

뉴로 퍼지를 이용한 냉동기 성능 진단 기법

신영기[†], 장영수^{*}, 김영일^{*}

(2002년 3월 5일 접수, 2003년 3월 17일 심사완료)

Neuro-Fuzzy Diagnostic Technique for Performance Evaluation of a Chiller

Younggy Shin, Young-Soo Chang and Youngil Kim

Key Words : Centrifugal Chiller(터보냉동기), Artificial Neural Network(인공 신경망), ANFIS(적응형 뉴로퍼지), COP (성능계수), Performance diagnosis (성능 진단)

Abstract

On-site diagnosis of chiller performance is an essential step for energy saving business. The main purpose of the on-site diagnosis is to predict the COP of a target chiller. Many models based on thermodynamics background have been proposed for this purpose. However, they have to be modified from chiller to chiller and require deep insight into thermodynamics that most of field engineers are often lacking in. This study focuses on developing an easy-to-use diagnostic technique that is based on adaptive neuro-fuzzy inference system (ANFIS). Quality of the training data for ANFIS, sampled over June through September, is assessed by checking COP prediction errors. The architecture of the ANFIS, its error bounds, and collection of training data are described in detail.

기호설명

COP : 냉동기 성능계수
 C_1, C_2 : 임의 상수
 f, g : 함수
 \dot{m} : 질량유량
 P_{eff} : 냉동기 유효소비 전력
 Q_c : 증발기측 부하
 T : 온도
 μ : 퍼지 멤버쉽 함수

하첨자

A : 퍼지 규칙
 cwi : 응축기측 냉각수 입구온도
 ew : 증발기측 냉수
 ewi : 증발기측 냉수 입구온도
 ewo : 증발기측 냉수 출구온도

[†] 책임저자, 회원, 세종대학교 기계공학과
 E-mail: ygshin@sejong.ac.kr
 TEL : (02)3408-3284, FAX : (02)3408-3333

^{*} 회원, 한국과학기술연구원 열유동제어 연구센터

1. 서론

대부분의 상업용 빌딩, Clean room, 공장 등에서 증발기측 부하 처리에 사용되는 대용량 터보 냉동기는 건물 연간 에너지 소비의 중요한 비중을 차지한다. 따라서, 냉동기 성능저하에 따른 에너지 비용 손실을 정량적으로 계산하기 위해서는 현재 사용중인 냉동기의 성능계수가 얼마인지 정확하게 평가되어야 한다. 냉동기의 성능계수 비교는 일반적으로 표준조건에서 행해지나, 운전 중인 증대형 냉동기에서 표준조건을 재현하는 것은 불가능하므로 많은 연구자들은 운전중인 냉동기의 비표준 조건하의 시험 데이터와 냉동기 시뮬레이션 모델을 이용하여 표준조건에서의 성능계수를 예측하고 있다.⁽¹⁾ 이러한 에너지 진단이 가능하기 위해서는 다음과 같은 기술적 과제들을 해결해야 한다. 첫째, 에너지 절약을 위한 냉동기 성능진단은 수 일 이내에 완료되어야 하되 가능하면 비수기에 진단이 이루어져야 한다. 둘째, 운전 중인 냉동기에 지장을 초래하지 않으면서 필요한 데이터의 측정이 이루어져야 한다. 셋째, 측정된 데이터로부터 성능계수 진단에 필요

한 준정상상태 (quasi-steady state)의 데이터를 추출해야 한다. 마지막으로 추출된 데이터로부터 표준 조건에서의 성능계수 예측을 위한 냉동기 성능해석 프로그램이 개발되어야 한다. 본 연구에서는 위에서 서술한 기술적 과제들을 해결하기 위한 방안을 모색하고자 한다.

성능예측 프로그램으로서 모델의 예측 정확도를 높이고 각종 부속기기의 성능특성까지 감안하기 위해서는 프로그램이 복잡해지고 모델링에 필요한 변수 값들을 정하는 것도 간단한 일이 아니다. 따라서 이러한 범위의 시뮬레이션 작업은 세계적으로 시장점유율이 높은 일부 회사에서만 진행되고 있다. 이러한 프로그램의 접근방법은 열역학, 열전달 이론 및 실험데이터에 의한 경험식을 이용한 프로그램을 이용하는 방법으로서 특정 냉동기에만 적용되며 프로그램 개발을 위해서 많은 시간과 인적자원이 요구된다. 그러나, 에너지 진단 사업 실용화의 목적상 모든 냉동기에 적용될 수 있으며 취급이 간편하고 보편적인 성능예측 프로그램이 요구된다. 이러한 필요성에 부응하여 인공 신경망을 이용한 냉동기의 성능예측과 관련한 연구가 진행되어 왔으며,^(2,3) 인공 신경망은 냉동기의 입출력 데이터로부터 비선형적 함수관계를 추출하므로 물리적 모델에 대한 복잡한 해석 없이도 성능예측이 가능한 장점이 있다. 그러나, 인공 신경망 구축에 필요한 변수가 많아서 학습에 요구되는 측정 데이터 수가 많이 요구되고 학습시간이 오래 걸리는 등의 단점이 있다.⁽⁴⁾ 본 연구에서는 인공 신경망이 갖는 이러한 단점을 개선하기 위하여 인공 신경망 (artificial neural network) 및 퍼지이론 (fuzzy logic)을 조합한 적응형 뉴로 퍼지 추론체계 (ANFIS; adaptive neuro-fuzzy inference system)^(4,5)를 이용한 성능진단 프로그램을 제시한다.

2. 실험장치 및 방법

본 연구의 목적은 현장에서 사용 중인 냉동기 운전 전에 지장을 초래하지 않으면서 성능을 진단하는 것이므로 최소한의 센서와 비간섭형 설치 방법을 적용하여 다음과 같이 터보 냉동기를 진단하였다.

2.1 실험장치

한국과학기술연구원 내 청정연구동은 연면적 6655.4 m²의 4층 건물로, 내부에 고정정을 요구하는 실험을 수행할 수 있는 청정실험실이 있다. 지하 기계실에는 200 RT 급의 터보 냉동기가 3대 설치되어 있으며 연구에 사용된 데이터는 이 냉동기로부터 얻어졌다. 터보 냉동기에서 만들어진 냉수

는 클린룸의 부하처리를 위한 2대의 AHU (air handling unit)와 연구실과 실험실의 냉방을 위한 2대의 AHU, 각 연구실 FCU (fan coil unit)에 공급되고 그리고 일부 실험장비의 냉각수로도 공급된다.

터보 냉동기는 2단 압축 방식으로 응축기 출구의 고압 냉매를 중간단에서 팽창시켜 액은 증발기로 보내고, 플래쉬 가스는 1단에서 압축된 냉매와 같이 2단 압축기로 압축하는 사이클로 단단 압축기에 비해 성능향상을 얻을 수 있다. 또한 압축기 입구에 설치된 IGV (inlet-guide vane)의 개도를 조절하여 용량제어가 가능하다. IGV의 개도는 압축기 소비전력과 냉수온도에 의해 제어되어 부하변동에 관계없이 일정한 온도의 냉수를 공급할 수 있도록 한다. 응축기의 방열은 냉각수로 옥상에 설치된 냉각탑에 수송되어 대기 중으로 방출된다.

2.2 성능 측정 방법

냉동기 성능계수는 증발기의 2차 유체인 냉수의 유량과 입출구 온도차 및 냉동기 유효소비전력을 측정하여 식 (1)의 관계식을 통하여 구하였다.

$$COP = \frac{Q_e}{P_{eff}} = \frac{\dot{m}_{cw} c_p (T_{ewi} - T_{ewo})}{P_{eff}} \quad (1)$$

입출구 온도는 T-type 열전대를 배관 내에 설치하여 측정하였고 유량은 배관표면에 장착된 초음파 유량계를 이용하였다. 식 (1)에서 보는 바와 같이 온도차가 작으면 센서의 측정오차가 성능계수 계산에 영향을 미칠 수 있으므로 5쌍의 열전대를 직렬로 연결한 써모파일(thermopile)을 사용하여 온도차의 측정 정밀도를 5배 향상시켰다. 열전대의 정밀도는 일반적으로 ± 0.1 °C 이므로 써모파일을 통하여 ± 0.02 °C 로 측정 정밀도를 향상시켰다. 냉동기의 유효소비전력은 모터에 인가하는 전원의 전압, 전류, 역률을 측정하여 구하였다. 데이터는 1분 간격으로 샘플링 되었다. 데이터로거를 이용하여 처리된 온도 및 유량 신호 그리고 전력계 측정 정보는 모두 RS485 통신을 통한 multi-drop 방식으로 PC로 전송되었으며 데이터 통신 및 처리 프로그램을 자체적으로 작성하였다. Fig. 1은 현장의 냉동기에 설치된 측정장치의 구성을 나타낸다. Table 1은 10분 평균 데이터의 일부를 이용하여 COP를 계산한 예이다. 써모파일의 측정오차를 고려하면 성능계수 1.38, 3.40의 경우 성능계수의 오차는 각각 6%, 1.3%에 해당한다.




Fig. 1 Schematic of the measurement setup


Table 1 Example of measured COP

\dot{m}_{cw} [kg/s]	T_{ewi} [°C]	T_{cwO} [°C]	P_{eff} [kW]	COP
46.36	6.8	6.13	95.7	1.38
46.36	9.05	7.84	109.0	2.14
46.36	9.91	7.81	138.0	2.93
46.36	11.5	8.33	178.0	3.40


3. 적응형 뉴로퍼지 추론체계(ANFIS)

3.1 이론개요

ANFIS 는 Jang⁽⁴⁾에 의해 제안된 인공 신경망(neural network)에 기반을 둔 적응형 퍼지 추론 체계이다. 냉동기처럼 시스템이 복잡하여 수학적 모델링이 곤란하거나 불확실성이 많은 경우에는 해당 시스템의 문제 해결을 위하여 전문가의 경험적 사고에 의존한다. 이러한 전문가의 경험적 판단체계를 모델링하는 방법의 하나가 퍼지 추론체계이다. 퍼지추론은 인간의 사고방식처럼 조건부와 결론부로 구성되며 조건으로부터 결론을 유도하기 위한 규칙 생성 및 논리 연산의 과정에서 다양한 퍼지 이론들이 분기된다. 인간의 사고에서는 조건부와 결론부가 수학적인 정량적 값들로 표현될 수 없으며 이러한 애매한(fuzzy) 특성을 반영하기 위하여 멤버쉽 함수 (membership function)가 사용된다. 본 연구에 적용된 ANFIS 의 퍼지 추론체계는 Takagi-Sugeno 추론체계⁽⁶⁾로서 Fig. 2(a)에 그 구조가 묘사되어 있다. Fig. 2(a)는 두 개의 입력 값 x, y 에 대응한 종 모양(bell-shaped)의 멤버쉽 함수를 보여주고 있다. x, y 에 대응한 멤버쉽 함수의 출력치 중 작은 값 w_1 이 규칙 1 의 출력이 되고 규칙 2 의 출력은 하단의 w_2 가 된다. Takagi-Sugeno 추론체계의 특징은 결론부가 멤버쉽 함수가 아닌 입력 값들의 선형 조합인 f_1 과 f_2 로 표현된다는 점이다. 최종 결론 f 는 규칙 1 과 2 의 출력인 w_1 과 w_2 를 선형 가중치로 하여 최종적인 값으로 출력된다. Jang 은 Fig. 2(a)의 구조가 Fig. 2(b)의 인공신경망 구조와 동등함을 파악하였다. 인공신경망은 주어진 학습데이터를 가장 잘 모사할 수 있도록 자기학습을 할 수 있는 기



(a)



(b)

Fig. 2 (a) Takagi-Sugeno type fuzzy inference system (b) Equivalent neural network (ANFIS)

능을 갖추고 있는데 신경망 구조가 선형적일수록 단시간에 안정적으로 학습 데이터에 수렴하는 학습 효과를 나타낸다.

3.2 데이터 처리

ANFIS 의 단점은 해석 대상의 물리적 특성에 대한 사전 정보 없이 입력과 출력의 상관성만을 추론하는 시스템인 관계로 정의역 구간에 걸친 충분한 양의 데이터가 존재하지 않는다면 훈련된 추론체계의 신뢰성을 확신할 수 없다. 이러한 단점을 보완하기 위해서는 해석대상에 대한 사전 정보를 이용하여 ANFIS 훈련에 사용될 데이터를 필터링할 필요가 있다. 여기서 ANFIS 훈련이란 주어진 입출력 데이터 베이스를 가장 잘 모사할 수 있도록 오차를 최소화하는 방향으로 ANFIS 의 각종 계수들을 스스로 조정해나가는 자기 학습과정을 의미한다. 열역학 기반 성능예측 모델링에 관한 많은 연구 논문들⁽⁷⁻⁹⁾의 공통적 결론은 정상상태 운전조건 하에서 성능계수의 역수 $1/COP$ 와 증발기측 부하의 역수 $1/Q_e$ 는 다음과 같은 경험적 선형관계를 갖는다는 것이다.

$$\frac{1}{COP} \approx \frac{C_1}{Q_e} + C_2 \quad (2)$$

선형적 관계의 원인은 정상상태 하에서 냉동기의 응축기와 증발기의 열교환 과정에서 주로 유한한 온도차에 의해 발생하는 비가역성이 증발기측 부하 Q_e 에 비례하는 특성을 나타내기 때문이다.⁽⁸⁾ 이러한 경험적 사실은 측정된 데이터로부터 성능 예측에 필요한 준정상 상태의 데이터를 추출하는데 유

용한 정보가 된다. ANFIS의 훈련을 위해서는 수 일간의 데이터로부터 모든 증발기측 부하 영역에 대하여 최대한 많은 준정상 상태 데이터를 추출해야 하며 이는 1분 간격으로 측정된 데이터의 적분 평균 시간을 최대한 작게 해야 함을 의미한다. Browne 등⁽¹⁰⁾의 동특성 실험결과에 의하면 200RT급 스크류 냉동기의 시상수는 약 2분 정도였다. 본 연구에서는 이 시상수 크기를 감안하여 비정상 상태의 영향을 최소화하기 위해 1분 간격으로 측정된 데이터를 시간 평균하였다. 5분, 15분, 20분 평균 등을 시도하였으나, 10분 이상이면 대부분의 데이터가 식(2) 근처로 수렴하였으므로 가능한 한 많은 준정상 상태 데이터를 얻기 위한 최소 시간 평균 간격을 10분으로 정하였다. 기동, 정지 등과 같은 비정상 상태 구간 운전결과의 평균치는 정상 상태의 값에서 벗어나게 되며 이러한 비정상 상태의 값들을 배제하기 위해 다음과 같은 조건을 적용하였다.

- 1) 냉수 출구온도가 설계 정상상태 온도(본 연구 장치에서는 8°C)±1°C편차의 범위를 벗어날 때.
- 2) 열역학적 경험식(2)의 직선성에서 벗어날 때.

Fig. 3은 6월초 4일간(1,3,5,7일)에 걸쳐 취득한 데이터 중에서 냉동기가 운전되는 구간에서만 10분 평균하여 얻어진 성능계수와 증발기측 부하(cooling load)의 관계를 나타낸다. Fig. 3(a)는 계측된 10분 평균 데이터를 모두 나타낸 것이고 Fig. 3(b)의 데이터는 Fig. 3(a)의 데이터 중 위의 준정상 조건에 드는 데이터만 필터링하여 나타낸 것으로서 식(2)의 경험식과 유사한 선형 관계를 나타냄을 알 수 있다.

3.3 ANFIS 기반 성능 예측 모델

3.3.1 입력변수의 선정

경험식(2)의 함수관계를 보다 정량적으로 규명하기 위한 연구 결과들⁽⁷⁻⁹⁾에 따르면, COP는 증발기측 부하 Q_e 이외에도 냉각수 입구 온도 T_{cwi} , 냉수 출구온도 T_{cwo} 와 밀접한 관계가 있음이 알려져 있다. 이외에 냉각수 출구 온도 및 냉수 입구 온도의 효과도 고려할 수 있으나, 이들은 냉각처리 부하와 연동되어 열교환기 성능에 반영되므로 입력변수의 수를 줄이기 위해 일반적으로 생략된다. 따라서, ANFIS 기반 퍼지 모델은 다음과 같은 함수관계를 갖는 것으로 가정한다.

$$1/COP = f(1/Q_e, T_{cwi}, T_{cwo}) \quad (3)$$

식(3)의 입력변수 이외에 증발기측 냉매 압력


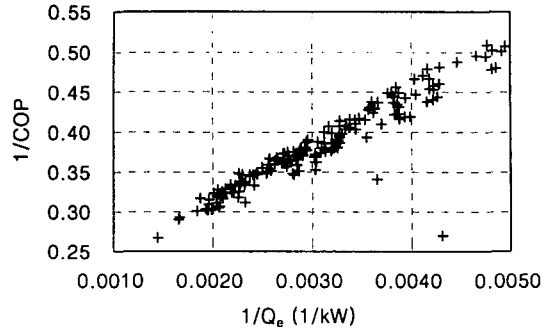


Fig. 3 (a) 10 minutes-average data points sampled during June 1st, 3rd, 5th and 7th of 2000 (b) data points filtered through the quasi-steady state criteria for the data points of (a)

등보다 많은 입력변수를 상정할 수도 있지만 이 경우 훈련시켜야 할 ANFIS의 변수 수가 기하급수적으로 증가하여 계산량이 증대한다. 따라서, 해당 입력변수의 영향이 크지 않은 경우에는 가능한 한 배제하는 것이 좋다. 더욱이 개발하고자 하는 모델은 현장에서 간단히 측정할 수 있는 측정 변수들만의 함수로 표현하고자 하는 것이며 이들 입력변수에 대한 성능계수 경험식은 많은 연구결과에서 발표된 바 있다.⁽⁷⁻⁹⁾

3.3.2 멤버십 함수

N 차원의 콤팩트 공간(compact space)인 정의역 D 대하여 퍼지 추론 멤버십 함수들의 집합 S가 다음의 Stone-Weierstrass 정리⁽⁴⁾의 조건을 만족하면 임의의 비선형 함수를 원하는 정밀도까지 근사시킬 수 있다.

- 1) Identity Function: $f(x)=1$ 인 함수가 S에 속한다.
- 2) Separability: 임의의 서로 다른 두 점 $x_1 \neq x_2$ 에 대해 $f(x_1) \neq f(x_2)$ 인 함수 f가 존재한다.
- 3) Algebraic Closure : S에 속하는 임의의 두 함수 f,

g 와 임의의 실수 a, b 에 대하여 fg 와 af+bg 도 S 에 속한다.

조건 1,2 는 멤버쉽 함수의 형태에 별다른 제약을 가하지 않지만 조건 3 을 만족하기 위해서는 함수의 형태가 종(bell)모양 또는 가우스 확률 분포함수의 형태를 보여야 한다.⁽⁴⁾ 3 개의 조정변수 a,b,c 를 갖는 다음의 종함수 (bell function)가 멤버쉽 함수로 주로 사용된다.

$$\mu_A(x) = \frac{1}{(1 + \left| \frac{x-c}{a} \right|)^{2b}} \quad (4)$$

3.3.3 ANFIS 구조 설계

주어진 대상을 모사하기 위해 필요한 ANFIS 구조의 설정조건에 대해서는 일정한 규칙이 없다. ANFIS 운용 예에 따르면,⁽⁴⁾ 멤버쉽 함수형태로서 식 (4)의 일반화된 종함수가 선호되므로 본 연구에서도 같은 함수를 선택하였다. 입력변수는 식 (2)에 주어진 3 개의 변수로 정하였으며 각 입력변수 별로 필요한 멤버쉽 함수의 수는 2 개로 설정하였다. 입력변수 별로 3 개의 멤버쉽 함수를 설정한 경우, 훈련된 ANFIS 는 실제 냉동기의 특성을 다소 과도 근사(over-fit)하였다. 여기서 과도근사란 실제 시스템의 거동보다 높은 차수의 모델로 근사화하려는 경우 퍼지나 인공지능망 시스템이 학습공간에서는 실제와 흡사한 예측성능을 나타내나 학습영역을 벗어나면 엉뚱한 예측을 초래하게 되는 것을 의미한다. 열역학 모델에 근거한 성능계수의 거동을 보면 해당 입력변수들의 영향이 선형에 가까웠으므로 멤버쉽 함수의 수도 이에 근사하도록 2 개로 설정하는 것이 모델과 실험결과의 오차를 줄일 수 있었다. 결과적으로 적용된 ANFIS 의 구조는 Fig. 4 와 같다.

Fig. 4 에서 3 개의 입력변수 Q_c, T_{cwi}, T_{cwo} 에 대하여 각각 2 개의 입력 멤버쉽 함수 (input membership function; 식 (4) 참조)을 할당하게 되므로 만들 수 있는 규칙(rule)의 조합은 $2^3 = 8$ 개이다. 조건부의 입력 멤버쉽 함수 (식 (4) 참조)와 관련된 비선형 변수의 개수는 $6 \times 3 = 18$ 개이다. Sugeno 형태의 추론법에 의한 결론부의 멤버쉽 함수 (Output membership function)는 입력변수의 선형 조합인 다음의 식 (5)로 표현된다.

$$f_i = p_i T_{cwi} + q_i T_{cwo} + r_i Q_c^{-1} + s_i \quad (5)$$

여기서 하첨자 i 는 i-번째 규칙, f_i 는 i-번째 규칙의 결론 결과치, p_i, q_i, r_i, s_i 는 학습과정에서 조

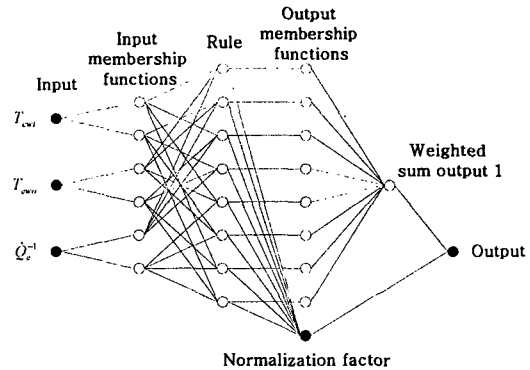


Fig. 4 The ANFIS architecture for the prediction of chiller performance

정되는 계수이다. 8 개 규칙에 대하여 결정되어야 할 결론부 미지수는 $8 \times 4 = 32$ 개다. 결과적으로 ANFIS 의 훈련은 조건부와 결론부의 50 개 변수의 최적치를 구하는 것을 의미한다. ANFIS 에서 제안된 혼합형 훈련규칙은 주어진 훈련 데이터 집합에 대하여 결론부 선형 변수들을 최소 오차승 기법으로 구한 후, 결정된 선형 변수 값들에 대하여 오차의 변화율을 입력부로 역전시켜 (back-propagation) 변수 값들을 gradient descent 기법으로 찾는 것이다. 이러한 한 과정은 최종 오차가 설계 범위에 도달할 때까지 반복되거나 정해진 횟수만큼 반복하여 ANFIS 를 훈련한다.⁽⁴⁾

3.3.4 ANFIS 훈련

ANFIS 훈련에 필요한 데이터는 입력변수 공간에 걸쳐 고르게 데이터가 분포하는 것이 가장 좋으나 이는 사실상 불가능하므로 단기간의 냉동기 성능진단 시험 결과를 토대로 신뢰성 있는 ANFIS 모델을 구축하는 방안이 강구되어야 한다. 여름 성수기보다는 비성수기에 냉동기를 진단하여 필요한 조치를 취하는 것이 바람직한 방안이나 외기 온도가 낮은 겨울철과 같은 경우에는 증발기측 부하가 없어 냉동기를 전부하 범위에 걸쳐 시험할 수 없으므로 정확한 냉동기 진단이 불가능하다. 본 연구에서는 6 월부터 9 월까지 수집된 데이터를 토대로 냉동기 진단에 필요한 데이터의 조건에 대하여 연구해 본다.

4. ANFIS 적용 및 결과 분석

4.1 훈련 데이터가 ANFIS 모델에 미치는 영향

Fig. 5(a)는 6 월초의 4 일 동안 수집한 데이터에 대하여 식 (3)의 함수관계를 모사한 ANFIS 모델의

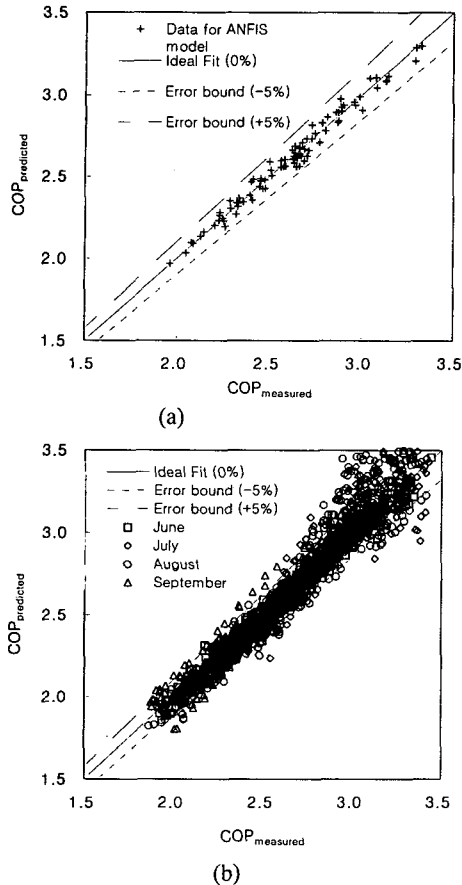


Fig. 5 (a) Fitting performance of ANFIS trained with the data sampled during June 1st, 3rd, 5th and 7th of 2000 (b) prediction performance

근사성능($COP_{predicted}$)과 식 (1)에 의해 측정된 성능계수 $COP_{measured}$ 와의 관계를 나타낸다. ANFIS 훈련에 사용된 동일한 데이터를 근사하는 정도가 약 $\pm 5\%$ 범위에 드는 것을 알 수 있다. 이렇게 훈련된 모델을 이용하여 예측한 냉동기 성능과 6월부터 9월까지의 냉동기 성능 측정 데이터를 비교한 결과가 Fig. 5(b)에 나타나 있다. 결과에서 알 수 있듯이 성능 예측 오차는 $\pm 5\%$ 를 약간 상회하는 정도이며 성능계수가 높은 고부하 영역에서는 오차가 증가함을 알 수 있다. Fig. 5(a)와 (b)를 비교해 보면 예측 오차가 큰 (b)의 높은 성능계수 영역에 해당하는 (a)의 영역에 훈련 데이터가 부족함을 알 수 있다. 이는 6월의 증발기측 부하가 작은 관계로 냉동기가 고부하로 운전되는 사례가 적어 훈련에 필요한 데이터가 부족하였기 때문이다. 이러한 문제점을 확인하기 위하여 8월중 18일간의 데이터를 이용하여 ANFIS를 훈련시킨 결과를 Fig. 6

에 나타내었다. Fig. 6(a)는 해당 모델의 훈련결과를 나타낸다. Fig. 5(a)의 경우처럼 실험오차 때문에 오차범위는 대략 $\pm 5\%$ 이다. 하지만 냉동기가 운전될 수 있는 대부분의 영역에 대한 시험 데이터가 포함되어 있는 관계로 Fig. 6(b)에서 보는 바와 같이 6월부터 9월까지의 데이터에 대하여 $\pm 5\%$ 오차 범위로 성능 예측을 하고 있음을 알 수 있다.


Fig. 5와 6의 결과에서 알 수 있듯이 ANFIS 예측 성능을 개선하기 위해서는 모든 부하 영역에서 충분한 데이터를 갖추고 있어야 한다. 냉동기 성능 진단이 가능한 시기와 적정한 데이터 측정 기간을 파악하기 위하여 6, 7 및 9월 중의 데이터도 수집하였다. 수집한 데이터를 이용하여 훈련한 ANFIS의 예측성능을 Fig. 7-9에 걸쳐 나타내었다. 6월과 7월의 경우에도 데이터 수집일 수가 열흘 이상이 되면 냉동기 진단에 필요한 고부하 영역(COP가 높은 영역)의 데이터가 존재하여 훈련된 ANFIS의 신뢰성을 향상시킨다. 그러나, peak 냉방부하가 적은 9월의 경우 열흘 간의 데이터 수집에도 불구하고 고부하 영역 데이터의 부족으로 인하여 고부하 영역에서의 예측성능이 저하됨을 알 수 있다.

Fig. 5에서 9까지의 결과를 정리하면 현장에서 데이터 수집 시 데이터의 실시간 모니터링이 가능하면서 10분 평균 데이터를 화면에 나타낼 수 있어야 한다. 냉동기 진단 경험사례가 많아지면 경험에 의하여 준정상 상태 조건에 부합한 10분 평균 데이터의 축적 상황을 보고서 ANFIS 훈련에 필요한 데이터의 적합성을 판단할 수 있다. 냉동기 진단용 PC가 네트워크상에 연결되어 있는 경우에는 원격으로 냉동기 진단 전문가가 훈련 데이터의 적정성을 판단하고 동시에 해당 냉동기의 성능도 예측하는 것이 가능할 것이다.


4.2 ANFIS 모델에 의한 냉동기 성능 예측

아래의 Fig. 10은 Fig. 5-9에 걸쳐 훈련된 ANFIS 모델들을 이용하여 냉동기 표준조건에서 예측된 냉동기 성능의 비교를 보여준다. 냉동기 시험 표준조건⁽¹¹⁾에 따르면, 냉각수 입구 온도 T_{cwi} 및 냉수 출구온도 T_{cwo} 가 각각 32°C , 7°C 로 유지해야 한다.

Fig. 10에 따르면 데이터가 부족했던 6월초 4일간의 데이터에 의해 훈련된 ANFIS는 다른 ANFIS들에 비해 상대적으로 오차가 크게 발생하여 성능 예측결과를 신뢰할 수 없다. 고부하 영역 운전 데이터가 일부 부족했던 Fig. 9에 해당하는 9월의 경우 나머지 6, 7, 8월 데이터에 의한 예측결과와 유사하나 고부하 영역에서 약 8%의 오차를 나타




(a)

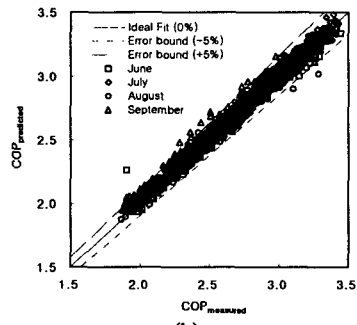


(b)

Fig. 6 ANFIS training (a) training data sampled during 18 days in August of 2000 (b) prediction performance




(a)




(b)

Fig. 8 ANFIS training (a) training data sampled during 10 days in July of 2000 (b) prediction performance




(a)




(b)

Fig. 7 ANFIS training (a) training data sampled during 13 days in June of 2000 (b) prediction performance



(a)



(b)

Fig. 9 ANFIS training (a) training data sampled during 10 days in September of 2000 (b) prediction performance




Fig. 10 Comparison of COP predicted at the standard test condition⁽¹¹⁾ according to ANFIS trained for the data sets obtained over June through September

내고 있다.

13 일간의 데이터를 축적하여 ANFIS 모델을 훈련시킨 Fig. 7 의 6 월의 경우도 7 월 및 8 월의 결과와 유사한 결과를 얻을 수 있었다. 결론적으로 peak 냉방부하가 존재하는 6 월부터 8 월 말까지는 열흘 정도면 냉동기 진단에 필요한 모든 부하 영역의 데이터를 취득할 수 있음을 의미한다. 9 월의 경우에는 추가적인 연구가 필요하긴 하지만 초순을 벗어나면 충분한 데이터를 얻지 못한 가능성이 있다. 이 이외의 기간에서는 고부하 영역 데이터의 부족으로 COP 의 정확한 예측이 불가능하다.

5. 결론

건물 에너지 비용을 많은 부분을 차지하는 냉동기 성능진단을 위해서는 부분부하에서의 냉동기 성적계수를 파악하여야 한다. 현장에 설치된 냉동기를 표준조건으로 운전하며 부하 별 성적계수를 측정하는 것이 불가능하므로 본 연구에서는 현장에서 얻어진 운전데이터를 토대로 표준조건에서 부하 별 성적계수를 예측하기 위한 인공지능망 설계방안을 실험적으로 연구하였고 얻어진 결론은 다음과 같다.

(1) 현장에서 수집된 실시간 데이터를 토대로 냉동기 성능을 진단하고자 할 때, 냉수 출구온도 범위, $1/COP$ 와 $1/Q_c$ 간의 직선성을 고려한 준정상 상태 데이터의 추출이 가능하며 시간 평균 간격은 최소 10 분 이상이 요구된다.

(2) 정상상태 냉동기 성능해석에 대한 열역학적 경험식과 비교해 볼 때, 퍼지 규칙 수는 입력변수 별 2 개가 적절하며 그 이상이 되면 계산량이 급증하며 과도근사의 경향이 있다. 냉동기 성능 진단에 ANFIS 가 유용하게 사용되기 위해서는 열역학적

해석결과나 경험식을 최대한 활용해야 한다.

(3) ANFIS 훈련에 필요한 데이터는 냉동기의 모든 운전범위에 걸쳐 고르게 분포해야 좋은 예측 성능을 기대할 수 있다. 늦은 봄과 초가을에 해당하는 6 월초(Fig. 5) 및 9 월 (Fig. 9)의 데이터에서는 고부하 영역의 운전 데이터 부족으로 고부하 영역 예측 성능의 신뢰도가 저하하고 있다. ANFIS 의 양호한 훈련을 위해서는 6 월부터 8 월 사이에 열흘 이상의 데이터 수집이 필요하다. 이 때, 예측성능 오차범위는 실험오차 범위인 $\pm 5\%$ 이내이다.

참고문헌

- (1) Centrifugal and Rotary Screw Water - Chilling Packages (CRWC), 2002, from <http://www.ariprinenet.org/ari-prog/direct.nsf>.
- (2) Swider, D.J., Browne, M.W., Bansal, P.K., Kecman, V., 2002, "Modelling of vapour-compression liquid chillers with neural networks," *J. of Applied Thermal Engineering*, Vol. 21, pp. 311-329.
- (3) A. Palau, E. Velo, L. Puigjaner, 1999, "Use of neural networks and expert systems to control a gas/solid sorption chilling machine," *Int. J. of Refrigeration*, Vol. 22, No. 1, pp. 59-66.
- (4) Jang, J.-S. R., 1993, "ANFIS: Adaptive-Neural-based Fuzzy Inference Systems," *IEEE Transactions on Systems, Man, and Cybernetics*, Vol. 23, No. 3, pp. 665-685.
- (5) Jang, J.-S. R., 1991, "Fuzzy Modeling Using Generalized Neural Networks and Kalman Filter Algorithm," *Proc. of the Ninth National Conf. on Artificial Intelligence (AAAI-91)*, pp. 762-767.
- (6) T. Takagi and M. Sugeno, 1985, "Fuzzy Identification of Systems and its Application to Modeling and Control," *IEEE Transactions on Systems, Man & Cybernetics*, Vol. 15, pp. 116-132.
- (7) Browne, M. W. and Bansal, P. K., 1998, "Steady-state model of centrifugal liquid chillers," *Int. J. of Refrigeration*, Vol. 21, No. 5, pp. 343-358.
- (8) Gordon, J. M., Ng K. C., and Chua, H. T., 1995, "Centrifugal chillers: thermodynamic modeling and a diagnostic case study," *Int. J. of Refrigeration*, Vol. 18, No. 4, pp. 253-257.
- (9) Beyene A., Guven, H., Jawdat Z., and Lowrey, P., 1994, "Conventional chiller performances simulation and field data," *Int. J. Energy Research*, Vol. 18, pp. 391-399.
- (10) M.W. Browne and P.K. Bansal, 2000, "Modeling of In-Situ Liquid Chillers," *Eighth International Refrigeration Conference at Purdue University*, pp. 425-432.
- (11) Korean Standard, 1985, "KS B 6270-85 Centrifugal Chiller," *Agency for Technology and Standards*.