신경망 알고리즘의 냉방기 부분고장 검출

한 도 영[†], 이 한 홍^{*}, 윤 태 훈^{*}

국민대학교 기계·자동차공학부, *국민대학교 기계공학과 대학원

Partial Fault Detection of Air-conditioning System by Neural Network Algorithm using Data Preprocessing Method

Doyoung Han[†], Hanhong Lee^{*}, Teahun Yun^{*}

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

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

(Received February 6, 2002; revision received April 24, 2002)

ABSTRACT: The fault detection and diagnosis technology may be applied in order to decrease the energy consumption and the maintenance cost of the air-conditioning system. In this study, two different types of faults in the air-conditioning system, such as the condenser fouling and the evaporator fan slowdown, were considered. The neural network algorithm combined with data preprocessor was developed and applied to detect the faults of the real system. Test results show that this method is very effective to detect the faults in the air-conditioning system. Therefore, this developed method can be used for the development of the air-conditioner fault detection system.

Key words: Neural network algorithm(신경망 알고리즘), Fault detection system(고장검출 시스템), Multi-type air-conditioner(멀티형 냉방기), Energy conservation(에너지 절약), Condenser fouling(응축기 오염), Evaporator fan slowdown(증발기 팬 고장), Data preprocessing method(데이터 전처리방법)

기 호 설 명

| | |
|--|--|
| T_{out} : 실외온도 [°C] | P_i : 압축기 입구압력 [kg/cm ²] |
| T_{in} : 실내온도 [°C] | X : 입력값 |
| T_h : 압축기 출구온도 [°C] | Y : 출력값 |
| T_c : 응축온도 [°C] | W : 연결강도 |
| T_e : 증발온도 [°C] | b : 바이어스 |
| P_h : 압축기 출구압력 [kg/cm ²] | |

그리스 문자

δ : 오차

† Corresponding author

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

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

1. 서 론

냉방기 보급증가로 인해 국가 전력소비에서 냉

방기가 차지하는 비중이 큰 몫을 차지하고 있다. 이로 인해 냉방기의 에너지 소비를 줄일 수 있는 기술에 대한 여러 가지 방안이 제시되고 있으며 그중 고장으로 인한 불필요한 에너지 소비를 줄일 수 있는 지능화된 고장검출 및 진단방법은 에너지 절감효과가 큰 장점을 가지고 있으나 관련 연구는 미비한 실정이다. 현재까지 연구중인 대부분의 고장검출 및 진단 시스템에서는 고장으로 부터 초래되는 성능저하 현상을 주로 사용함으로써 시스템에서 고장이 상당부분 진행된 후에 고장을 검출할 수 있는 문제점이 있다. 그러나 현실적으로 에너지 소비증가의 주요한 원인은 완전 고장으로 인한 장비의 정지상태가 아닌 점진적인 고장으로 오랜 기간 운전하였을 경우 발생하는 불필요한 에너지 사용이 문제가 되고 있다. 따라서 냉방 시스템의 점증적인 노화나 부분적인 고장으로 인한 오작동을 검출하고 진단할 수 있는 지능화된 고장검출 및 진단 알고리즘의 개발이 요구되고 있다. 더욱이 일반 보급형 냉방 시스템에서 고가의 센서를 사용하여 고장을 검출하고 진단하는 방법은 그 경제적 비용으로 인해 실효 가능성이 희박하기 때문에 비교적 저가의 센서 사용이 가능한 온도 및 압력 등을 사용하여 고장을 검출하고 진단하는 방법에 더욱 많은 연구가 요구된다.

고장검출 및 진단에 관한 연구는 지속적으로 수행되어 왔으며 최근 Braun et al.^(1,2)은 소형 냉방기에 관한 고장별 비용조사를 통해 고장검출의 필요성과 고장에 따른 시스템 파라미터의 변화 경향을 연구하였으며 McIntosh et al.⁽³⁾은 정확한 수학적 모델을 이용한 고장검출 및 진단방법에 대한 연구를 진행하였으나 실시간 적용에는 많은

문제점을 내포하고 있다. Frank⁽⁴⁾는 인공신경망이 자기학습과 패턴분류 능력을 가지고 있기 때문에 고장검출 및 진단에 이용 가능하다고 주장하였으며 Ch'ng et al.⁽⁵⁾은 신경망 이론을 이용하여 전자제품 생산라인에서 제품의 고장을 분류하는 연구를 수행하였다.

본 연구에서는 자기학습기능을 갖는 신경망과 데이터 전처리기법을 사용하여 5RT 용량의 멀티형 냉방기⁽⁶⁾의 실시간 고장검출 시스템을 구축한 후 실험을 통하여 개발된 고장검출 기술의 성능을 확인하는 것을 목적으로 한다.

2. 고장모사장치

고장모사장치로는 고장검출 및 진단 알고리즘의 타당성을 확인하기 위해 5RT 용량의 멀티형 냉방기를 고장모사장치로 변환하여 사용하였으며 실험에 요구되는 환경조성을 위하여 실외조건 및 실내조건을 제어할 수 있는 실외 및 실내 환경 챔버를 사용하였다.

Fig. 1은 고장모사 실험에 사용한 멀티형 냉방 시스템의 구조를 나타낸다. 그림과 같이 시스템은 압축기, 응축기, 응축기 팬, 유분리기, 액분리기, 수액기를 포함한 한 대의 실외기와 전자팽창밸브, 증발기, 증발기 팬을 포함한 네 대의 실내기로 구성되었다. 냉방기의 다양한 고장 중 응축기 오염과 증발기 팬 고장을 본 연구에서는 고려하였다. 응축기 오염이란 실외에 설치된 응축기 표면에 먼지나 낙엽과 같은 이물질이 부착되어 응축기 전열면적이 감소되는 현상을 말하며 냉방 성능 및 열교환 능력을 저하시킨다. 이 실험은

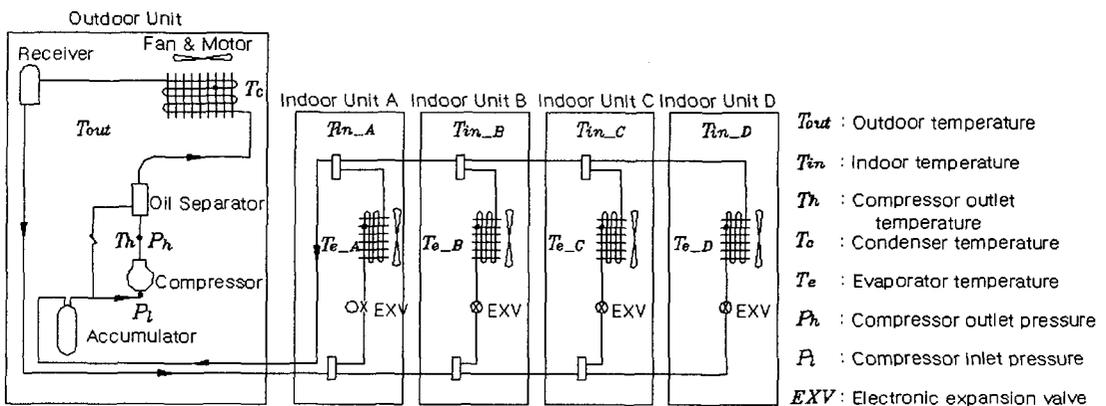


Fig. 1 Fault simulating device.

최초 오염이 없는 경우의 전체 전열면적을 측정 한 후 전열면적을 일정비율씩 차단하여 수행하였다. 증발기 팬 고장이란 증발기 팬의 성능저하로 풍량이 감소하는 현상으로 고장모사방법은 각 실내기 팬의 풍량을 조정하여 실험을 수행하였다.

고장모사장치에 부착된 온도센서와 압력센서의 위치가 Fig. 1에 표시되었으며 데이터 획득장치를 사용하여 데이터를 수집하였다. 온도측정을 위해 사용된 센서는 T형 열전대를 사용하였으며 압력측정은 압력변환기를 사용하였다.

3. 고장검출 시스템

냉방기의 고장검출 시스템에서 사용한 방법은 모델기반방법으로써 신경망을 사용하였다. Fig. 2는 고장검출 시스템을 나타내며 입력부, 데이터 전처리부, 신경망 알고리즘부, 출력부로 구성하였다. 입력값으로 5개의 온도와 2개의 압력을 사용하였으며 신경망 알고리즘을 통해 결정된 고장은 무고장, 응축기 오염고장, 증발기 팬 고장으로 분류하였다.

3.1 입력 데이터

학습을 위한 입력 데이터로 실외습도와 실내습

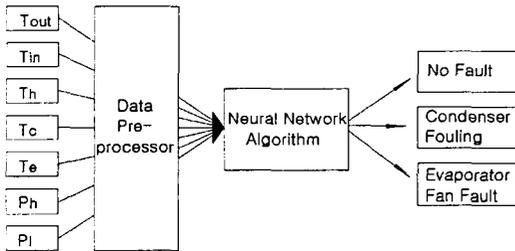


Fig. 2 Fault detection scheme.

Table 1 No fault data set

| | Set1 | Set2 | Set3 | Set4 | Set5 |
|-----------|--------|--------|--------|--------|--------|
| T_{out} | 36.43 | 36.43 | 36.43 | 36.43 | 36.43 |
| T_{in} | 16.77 | 21.31 | 24.50 | 28.89 | 32.49 |
| T_h | 108.01 | 112.86 | 114.22 | 115.49 | 117.89 |
| T_c | 44.65 | 45.16 | 45.52 | 45.44 | 45.90 |
| T_e | 0.86 | 2.53 | 3.47 | 5.00 | 6.05 |
| P_h | 17.63 | 17.80 | 17.89 | 17.92 | 18.05 |
| P_l | 3.35 | 3.47 | 3.56 | 3.68 | 3.73 |

도가 41%, 50%이고, 실외온도가 25~40℃, 실내 온도가 21~37℃일 때의 압축기 출구온도, 응축 온도, 증발온도, 압축기 출구압력, 압축기 흡입압력을 각각 18개 데이터 세트로 구성하여 사용하였다.⁽⁷⁾ Table 1, Table 2, Table 3에 무고장, 응축기 오염(30%), 증발기 팬 고장(25%)에 대한 각 18개의 학습 데이터 세트 중 5개의 데이터 세트를 보여준다.

3.2 데이터 전처리부

입력값에 포함된 노이즈의 영향을 축소시키기 위하여 입력부 뒤에 데이터 전처리부분을 추가하여 측정값을 직접 알고리즘부에 입력하지 않고 데이터 전처리부를 통과한 후 사용하였다. 전처리부분에 사용된 방법은 이동 평균(Moving average) 기법을 사용하였으며 본 실험에서는 13초마다 측정된 5개의 측정값을 이동 평균하여 사용하였다.

3.3 신경망 알고리즘

Fig. 3은 고장검출 시스템에 사용된 신경망의 구성을 나타낸다. 여기서 T_{out} , T_{in} , T_h , T_c , T_e ,

Table 2 Condenser fouling data set

| | Set1 | Set2 | Set3 | Set4 | Set5 |
|-----------|--------|--------|--------|--------|--------|
| T_{out} | 36.18 | 36.18 | 36.18 | 36.18 | 36.18 |
| T_{in} | 17.71 | 21.33 | 25.39 | 28.56 | 31.88 |
| T_h | 109.26 | 115.72 | 120.65 | 122.19 | 123.28 |
| T_c | 45.89 | 47.08 | 47.73 | 47.24 | 47.25 |
| T_e | 0.87 | 2.08 | 3.26 | 3.84 | 4.71 |
| P_h | 18.14 | 18.66 | 19.00 | 18.80 | 18.80 |
| P_l | 3.35 | 3.49 | 3.56 | 3.63 | 3.68 |

Table 3 Evaporator fan fault data set

| | Set1 | Set2 | Set3 | Set4 | Set5 |
|-----------|-------|-------|-------|-------|--------|
| T_{out} | 35.36 | 35.36 | 35.36 | 35.36 | 35.36 |
| T_{in} | 18.11 | 21.68 | 26.00 | 29.84 | 33.23 |
| T_h | 96.23 | 95.83 | 96.24 | 99.05 | 100.46 |
| T_c | 41.81 | 42.02 | 42.35 | 43.50 | 43.50 |
| T_e | -3.88 | -3.47 | -2.39 | -1.08 | -0.40 |
| P_h | 16.30 | 16.37 | 16.53 | 16.98 | 17.27 |
| P_l | 2.68 | 2.69 | 2.76 | 2.87 | 2.96 |

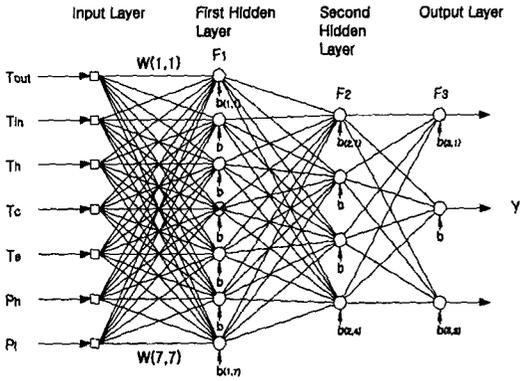


Fig. 3 Neural network architecture.

P_h, P_l 은 각각의 입력 데이터를, F 는 활성화함수 (Activation function)를 나타낸다. 신경망 구조는 입력층과 2개의 은닉층 그리고 출력층으로 구성하였다. 첫번째 은닉층은 7개의 뉴런과 탄젠트-시그모이드 활성화함수를 사용하였으며, 두번째 은닉층은 4개의 뉴런과 로그-시그모이드 활성화함수를 사용하였다. 출력층은 3개의 뉴런과 선형 활성화함수를 사용하였다.

3.4 신경망 학습

신경망 알고리즘의 학습은 무고장, 응축기 오염고장, 증발기 팬 고장 실험을 통해 측정된 데이터를 사용하였으며 연결강도와 바이어스의 조정을 위해 역전파 학습 알고리즘을 사용하였다. Fig. 4는 학습에 사용된 역전파 알고리즘의 진행

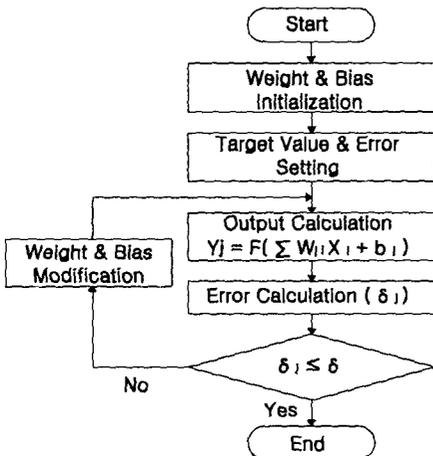


Fig. 4 Back-propagation algorithm.

과정을 나타낸다. 먼저 연결강도와 바이어스를 초기화한 후 목표값과 허용오차를 설정한다. 활성화함수를 사용하여 출력값을 계산한 후 오차 δ_j 를 계산하고 허용오차 δ 이하가 되도록 연결강도와 바이어스를 변화시켜 가며 학습을 반복한다. 출력값이 허용오차 이하로 수렴하면 학습은 멈추게 된다. 허용오차 범위는 10^{-3} 으로 설정하였다. 신경망 알고리즘을 학습시키기 위하여 무고장은 $[1 \ 0 \ 0]^T$, 응축기 오염은 $[0 \ 1 \ 0]^T$, 증발기 팬 고장은 $[0 \ 0 \ 1]^T$ 가 되도록 목표값을 설정하였다.

4. 고장검출 시스템 검증

고장검출 시스템 검증을 위해서 멀티형 냉방기에 대한 실시간 고장검출 실험을 수행하였다. 실험조건은 실외온도와 상대습도를 35℃, 41%, 실내온도와 상대습도를 24℃, 50%로 설정하였다.

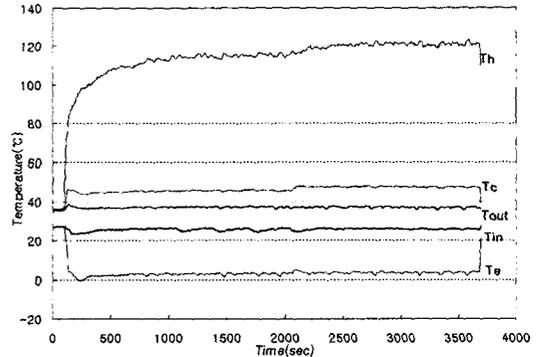


Fig. 5 Various temperatures at 30% condenser fouling.

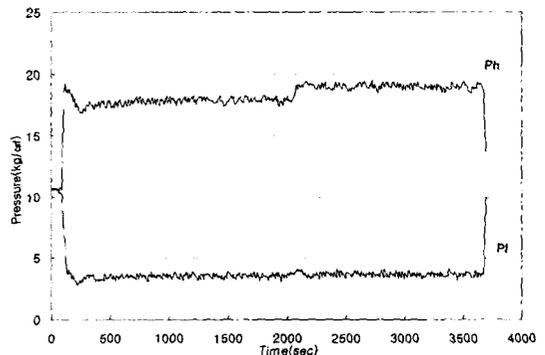


Fig. 6 Various pressures at 30% condenser fouling.

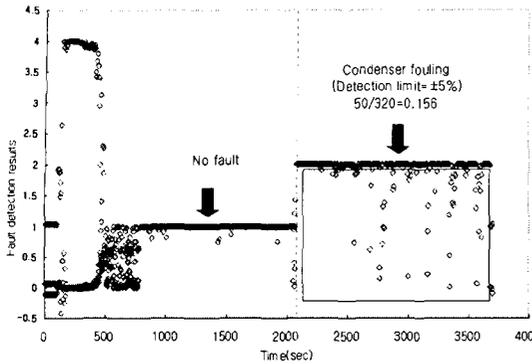


Fig. 7 Fault detection results at 30% condenser fouling without data preprocessing.

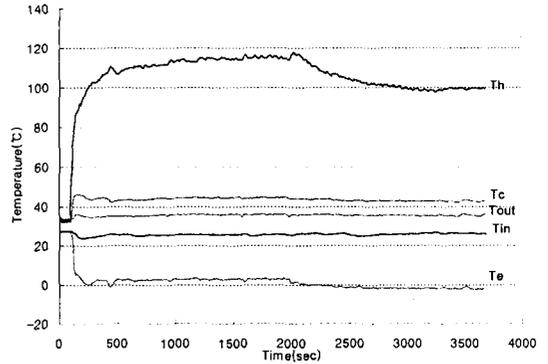


Fig. 9 Various temperatures at 25% evaporator fan fault.

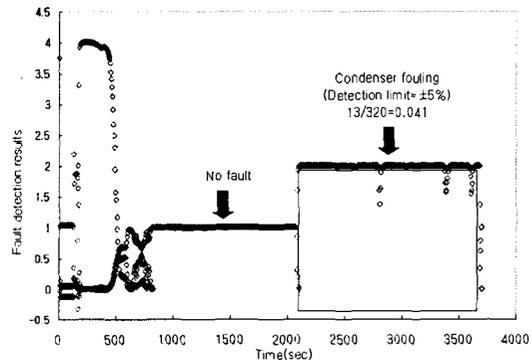


Fig. 8 Fault detection results at 30% condenser fouling with data preprocessing.

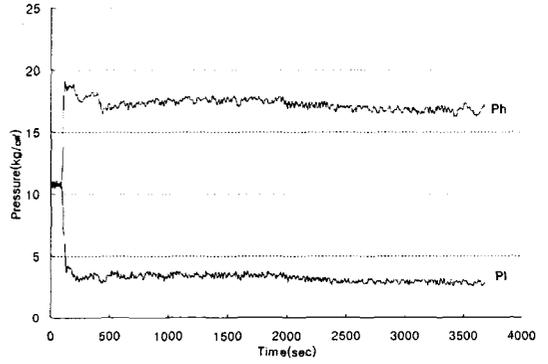


Fig. 10 Various pressures at 25% evaporator fan fault.

Fig. 5와 Fig. 6은 응축기 오염모사 실험결과로 측정된 각종 온도와 압력값을 나타낸다. Fig. 7은 데이터 전처리기법을 사용하지 않은 경우의 검출 결과로 검출결과를 표시하기 위하여 $[2^0 \ 2^1 \ 2^2] \cdot [F_{31} \ F_{32} \ F_{33}]^T$ 와 같이 계산하여 신경망을 통한 결과가 $[1 \ 0 \ 0]^T$ 일 경우 $[2^0 \ 2^1 \ 2^2] \cdot [1 \ 0 \ 0]^T$ 이므로 “1”로, $[0 \ 1 \ 0]^T$ 일 경우 “2”로, $[0 \ 0 \ 1]^T$ 일 경우 “4”로 나타내었다. 약 500초 근방까지는 고장모사 장치와 실외 및 실내 환경조성 챔버가 주어진 환경조건을 모사하기 위한 과도영역이며 실험의 신뢰성을 높이기 위해 충분한 시간이 경과한 후 1,000초 이후부터 무고장 실험을, 2,000초 이후부터 고장실험을 실시하였으며 그림에서와 같이 2,100초부터 고장을 검출하기 시작하였다. Fig. 8은 데이터 전처리기법을 사용한 후의 고장검출 결과를 나타내고 있다. 2,100초에서 3,600초까지 320회에 걸쳐 고장 여부를 진단한 결과 그림에

나타낸 윈도우 영역으로 표시된 것과 같이 데이터 전처리기법을 사용한 후 고장검출 영역의 $\pm 5\%$ 범위를 벗어난 경우가 50회에서 13회로 감소함으로써 84.4%에서 95.9%로 고장검출 성능이 개선됨을 확인할 수 있었다.

Fig. 9와 Fig. 10은 증발기 팬 고장 모사실험결과로 측정된 각종 온도와 압력값을 보여주며, Fig. 11과 Fig. 12는 검출결과를 나타낸다. 시스템이 안정된 후 2,200초부터 3,500초까지 283회에 걸쳐 고장 여부를 진단한 결과 그림에 나타낸 윈도우 영역으로 표시된 것과 같이 데이터 전처리기법을 사용한 후 고장검출 영역의 $\pm 5\%$ 범위를 벗어난 경우가 5회에서 0회로 감소함으로써 98.2%에서 100%로 고장검출 성능이 개선됨을 확인할 수 있었다.

Fig. 13과 Fig. 14는 무고장, 응축기 오염, 무고장, 증발기 팬 고장을 단계별로 수행한 연속 고

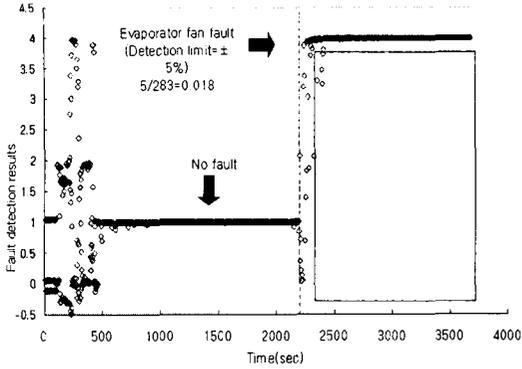


Fig. 11 Fault detection results at 25% evaporator fan fault without data preprocessing.

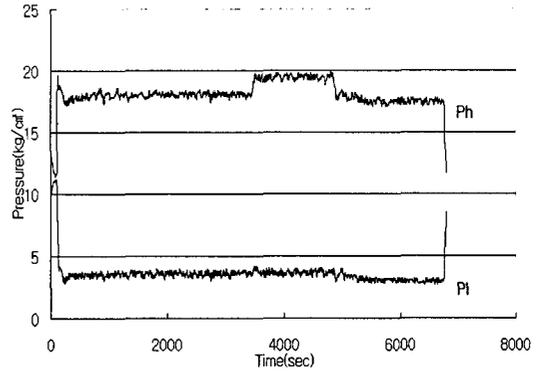


Fig. 14 Various pressures at 30% condenser fouling and 25% evaporator fan fault.

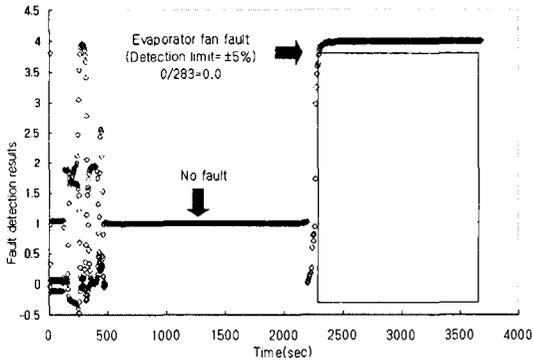


Fig. 12 Fault detection results at 25% evaporator fan fault with data preprocessing.

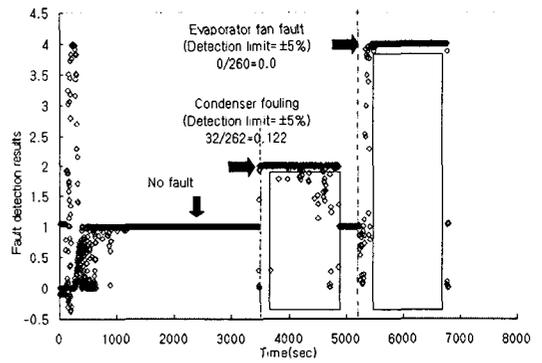


Fig. 15 Fault detection results at 30% condenser fouling and 25% evaporator fan fault without data preprocessing.

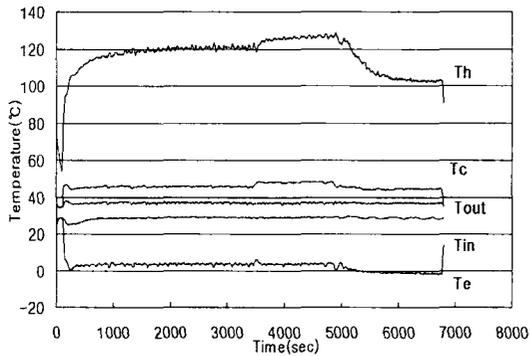


Fig. 13 Various temperatures at 30% condenser fouling and 25% evaporator fan fault.

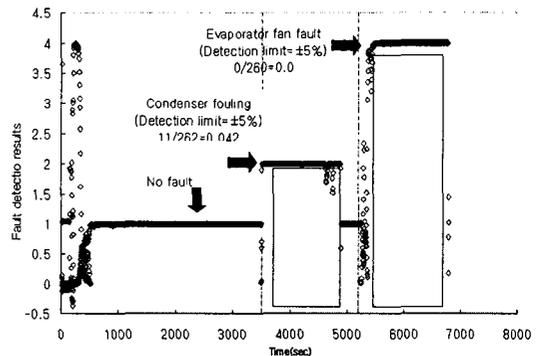


Fig. 16 Fault detection results at 30% condenser fouling and 25% evaporator fan fault with data preprocessing.

장검출 실험에서 측정된 각종 온도와 압력값을 나타내며, Fig. 15와 Fig. 16에는 검출결과를 나타낸다. 1,000초에서 시스템이 안정화된 후 3,500초까지를 무고장 실험, 3,500초에서 4,800초까지를 응축기 오염 실험, 4,800초에서 5,200초까지 무고장 실험, 5,200초에서 6,700초까지를 증발기 팬 고장 순으로 수행하였다. 응축기 오염의 경우 3,700초에서 4,800초까지 262회에 걸쳐 고장 여부를 진단한 결과 데이터 전처리기법을 사용한 후 고장검출 영역의 $\pm 5\%$ 범위를 벗어난 경우가 32회에서 11회로 감소함으로써 87.8%에서 95.8%로 고장검출 성능이 개선되었으며 증발기 팬 고장의 경우 5,400초에서 6,700초까지 260회에 걸쳐 고장 여부를 진단한 결과 고장검출 영역의 $\pm 5\%$ 범위를 벗어난 경우가 없는 것으로 나타났다.

5. 결 론

냉방기에 발생할 수 있는 고장 중 응축기 오염과 증발기 팬 고장에 대해서 신경망 알고리즘과 데이터 전처리기법을 적용한 고장검출 성능실험을 수행하였다. 고장검출 시스템의 학습을 위해 실외온도조건을 25~40℃까지 변화시키고 실내온도를 21~37℃까지 변화시키면서 이에 따른 압축기 출구온도, 응축온도, 증발온도, 압축기 출구압력, 압축기 흡입압력을 입력변수로 선정하였다.

학습된 신경망을 적용한 고장검출 시스템을 실험을 통해 확인한 결과 데이터 전처리기법을 사용하지 않은 경우보다 전처리기법을 사용한 경우가 검출성능이 현저히 향상됨을 확인하였다.

따라서 개발된 신경망 알고리즘을 더욱 확대하여 냉방 시스템의 다른 고장검출에 사용할 경우

효과적인 고장검출이 가능하며 적절한 데이터 전처리기법을 추가함으로써 더욱 효과적인 고장검출이 이뤄질 것으로 기대된다.

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. Chen, B. and Braun, J. E., 2001, Simple rule-based methods for fault detection and diagnostics applied to packaged air conditioners, ASHRAE Transactions 2001, V. 107, Pt. 1.
3. 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.
4. 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.
5. Ch'ng, C. G. and Yak, A. S., 1998, Neural networks for process diagnosis, ICARCV, pp. 494-498.
6. Han, D. and Lee, H., 1999, The development of multi heat pump, Ministry of Commerce, Industry and Energy.
7. Han, D. and Yoon, T., 2000, Partial fault response of multi-type air conditioner, Proceedings of the SAREK, pp. 319-323.