

정규화 입력을 사용한 신경망 알고리즘에 의한 냉동기의 부분 고장 검출

한 도 영[†], 황 정 욱^{*}

국민대학교 기계·자동차공학부, *국민대학교 기계공학과 대학원

The Partial Fault Detection of an Air-Conditioning System by the Neural Network Algorithm using Normalized Input Data

Doyoung Han[†], Junguk Hwang^{*}

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

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

(Received August 24, 2002; revision received January 16, 2003)

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. To detect partial faults of the air-conditioning system, a neural network algorithm may be used. In this study, the neural network algorithm using normalized input data by the standard deviation was applied. And the $[7 \times 10 \times 10 \times 1]$ neural network structure was selected. Test results showed that the neural network algorithm using normalized input data was very effective to detect the condenser fouling and the evaporator fan fault of an air-conditioning system.

Key words: Neural network algorithm(신경망 알고리즘), Fault detection system(고장 검출 시스템), Condenser fouling(응축기 오염), Evaporator fan fault(증발기 팬 고장), Standard deviation(표준편차), Normalized input data(정규화 입력 데이터)

기 호 설 명

a : 은닉층의 뉴런값

P : 입력값

P_h : 압축기 출구압력 $[\text{kg}/\text{cm}^2]$

P_l : 압축기 입구압력 $[\text{kg}/\text{cm}^2]$

PN : 정규화 입력값

T_c : 응축온도 $[\text{°C}]$

T_e : 증발온도 $[\text{°C}]$

T_h : 압축기 출구온도 $[\text{°C}]$

T_{in} : 실내온도 $[\text{°C}]$

T_{out} : 실외온도 $[\text{°C}]$

W : 연결강도

그리스 문자

θ : 바이어스

하첨자

i : 신경망의 입력층(Input layer)

j : 신경망의 첫번째 은닉층(Hidden layer)

k : 신경망의 두번째 은닉층(Hidden layer)

l : 신경망의 출력층(Output layer)

[†] Corresponding author

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

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

1. 서 론

최근에 냉동기 보급이 보편화되어 전력수요가 증가되면서 냉동기의 신뢰성과 정격용량 성능향상에 관해서 많은 연구가 진행되고 있으나 냉동기 부품의 부분 고장 발생으로 인한 성능저하에 관해서는 인식도 부족하고 연구도 매우 부족한 현실이다. 냉동기의 부분 고장을 조기에 검출하고 진단함으로써 쓸데없는 에너지 소비를 억제하고 냉동기에 추후 발생될 심각한 고장을 미연에 방지하여 줌으로써 사용자에게 불편과 경제적인 부담을 최소화시킬 수 있게 된다. 이를 위해 지능화된 고장 검출 및 진단 알고리즘의 개발이 요구되고 있다. 많은 센서와 고가의 센서를 사용하여 고장을 검출하고 진단하는 방법은 초기 투자비가 증가하므로 가능하면 비교적 적은 수로 저가의 센서를 사용하여 고장을 검출하고 진단하는 방법이 필요하며 이에 관한 많은 연구가 요구된다.

공조냉동 분야 이외의 타분야에서 고장 검출 및 진단에 관한 연구는 활발히 지속적으로 수행되어 왔으며, Frank et al.⁽¹⁾는 자기학습과 패턴분류 능력을 갖고 있는 신경망을 고장 검출 및 진단 알고리즘으로 이용함으로써 신경망의 사용 가능성을 보였고 Ch'ng et al.⁽²⁾은 신경망 이론을 사용하여 전자제품 생산라인의 제품 고장 패턴을 분류하는 연구를 수행하였다. 공조시스템 분야에서는 IEA(International Energy Agency)의 Annex 25⁽³⁾와 Annex 34 등에서 공조기의 고장 검출 및 진단에 대하여 집중적인 연구를 수행하였고, 특

히 Peitsman et al.^(4,5)은 ARX와 인공신경망을 적용한 블랙박스 모델을 사용하여 공조기의 고장 감지를 시도하였다. 냉동시스템 분야에서는 Braun et al.^(6,7)이 부분 고장으로 오는 에너지 손실과 부분 고장이 일어날 경우 각종 측정 변수에 미치는 영향에 대해서 연구하였고, McIntosh⁽⁸⁾는 수학적 모델을 사용하여 고장을 검출하고 진단하는 방법에 대해서 연구하였다. 또한 Han⁽⁹⁾은 냉동기의 고장 검출과 진단 방법을 제시하고 부분 고장에 대한 시스템의 반응⁽¹⁰⁾을 연구하였으며, 특히 고장 검출을 위하여 곡선 적합 모델,⁽¹¹⁾ 퍼지 알고리즘,⁽¹²⁾ 그리고 신경망 알고리즘을 적용⁽¹³⁾하였으며 모델기반 방법과 신경망 알고리즘에 데이터 전처리 기법^(14,15)을 사용하여 냉동기의 고장 검출과 진단의 신뢰도를 향상시켰다. 하지만 냉동시스템의 복잡성과 비선형성 때문에 고장 및 진단의 정도가 떨어지고 따라서 이를 개선하기 위하여 현재도 연구가 활발히 진행되고 있다.

냉동시스템의 실시간 고장 검출 방법을 개선하기 위하여 본 논문에서는 신경망 알고리즘⁽¹⁶⁾에 정규화된 입력을 사용하는 방법을 개발하였으며, 개발된 알고리즘을 5RT 용량의 멀티형 냉방기⁽¹⁷⁾에 적용하여 냉방기 부분 고장 검출 정도를 확인하였다.

2. 고장모사 실험장치

고장모사에 사용된 실험장치는 Fig.1에 보여 주듯이 한 대의 실외기와 네 대의 실내기를 갖는

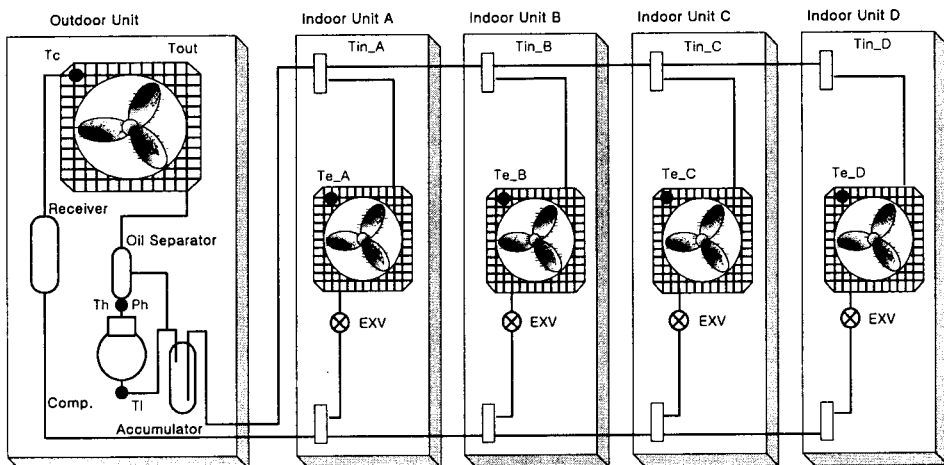


Fig. 1 Fault simulator.

멀티형 냉방기로서 본 연구에서는 냉방기의 고장 중 열교환기 부분 고장인 응축기 부분 오염과 증발기 팬 부분 고장을 선택하였다.

응축기 오염은 실외에 설치된 응축기 표면에 먼지나 낙엽 같은 이물질이 부착되어 응축기 전 열면적이 감소되어 냉방성능이 저하되는 현상으로써 응축기 오염을 모사하기 위하여 공기 오염이 없는 경우의 열교환 면적을 측정한 후 전체 열교환 면적을 일정 비율 차단하여 모사실험을 수행하였다. 증발기 팬 고장은 실내기 팬의 부분 고장을 의미하며 각 실내기 팬의 풍량을 조정하여 모사실험을 실시하였다.

3. 고장 검출 시스템

신경망에서 일반적으로 사용하는 입력방법은 입력을 그대로 사용하는 방법과 입력을 수정 후 사용하는 방법으로 분류할 수 있으며 수정 후 사용하는 방법에는 입력의 증가나 감소에 따라 ± 1 로 단순화하는 방법, 입력의 크기를 조정하는 방법, 입력이 ± 1 사이의 값을 갖도록 하는 방법 등이 있다. 본 논문에서는 냉동기의 고장을 검출하기 위하여 Fig.2와 같이 입력을 수정한 후 사용하는 방법 중에서 온도와 압력으로 구성되어 유닛숫자가 서로 다른 입력의 크기를 조정하기 위해서 평균과 표준편차를 사용하여 정규화한 입력 데이터를 사용하였으며 2개의 은닉층으로 구성된 신경망 알고리즘을 사용하여 무고장, 응축기 오염, 증발기 팬 고장을 구분하여 고장을 검출하였다.

3.1 입력

고장을 검출하기 위하여 신경망에서 사용하는




Fig. 2 Fault detection system.

입력 변수로 실외온도 T_{out} , 실내온도 T_{in} , 압축기 출구온도 T_h , 응축기온도 T_c , 증발기온도 T_e 등 5개의 온도와 압축기 출구압력 P_h , 압축기 입구압력 P_l 등 2개의 압력을 선택하였다.

각 고장에 대해서 각 입력 변수값의 상대적인 변동 크기에 따른 영향을 감소하기 위하여 입력 변수값을 각 입력 변수의 표준편차를 사용하여 다음 식으로 정규화하였으며

$$PN_i = \left(\frac{P_i - \text{mean}P_i}{\text{std}P_i} \right) \quad (1)$$

여기서 P_i 는 입력값, $\text{mean}P_i$ 는 무고장과 고장에 대한 전체 입력값의 평균, $\text{std}P_i$ 는 무고장과 고장에 대한 전체 입력값의 표준편차, PN_i 는 정규화된 입력값을 의미한다.

3.2 신경망

고장 검출에 사용된 신경망 구조가 Fig.3에 보여준다. 신경망은 각 고장에 따라 입력층과 2개의 은닉층, 그리고 출력층으로 구성된 $[7 \times 10 \times 10 \times 1]$ 구조의 다층퍼셉트론⁽¹⁸⁾을 사용하였다. 입력으로 T_{out} , T_{in} , T_h , T_c , T_e , P_h , P_l 등 7개의 변수를 선택하였으며 출력으로 무고장은 '0', 응축기 30% 오염은 '1', 증발기 팬 25% 고장은 '-1'로 정의하였다. 각 뉴런의 출력값은 다음 식에서 계산할 수 있으며

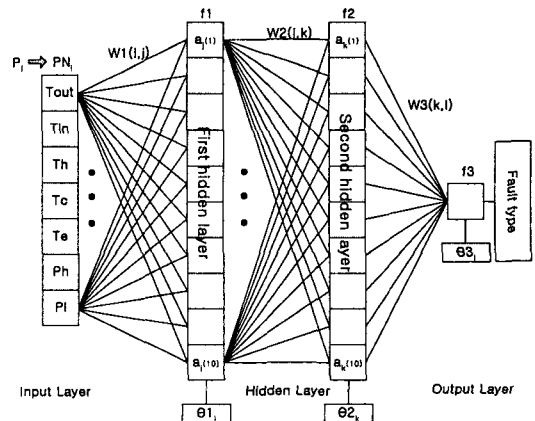


Fig. 3 Neural network architecture.

$$a_j = f_1 \left(\sum_{i=1}^7 W1(i,j) PN_i + \theta1_j \right) \quad (2a)$$

$$a_k = f_2 \left(\sum_{j=1}^{10} W2(j,k) a_j + \theta2_k \right) \quad (2b)$$

$$\text{Fault type} = f_3 \left(\sum_{k=1}^{10} W3(k,l) a_k + \theta3_l \right) \quad (2c)$$

여기서, W 는 연결강도, θ 는 바이어스, f 는 활성화 함수, a_j 는 첫번째 은닉층의 뉴런값, a_k 는 두번째 은닉층의 뉴런값, Fault type은 최종 출력값으로 고장형태를 의미한다.

4. 고장 검출 결과

4.1 학습 데이터

신경망 학습에 필요한 데이터를 수집하기 위하여 무고장, 응축기 30% 오염, 증발기 팬 25% 고장에 대한 고장 모사실험을 실시하였으며 KS규격에 의한 저온조건, 표준조건, 과부하 조건 등 냉동기의 적용범위 전체를 고려하여 선정한 실험의 실외 및 실내온도 조건이 Table 1에 나타나 있다. 이를 기본 데이터로 보다 많은 학습 데이터를 확보하기 위해 Table 1의 조건 외의 다른 온도조건에 대해서도 데이터를 선형이라 가정하고 보간법을 사용하여 학습 데이터를 획득하여 사용하였다.

Table 2는 신경망 알고리즘의 학습을 위해 사용된 정규화된 입력 데이터의 한 예로 실외온도 35℃와 실내온도 29℃에서의 무고장과 두 가지 고장에 따른 7개 입력값의 정규화 전과 정규화 후의 값을 보여주며 입력 데이터는 평균과 표준

Table 1 Test conditions

	Outdoor	25℃	30℃	35℃	40℃
Indoor					
17℃		•	•	•	•
21℃		•	•	•	•
25℃		•	•	•	•
29℃			•	•	•
33℃				•	•
37℃					•

편차를 사용하여 정규화함으로써 각종 입력값이 온도와 압력의 크기에 관계없이 비슷한 크기로 정규화됨을 확인할 수 있었다.

4.2 검출 결과

학습된 고장 검출 신경망 알고리즘의 고장 검출 결과를 확인하기 위하여 무고장, 응축기 30% 오염, 증발기 팬 25% 고장에 대하여 실험을 실시하였다.

Fig. 4와 Fig. 5는 고장 모사실험 장치로부터 획득한 온도와 압력을 나타내고, Fig. 6은 측정값을 그대로 사용했을 때의 검출 결과이며, Fig. 7은 정규화 입력을 사용했을 때의 검출 결과를 나타낸다. 실험 시작 후 1000초가 지나서 시스템이 정상상태로 되었다고 가정하여 1000초에서 3400초까지 무고장 실험, 3600초에서 4800초까지 응축기 30% 오염 실험을 실시한 후, 5200초까지 무고장으로 유지하다가, 5400초에서 6700초까지 증발기 팬 25% 고장 실험을 수행하였다. 고장 검출 영역은 ±5%로 선택하여 사용하였다. Fig. 6과 Fig. 7에서 보듯이 입력값을 그대로 사용하여 진단한 경우와 정규화값을 사용하여 진단한 경우의

Table 2 Normalized input data

	Original inputs			Normalized inputs		
	No fault	Condenser fouling	Evaporator fault	No fault	Condenser fouling	Evaporator fault
T_{out}	36.43	36.18	35.36	0.3092	0.263	0.1116
T_{in}	28.89	28.56	29.28	0.7241	0.6674	0.8874
T_h	115.5	122.2	99.05	0.5032	0.9833	-0.675
T_c	45.44	47.24	43.5	0.2896	0.5921	-0.036
T_e	5	3.84	-1.08	1.2098	0.8769	-0.535
P_h	17.92	18.8	16.98	0.2375	0.6196	-0.171
P_l	3.68	3.63	2.87	0.9952	0.8854	-0.783




Fig. 4 Temperature readings.




Fig. 6 Detection results using original inputs.




Fig. 5 Pressure readings.




Fig. 7 Detection results using normalized inputs.

진단 결과를 비교한 결과 무고장의 경우는 94%에서 100%로, 응축기 오염의 경우는 87.2%에서 100%로, 증발기 팬 고장의 경우는 99.6%에서 97.5%로 정규화 입력을 사용한 경우가 상대적으로 더 정확히 검출됨을 확인하였다.

신경망 구조가 고장 검출 결과에 미치는 영향을 확인하기 위해 Table 3과 같은 다른 구조의 신경망을 사용하여 검출 정도를 확인하였다. 여기서 신경망 구조의 첫번째 숫자는 입력층의 뉴런

수, 마지막 숫자는 출력층의 뉴런수, 입력층과 출력층 사이의 숫자는 은닉층의 뉴런수를 나타낸다. 실험 결과 신경망 구조가 [7×10×10×1]일 때 검출 정확도가 99.2%로 가장 높게 나타났으며 은닉층의 뉴런수가 너무 적거나 또는 너무 많아도 좋은 검출 결과를 얻을 수 없음을 확인하였다.

5. 결론

냉동기의 응축기 오염과 증발기 팬 고장을 검출하기 위하여 신경망 알고리즘을 사용하였다.

신경망 알고리즘의 학습을 위한 입력 데이터를 수집하기 위하여 먼저 과부하 조건, 표준 조건, 저온 조건을 포함한 18개의 조건에 대한 실험을 실시하여 입력 데이터를 얻었으며, 각 입력 데이터에 대해서 평균값과 표준편차를 얻은 후 이를 사용하여 정규화함으로써 정규화된 입력 데이터를 수집하였다. 그외 조건에서의 학습을 위한 입력 데이터를 추가하기 위하여 보간법을 사용하였다.

Table 3 Detection results

Neural network structure	Detection rate (%)			
	No fault	Condenser fouling	Evaporator fault	Average
7×4×1	99.2	0	0	33.1
7×7×4×1	99.6	94.8	90.7	95
7×10×10×1	100	100	97.5	99.2
7×20×20×1	10	3.6	57.9	23.8

수집된 학습 입력 데이터를 그대로 사용한 경우와 평균과 표준편차를 이용하여 정규화시켜 사용한 경우에 대하여 신경망을 각각 학습시켰으며 학습된 신경망 알고리즘을 사용하여 고장 검출 시험을 시행하였다.

학습된 신경망 알고리즘을 사용하여 무고장, 응축기 30% 오염, 증발기 펜 25% 고장에 대한 고장 검출 시험을 시행한 결과 정규화된 입력값을 사용한 신경망이 정규화되지 않은 입력값을 사용한 신경망에 비해 고장 검출에 상대적으로 효과적임을 확인할 수 있었다. 또한 신경망 구조에 따른 검출의 정확도를 확인하기 위하여 다양한 구조에 대해서 시험을 실시한 결과 $[7 \times 10 \times 10 \times 1]$ 의 구조가 상대적으로 고장 검출에 효과적임을 확인하였다.

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. Ch'ng, C. G. and Yak, A. S., 1998, Neural networks for process diagnosis, *ICARCV*, pp. 494-498.
3. Hyvariene, J. and Kohonen, R., 1996, Building optimization and fault diagnosis system, *Report of IEA Annex 25, VTT Building Technology*.
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. 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.
7. Chen, 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.
8. McIntosh, I. B. D., Mitchell, J. W. and Beckman, W. A., 2000, Fault detection and diagnosis in chillers, *ASHRAE Transactions*, Vol. 106, Pt. 2, Paper # 4395.
9. Han, D. and Ha, S., 2000, A study on the fault detection and diagnosis method for the air conditioner, *Proceedings of the SAREK Summer Annual Conference*, Vol. 3, pp. 1408-1412.
10. Han, D. and Yoon, T., 2000, Partial fault response of multi-type air-conditioner, *Proceedings of the SAREK Winter Annual Conference*, Vol. 1, pp. 319-323.
11. Han, D. and Lee, H., 2001, Partial fault detection of the air-conditioning system by using curve fitting model, *Proceedings of the SAREK Summer Annual Conference*, Vol. 2, pp. 670-674.
12. 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.
13. Han, D. and Yoon, T., 2001, Fault detection of the condenser and the evaporator fouling by using neural network algorithm, *Proceedings of the SAREK Summer Annual Conference*, Vol. 2, pp. 675-679.
14. Han, D. and Lee, H., 2002, Partial fault detection of an air-conditioning system by using the model-based method with data preprocessing, *Proceedings of the SAREK Summer Annual Conference*, Vol. 1, pp. 295-300.
15. 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.
16. Han, D. and Hwang, J., 2002, The partial fault detection of an air-conditioning system by the normalized input neural network algorithm, *Proceedings of the SAREK Sum-*

- mer Annual Conference, Vol. 3, pp. 1457-1462.
17. Han, D. and Lee, H., 1999, The development of multi heat pump, Ministry of Commerce, Industry and Energy.
18. Simon, H., 1999, Neural networks a comprehensive foundation, 2nd ed., Prentice-Hall, pp. 156-255.