

신경망 이용 공조기 고장검출 및 진단

이 원 용[†], 경 남 호

한국에너지기술연구원

Fault Detection and Diagnosis for an Air-Handling Unit Using Artificial Neural Networks

Won-Yong Lee[†], Nam-Ho Kyong

Korea Institute of Energy Research, Taejeon 305-343, Korea

(Received July 4, 2001; revision received November 9, 2001)

ABSTRACT: A scheme for on-line fault detection and diagnosis of an air-handling unit is presented. The fault detection scheme uses residuals which are generated by comparing each measurement with analytical redundancies computed from the reference models. In this paper, artificial neural networks (ANNs) are used to estimate analytical redundancy and to classify faults. The Levenburg-Marquardt algorithm is used to train feed forward ANNs that provide estimates of continuous states and diagnosis results. The simulation result demonstrated that the ANNs can effectively detect and diagnose faults in the highly non-linear and complex HVAC systems.

Key words: Fault detection(고장검출), Model-based(모델기반), Air-handling unit(공조기)

기 호 설 명

b : 신경망 바이어스
 H : 공기습도(건조공기) [kg/kg]
 P : 압력 [Pa]
 Q : 공기유량 [m^3/s]
 R : 잔차(residual) 또는 관계(relation)
 T : 온도 [$^{\circ}C$]
 U : 제어신호

그리스 문자

ω : 신경망 연결 가중치

하첨자

cc : 냉각코일온도 제어밸브
 ci : 회수 순환공기
 d : 급기 및 순환공기 차
 dmp : 혼합공기 댐퍼
 es : 예측값
 fr : 외기
 m : 혼합공기
 p : 압력
 re : 순환공기
 s : 급기

1. 서 론

건물 공조설비를 비롯한 에너지 설비의 규모가 커지고 구성이 복잡해짐에 따라 운전자가 전체 시스템을 이해하여 운영하기가 어려워지고 있으

[†] Corresponding author

Tel.: +82-42-860-3574; fax: +82-42-860-3739

E-mail address: wy82lee@kier.re.kr

며, 신뢰성과 안정성 확보를 위하여 새로운 운영 기술의 도입이 필요하게 되었다.

장시간 운전중인 에너지 설비의 성능을 분석해보면 설계성능이나 운전 초기의 성능을 유지하지 못하는 것을 발견하게 된다. 운전에 따라 센서의 손상, 밸브나 탬퍼의 누설, 그리고 열교환기의 오염에 의한 성능저하 등 수많은 문제들이 발생할 수 있다. 이런 현상들을 고장으로 인식할 수 있으며, 공조설비에 고장이 발생하면 에너지 사용량의 증가는 물론 환경공해를 초래할 수 있다. 공조설비와 같은 에너지 설비에 있어서 관리기술 개선에 의해 절약될 수 있는 에너지량은 무시할 수 없는 양으로 상용 건물의 공조설비 재감리에 의해 고장상태를 개선한 후 20% 이상의 에너지 절감효과를 얻을 수 있는 것에서 고장검출 및 진단시스템의 중요성을 알 수 있다.

고장검출과 진단기술을 도입하면 시스템의 고장을 조기에 발견하여 고장의 파급효과에 의한 손실과 재해는 물론 에너지 낭비를 미연에 방지할 수 있으며, 성능진단에 근거해 유지 보전계획을 합리적으로 세울 수 있어 인건비 및 운영비를 절감할 수 있는 장점이 있다. 이와 같은 기술은 컴퓨터와 전자기술의 발달로 실현이 가능하게 된 것으로, 공조설비에 대한 실시간 고장검출 및 진단기술은 International Energy Agency(IEA)의 연구분과에서 90년대 초부터 국제적인 과제로 적용을 위한 연구가 집중적으로 수행되고 있다.

고장검출을 위한 연구는 안전과 신뢰성이 요구되는 모든 분야에서 광범위하게 수행되고 있다. Wilsky⁽¹⁾는 통계적인 방법을 제시하였으며, Isermann⁽²⁾는 모델기반 고장검출방법을 정리 발표하였고, Patton et al.⁽³⁾도 여러 가지 고장진단과 검출방법을 정리하여 발표하였다. 이러한 연구결과들은 간단한 시스템을 위한 이론적인 결과들로서 복잡하고 종합적인 건물설비에 적용하기에는 무리가 있었다.

공조설비에 대한 연구는 규칙기반과 전문가 시스템을 적용한 것이 있으며,⁽⁴⁾ 이것은 주로 운전 규칙과 허용범위를 이용하는 것으로 상태변화가 큰 고장의 검출에 효과적이다. 고장검출에 대표적으로 사용되는 방법으로는 모델기반방법이 있으며, 모델식에 의한 잔차(residual)를 고장검출에 이용할 경우 단순히 상태의 상·하한 허용값을 이용하는 것보다 검출성능이 향상되어 급격한 고

장은 물론 서서히 발생하는 성능저하현상도 미리 검출할 수 있는 장점이 있다. 잔차는 기준값과 직접 측정된 값과의 차로 정의되며, 기준값은 물리적으로 중첩된 복수개의 센서를 이용하거나 관련된 다른 센서의 측정값을 이용하여 함수적으로 예측된 값으로 구할 수 있다. 위험성이 크게 수반되지 않는 공조시스템의 경우 경제적인 면을 고려하여 관련 측정값과 모델식을 기초로 이론적인 중첩(analytical redundancy)으로 기준값을 구하는 것이 바람직하다. 공조 분야에서는 물리적 모델식⁽⁵⁾과 블랙박스 모델⁽⁶⁾이 사용되었는데, 물리적 모델식은 전체적인 시스템보다는 특성이 잘 알려진 일부 부품에만 적용되는 단점이 있었으며, 급격한 고장에 주로 적용된 블랙박스 모델 방식은 고장검출에는 효과적이거나 진단을 위한 정보를 제공하지 못하는 단점이 있었다.

이론적인 중첩값을 예측하기 위해 회귀신경망을 이용할 수도 있다. 회귀신경망은 학습과정이 간단한 장점은 있으나 시스템이 복잡해지고 기준자료가 늘어나면 실시간으로 기준값을 구하는 데 소요되는 연산시간이 늘어날 수 있는 단점이 있다.⁽⁷⁾ 본 논문에서는 오프라인(off-line)상의 학습을 위해서는 일반 회귀신경망에 비해 연산시간이 많이 소요되는 단점은 있으나 일단 학습이 완료되면 실제 고장검출에 중요한 실시간으로의 적용이 간단하고 연산시간이 짧은 장점이 있는 신경망 모델을 기준식(reference model)으로 적용하였다. 인간의 인식 및 판단능력을 좌우하는 뇌의 기능을 컴퓨터 등을 이용하여 실현시키려는 것이 신경망으로 공조설비와 같은 비선형 특성을 예측하거나 성능패턴을 판단하는 데 유용하게 사용될 수 있다.

본 논문에서는 고장검출과 진단과정을 구분하여 1단계 고장검출과정에서는 잔차를 산출하기 위한 기준식으로 신경망을 적용하였으며, 2단계 고장진단과정에서는 1단계에서 도출한 신경망 기준식의 입출력 관계로 제어기 부위별 고장패턴을 도출하여, 이것을 학습시켜 실시간 고장분류에 이용하기 위한 패턴 인식기로서 신경망을 이용하였다. 또한 공조기의 고장 특성을 해석하기 위해 개발한 전산 프로그램⁽⁸⁾을 사용하여 고장검출을 위한 신경망 기준식의 성능과 기준식의 입출력 관계를 이용한 고장진단 패턴 구성방법, 그리고 고장진단 성능을 검증하였다.

2. 본 론

2.1 공조시스템 및 자동제어기 개요

고장분석을 위해 전산해석에 사용한 공조기의 개략도는 Fig. 1과 같으며, 실내온도 제어를 위한 가변풍량(variable air volume, VAV) 유닛을 제외하면 중앙공조기의 제어시스템은 4부분으로 구성되어 있다.⁽⁸⁾

급기온도, 정압, 유량차, 그리고 실내온도 제어를 위해 PID 제어기를 사용하였다. 고장진단을 위한 부위로는 크게 급기온도 제어시스템, 혼합공기 시스템, 압력 제어시스템, 그리고 유량차 제어시스템으로 구분하였으며, 기본적으로 이들 부위별로 고장을 진단할 수 있도록 하였다.

공조기를 실시간으로 제어하면서 성능을 감시하기 위해서는 많은 수의 센서가 필요한데, 본 연구에서는 Fig. 1과 같이 8개의 센서를 해석적 중첩을 위한 관계식 유도에 사용하였다. 8개의 센서 중에 6개는 제어를 위한 센서이며, 나머지 2개는 부위별 에너지 성능을 감시하기 위해 사용된 센서이다. 사용된 8개의 측정센서로는 급기온도(T_s), 순환공기온도(T_{ci}), 외기흡입온도(T_{fr}), 혼합공기온도(T_m) 등을 측정하기 위한 4개의 온도센서와 압력제어를 위한 급기압력(P_s)센서, 급기유량(Q_s)과 순환유량(Q_{re})을 측정하기 위한 유량센서, 그리고 혼합공기습도(H_m)를 측정하기 위한 습도계가 사용되었다.

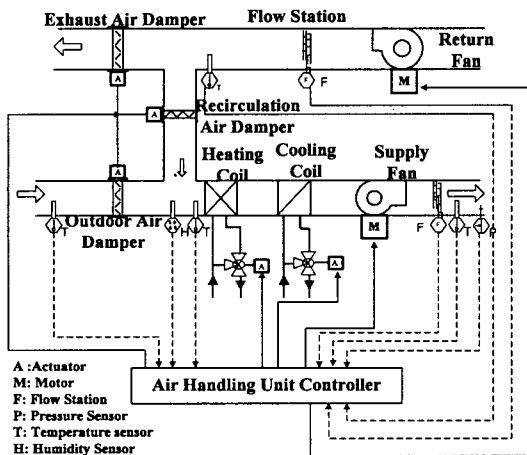


Fig. 1 Layout of an air handling unit.

2.2 고장검출 및 진단방법

해석적 중첩은 다른 특성이나 위치가 다른 센서의 측정값을 이용하여 필요한 측정값을 예측하는 것으로 예측값과 실제값을 비교하여 고장을 검출하게 되며, 본 논문에서는 신경망을 이용하여 정상적인 상태(normal condition)의 기준값을 예측하였다. 신경망의 경우 미리 구한 정상적인 상태의 자료를 이용하여 주어진 구조의 신경망을 학습시킨 후 정상적인 상태를 예측하게 되며, 고장이 발생한 경우 예측과 실제 결과와의 차이인 잔차가 발생할 수 있다. 고장검출을 위한 잔차 허용값은 정상적인 상태에서 외란과 예측오차가 포함된 잔차값을 이용하여 미리 구하게 된다. 본 논문에서는 통계적인 방법으로 정상적인 상태에서 구한 잔차의 표준편차값 3배를 허용값으로 이용하였다.⁽⁹⁾

공조설비는 시동 및 정지시간과 특별한 부하변화상태를 제외하고는 대부분 완만하게 부하가 변하기 때문에 정상상태(steady state)의 자료만을 고장검출 및 진단에 이용하였다. 시동이나 정지 과정에서 순간적인 변화가 발생하면 고장에 의한 변화와 구분이 어려우므로 상태변수의 기울기를 이용한 정상상태 검출기(steady state detector)를 사용하여 급격한 변화를 판단하였으며, 고장이나 정상적인 상태가 아닌 별도의 과도상태로 간주하여 고장진단의 정확도를 높였다. 기울기는 주어진 구간 내에서 최대값과 최소값의 차를 평균값으로 나누어 구하였다. 과도상태를 위한 기울기의 허용값은 정상상태에서 구한 기울기 변화의 표준편차를 사용하였다.

본 논문에서는 잔차를 산출하기 위하여 각 부위별 4개의 관계식을 사용하였으며, 4개의 관계식은 크게 4개 부위로 분류된 제어시스템의 고장을 검출하기 위한 것으로 급기온도 제어시스템(R_1), 혼합공기온도 제어시스템(R_2), 급기압력 제어시스템(R_3), 그리고 유량차 제어시스템(R_4)에 대한 것이다. 잔차는 실제값과 기준값인 신경망 예측값의 차로 정의하였고, 급기온도의 경우는 다음 식으로 주어진다.

$$R_1 = T_s - T_{s,es} \quad (1)$$

부위별 대표적인 기준값으로 급기온도(T_s),

혼합공기온도 (T_m), 압력 (P_s), 그리고 순환유량 (Q_{re})으로 정하였으며, 기준값을 예측하기 위한 기준식의 입출력 관계는 다음과 같다.

$$T_{s,es} = F(U_{cc}, T_m, H_m, Q_s) \quad (2)$$

$$T_{m,es} = F(T_{fr}, T_{ci}, Q_s, Q_{re}, U_{dmp}) \quad (3)$$

$$P_{s,es} = F(U_p, Q_s, U_{dmp}) \quad (4)$$

$$Q_{re,es} = F(Q_s, U_{re}, U_{dmp}) \quad (5)$$

식(1), (2), (3), (4), (5)를 이용하여 고장과 증상과의 관계를 구할 수 있다. 예로서 R_1 은 급기온도 제어시스템을 위한 관계식이며, R_1 을 위한 신호, 즉 U_{cc} , T_m , H_m , Q_s , 그리고 T_s 에 이상이 발생한 경우 예측식과 잔차에 변화를 일으키게 되므로 R_1 에 관계된 모든 센서와 구동기의 고장을 검출할 수 있다. 복수개의 관계식에 공통적으로 포함되어 있는 측정변수의 경우 센서에 고장이 생기면 관련된 관계식 모두가 영향을 받게 된다. 설비고장의 경우 운전상태의 변화로 인해 이를 보상해 주기 위한 제어신호에 영향을 끼치므로 해당 설비를 위한 제어신호가 포함되어 있는 관계식을 변화시키게 된다. R_1 과 마찬가지로 R_2 , R_3 , 그리고 R_4 를 이용하여 각 부위에서 고장과 증상과의 관계를 Table 1과 같이 미리 확보할 수 있으며, 이를 고장진단의 자료로 사용할 수 있다. Table 1에서 각기 다른 8개의 패턴을 볼 수 있으며, 이것을 이용하여 Table 2와 같은 고장진단을

Table 1 Fault and symptom relations

Fault signal	R_1	R_2	R_3	R_4	Subsystem
T_s sensor	○				T_s control
T_m sensor	○	○			T_m control
T_{ci} sensor		○			T_m control
T_{fr} sensor		○			T_m control
P_s sensor			○		P_s control
Q_s sensor	○	○	○	○	Q_d control
Q_{re} sensor		○		○	Q_d control
H_m sensor	○				T_s control
U_{cc} signal	○				T_s control
U_{dmp} signal		○	○	○	T_m control
U_p signal			○		P_s control
U_{re} signal				○	Q_d control

위한 입출력 패턴을 구성할 수 있다.

Table 2는 기본적으로 제어시스템을 위주로 부위별로 고장을 분류할 수 있도록 한 것으로 고장 패턴에 따라 일부 고장의 경우는 부품단위까지 고장진단이 가능하도록 출력 패턴을 구성하였다. 부위별 진단을 위해서는 공통적으로 급기온도 제어시스템의 경우는 출력벡터 중 두번째 항이 1로 출력되도록 하였으며, 이코노마이저 제어기인 혼합공기 시스템의 경우는 3번째 항이, 급기압력은 4번째 항이, 유량차는 5번째 항이 1로 출력되도록 하였으며, 같은 부위에서 고장패턴이 다른 경우를 구분하기 위해 6번째 항을 이용하였다. 혼합공기 제어 시스템 중 댐퍼/제어기 고장의 경우는 2번째 항의 출력도 1로 표시하도록 하였는데, 중간기에 냉난

Table 2 ANN patterns for fault diagnosis

Input pattern				Output pattern						Diagnosis result	
R_1	R_2	R_3	R_4							Subsystem	No.
0	0	0	0	1	0	0	0	0	0	Normal operation	1
1	0	0	0	0	1	0	0	0	0	T_s control	2
0	1	0	0	0	0	1	0	0	0	T_m control (T_{ci} , T_{fr} sensor)	3.0
1	1	0	0	0	0	1	0	0	1	T_m control (T_m sensor)	3.3
0	1	1	1	0	1	1	0	0	1	T_m control (damper, control)	3.6
0	0	1	0	0	0	0	1	0	0	P_s control	4
0	0	0	1	0	0	0	0	1	0	Q_d control (fan, controller)	5.0
0	1	0	1	0	0	0	0	1	1	Q_d control (Q_{re} sensor)	5.3
1	1	1	1	0	0	0	1	1	1	Q_d control (Q_s sensor)	5.6

방 코일을 사용하지 않고 외부 공기만으로 실내에 유입되는 공기의 온도를 제어할 경우 혼합공기 댐퍼가 급기온도제어계의 역할을 수행하므로 다른 패턴과 구분하기 위해 2번째 항과 3번째 항을 동시에 1의 값이 출력되도록 하였다. Q_3 의 경우 전체 잔차값에 영향을 끼치나 압력을 제어하는 급기송풍기와 유량차에 관련된 변수이므로 구별을 쉽게 하기 위하여 4번째와 5번째 항을 1로 출력하도록 패턴을 결정하였다. 첫번째 항이 1로 출력되는 것은 정상적인 상태를 나타낸다.

입력과 달리 출력은 고장을 구분할 수 있으므로 필요에 따라 다른 형태로 패턴을 구성할 수 있으며, 본 논문의 출력 패턴인 Table 2는 그 중 하나의 예로 간주할 수 있다. Table 2에서 마지막 항의 숫자는 고장을 구분하기 위한 분류번호로 고장검출 분류번호 1, 2, 3, 4, 5는 각각 정상적인 상태, 급기온도 제어시스템, 혼합공기온도 제어시스템, 급기압력 제어시스템, 그리고 유량차 제어시스템을 나타낸다. 각 제어시스템 내에서 분류가 가능한 고장은 다시 3.0, 3.3, 3.6 등으로 구분하였다. 여기서 3은 혼합공기 제어시스템을 나타내며 3.0은 T_{α} , T_{fr} 센서고장, 3.3은 T_m 센서고장, 그리고 3.6은 댐퍼와 제어기의 고장을 나타낸다. 마찬가지로 유량차 제어시스템의 경우도 시스템 내에서 고장을 진단할 수 있도록 5.0, 5.3, 5.6과 같은 임의의 구분번호를 사용하였다. 이와는 별도로 결과해석에서 0번은 과도상태를 표시하도록 하였다.

2.3 신경망 모델

정상상태의 예측값을 구하기 위한 기준식과 고장패턴의 분류기로서 신경망을 이용하였다. 신경회로망은 병렬, 분산, 정보처리 구조를 가지며, 이 구조는 가중된 연결(weighted connection)을 통해 많은 처리요소(processing element)들이 상호 연결되어 있다. 신경망에서 처리요소는 뉴우런(neuron)이라 불린다. i 번째 뉴우런에 대한 출력 \hat{Y}_i 는 다음과 같이 표현된다.

$$\hat{Y}_i = F\left(\sum_{j=1}^n w_{ij} X_j + b_i\right) \quad (6)$$

여기서, w_{ij} 는 i 번째와 j 번째 뉴우런 사이의 연




Fig. 2 Feed forward ANN model.

결 가중치이고, X_j 는 j 번째 입력, b_i 는 바이어스(bias)값이다. 전체 출력 \hat{Y}_i 와 입력 X_j 의 관계는 활성화 함수(activation function) F 에 의해 정해진다. 가장 간단한 선형 활성화 함수는 다음 식으로 표현된다.

$$\hat{Y}_i = F(X_j) = \omega_{ij} X_j + b_i \quad (7)$$

신경망의 활성화 함수로 일반적으로 가장 많이 사용되는 것은 시그모이드(sigmoid) 함수로 다음과 같다.

$$\hat{Y}_i = F(X_j) = \frac{1}{1 + e^{-\omega_{ij} X_j + b_i}} \quad (8)$$

일반적으로 신경망의 구조는 입력계층(input layer), 다단계의 은닉계층(hidden layer), 그리고 출력계층(output layer)으로 구성된다. 본 논문에서는 Fig. 2와 같이 중간에 하나의 은닉계층을 두고, 상태예측을 위해서는 식(8)을 입력과 은닉계층 사이의 활성화 함수로 사용하고 식(7)을 은닉계층과 출력계층 사이의 활성화 함수로 사용하는 전향 신경망을 채용하였다. 진단을 위해서는 식(8)을 활성화 함수로 양쪽에 사용하였다.

신경망 모델을 기준식으로 이용하기 위해서는 학습을 통해 연결 가중치와 바이어스값을 구해야 한다. 학습과정에서 기준 입력력자료를 이용하여 입력계층과 은닉계층, 그리고 은닉계층과 출력계층 간의 연결 가중치와 바이어스값을 산출하게

되며, 이들 값을 이용하여 실제 입력에 따른 출력을 예측하게 된다. 본 연구에서는 신경망 학습을 위해 Levenburg-Marquardt 알고리즘을 사용하여 실제 출력과 신경망을 통한 예측출력과의 차이 오차를 최소화시키는 방법을 사용하였다.⁽¹⁰⁾

2.4 고장검출 및 진단결과 분석

실험을 통해 얻기 어려운 장시간에 걸친 성능 저하현상을 구현하기 위하여 전산해석 프로그램을 이용하였으며, 동시에 단시간의 손상도 해석하였다. 공조기 해석 프로그램은 예열코일, 냉각코일, 실내 부하, 덕트, 송풍기와 댐퍼, 그리고 센서와 자동제어기 등의 부프로그램으로 구성되어 있으며, 공조기 각 부위에서 온도는 물론 습도와 압력, 유량을 계산할 수 있다. 본 연구에서는 여름철의 냉방모드를 위주로 해석하였다. 프로그램은 초기 입력과 출력을 그래픽 모드와 텍스트 모드를 선택하여 처리할 수 있도록 구성하였으며, 센서나 주요 설비의 고장을 선택할 수 있도록 하였다. 시스템 해석을 위한 모델식으로는 냉각코일과 덕트, 실내 부하의 경우 미국 국립표준기술연구원(NIST)에서 개발된 공조시스템의 동특성 해석 프로그램인 HVACSIM+의 동특성 해석 모델을 사용하였으며, 혼합공기 댐퍼, VAV 댐퍼, 그리고 급기 및 순환송풍기는 NIST의 기준 공조기 장치를 이용하여 실험을 통해 얻은 유량과 압력과의 관계 특성식을 사용하였다.^(7,8,11)

고장검출과 진단성능을 검증하기 위하여 7개 센서와 6개 설비의 고장자료를 산출하였다. 센서 고장은 시스템이 정상적으로 작동하는 도중에 발생하였다고 가정하였으며, 시스템 운전에 가장 중요한 센서인 온도센서를 제외하고는 센서에 10% 정도 편차가 생긴 것으로 가정하였다. 급기 온도센서는 성능저하현상을 분석하였으며, 전산해석을 위하여 성능저하를 가속시켰고, 시동 후 10,000초부터 최대 편차가 2.5°C가 되도록 기울기를 2.5°C/35,000 sec로 변화시켜 센서 측정값이 실제보다 낮은 값이 되도록 하였다. 나머지 온도센서의 경우 시동 후 10,000초 후에 실제값보다 1°C 낮은 온도편차가 생긴 것으로 가정하였다. 압력센서의 경우는 정격값의 5% 정도 편차가 이루어지도록 하였으며, 센서고장과 별도로 6개의 설비고장을 해석하였다. 6개의 설비고장은 냉각코일 밸




Fig. 3 Comparison of actual and estimated states at normal condition.

브가 운전중 고정된 상태와 냉각코일에 스케일이 생긴 상태로 열저항이 공기측은 0.4 m²K/kW, 물측은 0.5 m²K/kW 증가한 상태와 가열코일 밸브가 1% 정도 누수되는 상태, 순환공기 댐퍼가 10% 정도 열려 있는 고정된 상태, 그리고 급기 송풍기와 순환 송풍기의 성능이 10% 정도 저하된 상태를 고려하였다.

Fig. 3은 신경망을 이용하여 정상적인 상태를 예측한 결과로 4개의 주요 변수를 정확하게 산출하고 있다. Fig. 3에서 각 상태 변수들을 같은 스케일로 표시하기 위해 급기온도와 급기압력은 기준값으로 정규화시켰으며, 유량은 절대값을 그대로 사용하였다. 또한 혼합공기온도는 외부온도와 순환공기온도를 이용하여 정규화시켰으며, 정규화된 무차원 혼합공기온도(T_{mn})는 식(9)와 같다.

$$T_{mn} = \frac{T_m - T_{fr}}{T_{ci} - T_{fr}} = \frac{Q_{ci}}{Q_s} \quad (9)$$

무차원 혼합공기온도는 열수지에 의해 순환공기 유량과 급기유량과의 비로 표시할 수 있으며, 혼합되는 공기의 유량제어를 통해 온도를 조절하는 혼합공기 댐퍼 시스템의 고장을 검출하고 진단하는 데 효과적인 변수임을 알 수 있다.

예측오차를 절대평균오차로 구할 경우 급기온도의 경우 식(10)과 같이 표현된다.

$$AAE = \frac{1}{n} \sum_{i=1}^n \frac{|T_s(i) - T_{s,es}(i)|}{T_s(i)} \quad (10)$$




Fig. 4 Comparison of actual and estimated states when T_s sensor is degraded.

급기온도의 경우 AAE는 0.1%, 그리고 급기압력의 경우 AAE는 0.6%이며, 혼합공기온도와 유량의 오차도 0.1% 이하로 매우 정확하게 상태를 예측하고 있다.

고장검출 결과를 분석한 결과로 실험적으로 구현이 어려운 성능저하현상을 다음에 주로 설명하였다. Fig. 4는 T_s 센서의 성능저하가 일어난 것을 신경망을 이용하여 예측한 결과이다. 센서 측정값은 제어기의 보상작용에 의해 겉보기에는 정상적인 값을 나타내고 있으나 예측한 결과는 실제보다 높은 값을 나타내고 있다. 측정값이 센서 성능의 저하로 실제값보다 낮은 값을 지시하게 되면 제어기의 기능에 의해 측정값이 기준값이 되도록 조절되므로 실제값은 성능저하분 만큼

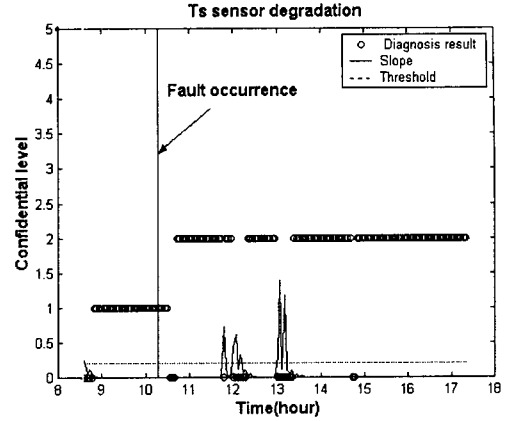




Fig. 5 Fault diagnosis at T_s sensor fault.

높은 값을 나타나게 되며, 신경망의 예측결과가 이것을 정확하게 예측하고 있다. 따라서 예측한 결과와 실제 측정결과의 차이인 잔차를 이용하여 고장을 검출할 수 있다.

Fig. 4에서 T_s 센서 고장의 경우 T_s 온도예측에 차이가 발생한 것을 알 수 있으며, 이를 통해 특정부위의 고장을 검출할 수 있다. Fig. 4에서도 4개 변수의 스케일을 일치시키기 위해 급기온도와 압력은 제어기의 설정 기준값으로 나누어 표시하였으며, 혼합공기온도는 식(9)의 무차원값으로, 그리고 순환공기유량은 실제값으로 표시하였다. Fig. 5는 신경망을 이용한 고장진단의 결과이다. 고장 초기에는 증상이 미약하여 산출된 잔차가 외란과 예측오차에 의한 것과 구분이 어렵기



(a)



(b)

Fig. 6 Estimated results and residuals.




Fig. 7 Fault diagnosis results.

때문에, 이 구간에서는 정상적인 상태 1로 분류되었고, 고장이 어느 정도 진행되어 허용범위를 초과하면 급기온도 제어시스템의 고장 2로 진단되는 것을 확인할 수 있다. 급격한 부하 변화시에 부분적으로 나타나는 과도상태는 0으로 분류되어 있다.

Fig. 6과 Fig. 7은 냉각코일의 스케일로 인하여 성능저하가 발생하였을 경우, 잔차와 신경망에 의해 고장을 진단한 결과이다. Fig. 6에서 알 수 있는 바와 같이 고장과 관련된 주요 잔차가 변화하는 것을 알 수 있으며, Fig. 7은 이와 같은 잔차변화를 이용하여 고장을 분류한 것으로 대부분의 구간에서 급기온도 제어시스템의 고장을 나타내는 고장번호 2를 표시하고 있다. 일부 구간에서 분류결과가 0과 1을 나타내는 것은 시동과 정지 시에는 부하가 상대적으로 작아 예측결과와 실제 결과의 차인 잔차값이 작거나 과도특성에 의해 고장검출을 유보한 결과이다. 정상상태 검출기에서 과도상태로 판별된 경우는 고장검출을 수행하지 않고 0으로 표시하였으며, 이것은 고장에 의한 변화인지 급격한 부하변화에 의한 과도특성인지를 판단하기 어렵기 때문에 잘못 진단되는 것을 막기 위해 상태변화 기울기를 이용하여 고장검출에서 제외한 것이다. Fig. 7에서는 급기온도 기울기를 표시하였으며 점심시간을 전후한 부하변화시에 과도특성이 나타나는 것을 알 수 있다.

나머지 고장에 따른 잔차변화는 Table 3에 정리하였다. 잔차의 변화값은 고장 후 3분 후의 값을 이용하였다. 성능저하가 일어나는 급기온도 센서의 경우 100초 후의 잔차변화는 약 0.09 정도

Table 3 Residual changes after faults

Faults	Residual changes			
	R_1	R_2	R_3	R_4
Normal operation	<0.1	<0.1	<3	<0.05
T_s sensor degradation	0.09 (2.5)	<0.1	<3	<0.05
Stuck cooling coil valve	2.9	<0.1	<3	<0.05
Fouled cooling coil	0.81	<0.1	<3	<0.05
Leaking heating coil valve	0.41	<0.1	<3	<0.05
T_{fr} sensor drift	<0.1	0.23	<3	<0.05
T_{ci} sensor drift	<0.1	0.31	<3	<0.05
T_m sensor drift	0.2	1.11	<3	<0.05
Stuck damper	<0.1	1.43	<3	0.11
P_s sensor drift	<0.1	<0.1	6.2	<0.05
Supply air fan	<0.1	<0.1	249	<0.05
Q_s sensor drift	0.58	0.21	249	0.1
Q_{re} sensor drift	<0.1	0.22	<3	0.251
Return air fan	<0.1	<0.1	<3	0.07

로 미세한 값이나 고장이 진행되면 2.5℃로 증가되므로 1시간 후의 값을 고장진단에 사용하였다. Table 3에서 나타나 있는 바와 같이 Table 1에서 예측한 증상과 실제결과의 패턴이 정확하게 일치하는 것을 알 수 있으며, 잔차를 이용하여 신경망으로 고장을 분류하면 Table 4와 같이 정확하게 고장을 진단할 수 있다. 이를 통해 신경망의 예측기술과 패턴 인식기술을 이용할 경우

Table 4 ANN diagnosis result after faults

Faults	Diagnosis results						No.
	1	0	0	0	0	0	
Normal operation	1	0	0	0	0	0	1
T_s sensor	0	1	0.01	0	0	0	2
Stuck cooling coil valve	0	1	0	0	0	0	2
Fouled cooling coil	0	1	0.01	0	0	0	2
Leaking heating coil valve	0	1	0	0	0	0	2
T_{fr} sensor	0	0	1	0	0	0.01	3
T_{ci} sensor	0	0	1	0	0	0.01	3
T_m sensor	0	0.01	1	0	0	1	3.3
Stuck damper	0	1	1	0	0	1	3.6
P_s sensor	0.01	0	0	0.99	0	0	4
Supply air fan	0	0	0	1	0	0	4
Q_s sensor	0	0	0	1	1	1	5.6
Q_r sensor	0	0	0	0.01	1	1	5.3
Return air fan	0	0	0	0	1	0	5

고장검출과 진단을 효과적으로 수행할 수 있는 것을 확인할 수 있다.

기준식으로 통계적 회귀식을 사용할 경우 특성 방정식이 주어지지 않은 경우 시행착오를 거쳐 식의 형태와 계수를 구해야 하며, 정확한 예측값을 산출하기 위해서는 반복을 통해 예측오차가 최소가 되는 회귀식을 결정해야 하는 데 반해 신경망은 일반 회귀식과는 달리 시스템 특성에 대한 특별한 전문지식이 없어도 입출력 관계만 파악되면 기준자료를 통한 학습을 통해 출력을 예측할 수 있는 장점이 있다. 신경망의 경우 계산시간은 오프라인으로 진행되는 학습과정에서 거의 소요되며, 학습된 결과를 이용하는 기준값 예측과 진단과정에는 간단한 활성화 함수의 계산만이 필요하므로 연산시간이 거의 필요하지 않는 장점이 있다. 따라서 컴퓨터를 이용하여 실시간으로 설비를 감시하고 성능을 진단하는 데 유용하게 사용될 수 있다.

3. 결 론

신경망을 이용한 공조설비의 고장검출 및 진단 방법을 제시하였다. 고장검출을 위해 필요한 정상적인 상태의 기준값을 예측하기 위해 신경망 모델을 사용하였으며, 고장진단은 신경망의 패턴인식방법을 이용하였다.

본 논문에서는 기본적으로 제어부위별로 고장을 진단할 수 있도록 각 제어기의 대표적인 변수를 신경망 기준식을 이용하여 예측하였으며, 예측식의 결과와 실제값의 차인 잔차의 패턴을 신경망으로 분류하여 실시간으로 운전자에게 진단 결과를 제공할 수 있도록 하였다. 고장패턴에 따라서는 부품별 고장진단도 가능하도록 하였다.

후 기

본 연구는 과학기술부의 국제공동연구과제로 수행되었으며, 연구에 도움을 준 미국 국립표준기술연구소의 Dr. Cheol Park과 Iowa energy center의 Dr. J. M. House에게 감사드립니다.

참고문헌

1. Wilsky, A. S., 1976, A survey of design methods for failure detection in dynamic systems, *Automatica*, Vol. 12, pp. 601-611.
2. Isermann, R., 1984, Process fault detection based on modeling and estimation methods, *Automatica*, Vol. 20, pp. 387-404.
3. Patton, R. P., Frank, P. M. and Clark, R., 1989, *Fault Diagnosis in Dynamic Systems Theory and Application* NewYork, Prentice Hall, p. 602.
4. Liu, S. T. and Kelly, G. E., 1989, Rule based diagnostic method for HVAC fault detection, *Proceedings of Building Simulation '89*, Vancouver.
5. Hyvarinen Juhani, 1994, Fault detection method for district heating substation control valve based on static and physical model, IEA ANNEX25 working paper, Stuttgart.
6. Yoshida, H. and Kumari, S., 1999, ARX and AFRM model-based on-line real-time data base diagnosis of sudden fault in AHU of VAV system, *Energy Conv. and Mgmt.*, Vol. 40, pp. 1191-1206.
7. Lee, Won-Yong and Lee, B. D., 2000, Regression Model-Based Fault Detection of an Air-Handling Unit, *Korean Journal of Air-Conditioning and Refrigeration Engineering*, Vol. 12, No. 7, pp. 688-696.
8. Lee, Won-Yong, 2000, Computer-aided practical application of faults detection and diagnosis techniques in energy systems, KIER Report, KIER-996816.
9. Lee, Won-Yong and Shin, D. R., 1999, Fault detection in an automatic central air-handling-unit, *Trans. KIEE*, Vol. 48A, No. 4, pp. 410-417.
10. Stepniewski, S. W. and Jorgensen, C. C., 1998, Accelerated Training for large feed-forward neural networks, NASA report, NASA/TM-1998-112239.
11. House, J. M., Lee, Won-Yong and Shin, D. R., 1999, Classification techniques for fault detection and diagnosis of an air handling unit, *ASHRAE Trans.*, Vol. 103, pp. 1087-1097.