

냉동기 성능 진단을 위한 적응형 뉴로퍼지(ANFIS) 모델 개발

신영기* · 장영수** · 김영일**

Prediction of Vapor-Compressed Chiller Performance Using ANFIS Model

Younggy Shin, Young-Soo Chang and Youngil Kim

Key Words : Centrifugal chillers (터보냉동기), ESCO (에너지 절약 전문기업), Artificial neural network (인공 신경망), ANFIS (적응형 뉴로퍼지), COP (성능계수)

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 the 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
T	: 온도
Q_e	: 냉동기 처리부하
μ	: 퍼지 멤버쉽 함수
	하첨자
A	: 퍼지 규칙
ewo	: 증발기측 냉수 출구온도
cwi	: 응축기측 냉각수 입구온도

1. 서론

대부분의 상업용 빌딩, Clean room, 공장 등에서

증발기측 부하 처리에 사용되는 대용량 터보 냉동기는 건물 연간 에너지 소비의 중요한 부분을 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 중대형 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 필요한 준정상상태 (quasi-steady state)의 데이터를 추출해야 한다. 마지막으로 추출된 데이터로부터 표준조건에서의 성능계수 예측을 위한 냉동기 성능해석 프로그램이 개발되어야 한다. 본 연구에서는 위에

* 세종대학교 기계공학과

** 한국과학기술연구원 열유동제어 연구센터

서 서술한 기술적 과제들에 대한 대안을 모색하고자 한다.

특히 중요한 부분은 성능예측 프로그램으로서 모델의 예측 정확도를 높이고 각종 부속기기의 성능 특성까지 감안하기 위해서는 프로그램이 복잡해지고 모델링에 필요한 변수 값들을 정하는 것도 간단한 일이 아니다. 따라서 이러한 범위의 시뮬레이션 작업은 세계적으로 시장점유도가 높은 일부 회사에서만 진행되고 있다. 접근방법은 열역학, 열전달 이론 및 실험데이터에 의거한 경험식을 이용한 프로그램으로서 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 많아 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 뉴로퍼지 추론체계(ANFIS; adaptive neuro-fuzzy inference system)^(4,5)를 이용한 성능진단 프로그램을 제시한다.

2. 적응형 뉴로퍼지 추론체계(ANFIS)

ANFIS는 Jang⁽⁴⁾에 의해 제안된 인공 신경망에 기반을 둔 적응형 퍼지 추론 체계이다. 냉동기의 성능처럼 시스템이 복잡하여 수학적 모델링이 곤란하거나 불확실성이 많은 경우에는 문제 해결을 위하여 전문가의 경험적 사고에 의존한다. 이러한 전문가의 경험적 판단체계를 모델링하는 방법의 하나가 퍼지 추론체계이다. 인간의 사고에서는 판단에 필요한 조건부가 정량적으로 엄밀히 정의된 것이 아니라 가령 크다 또는 작다 등의 언어적 표현을 쓰며 그에 상응한 결론부도 높다, 적당하다 등의 언어적 표현을 사용한다. 퍼지 이론은 이러한 언어적 표현을 멤버쉽 함수 (membership function)로 대체한다. 결론부에서는 정량적인 값 (crisp value)을 얻기 위하여 퍼지연산을 수행한다. 결론부 연산 방법 중 Takagi and Sugeno⁽⁶⁾가 제안한 기법은 추론 결과치가 입력값들의 선형조합이며 계수들은 각 퍼지 규칙출

력의 가중 평균치이기 때문에 Memrdani et al.⁽⁷⁾등의 결론부 연산방법에서는 불가능하였던 결론부와 조건부 간의 수학적 상관성 연산이 가능하게 되었다.⁽⁶⁾

다음의 Fig.1은 Takagi and Sugeno의 퍼지추론 체계와 그와 동등한 뉴럴 네트워크인 ANFIS의 구조를 보여준다. ANFIS는 뉴럴네트워크의 특징인 자기 학습능력을 이용하여 퍼지 규칙부의 변수들이 최종 출력을 추종하도록 학습될 수 있다. 주어진 학습데이터를 모사하기 위해 혼합형 알고리즘을 사용하여 Sugeno 타입 추론체계를 최적화한다.

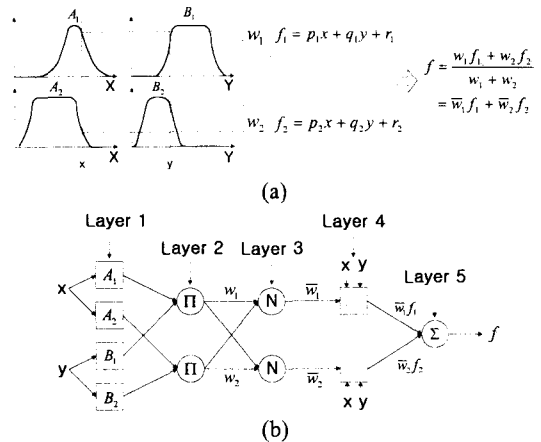


Fig. 1 (a) Takagi-Sugeno type fuzzy inference system (b) Equivalent neural network (ANFIS)

이 알고리즘은 인공 신경망 (artificial neural network)의 주요 구성 요소인 최소 오차자승법과 기울기 감소 오차역전법 (backpropagation gradient descent method)을 조합하여 사용한다. 조건부의 비선형인 멤버쉽 함수와 관련된 변수들은 훈련과정을 통하여 갱신된다. 이러한 변수의 계산 또는 조정은 퍼지 추론 체계가 주어진 데이터를 얼마나 잘 모사하고 있는지를 판단하는 척도인 기울기 벡터에 의해 수월해진다. 일단 기울기 벡터가 구해지면, 최적화 루틴이 적용되어 예측치와 비교치의 오차가 최소가 되도록 해당 변수들이 조정된다. 결론부는 Sugeno 타입으로서 선형이므로 최소오차 자승법을 적용한다.

3. 실험장치 및 방법

3.1 실험장치

KIST 내 청정 연구동은 연면적 6655.4 m²의 4층 건물로, 내부에 고정정을 요구하는 실험을 수행할 수 있는 청정실험실이 있다. 지하 기계실에

는 200 RT 급의 터보 냉동기가 3대 설치되어 있으며 연구에 사용된 데이터는 이 냉동기로부터 얻어졌다. 터보 냉동기에서 만들어진 냉수는 클린룸의 부하처리를 위한 2대의 AHU(Air Handling Unit)와 연구실과 실험실의 냉방을 위한 2대의 AHU, 각 연구실의 FCU에 공급되고, 일부 실험장비의 냉각 수도도 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 각도를 조절하여 용량제어가 가능하다. IGV의 개도는 압축기 소비전력과 냉수온도에 의해 제어되어 부하변동에 관계없이 일정한 온도의 냉수를 공급할 수 있도록 한다.

3.2 성능 측정 방법

냉동용량의 측정은 증발기의 2차 유체인 냉수의 유량과 입출구 온도차를 측정하여 구하였다. 입출구 온도는 T-type 열전대를 배관 내에 설치하여 측정하였고 유량은 배관표면에 장착된 초음파 유량계를 이용하였다. 냉동기의 소비전력은 모터에 인가하는 전원의 전압, 전류, 역률을 측정하여 구하였다. 데이터는 1분 간격으로 샘플링 되었다. Yokogawa 사의 데이터 로거를 이용하여 처리된 온도 및 유량 신호 그리고 전력계 측정 정보는 모두 RS485 통신을 통한 multi-drop 방식으로 PC로 전송되었으며 NI사의 LabVIEW® 프로그램을 이용하여 데이터 통신 및 처리 프로그램을 작성하였다. 냉동용량과 성능계수 측정시 실험오차는 Klein and McClintock⁽⁸⁾이 제안한 방법에 의하면, 평균적인 조건에서 각각 5.4%, 5.6%이다.

4. 데이터 처리

ANFIS의 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 확인할 수 없다. 이러한 단점을 보완하기 위해서는 해석대상에 대한 사전 정보를 이용하여 ANFIS 훈련에 사용될 데이터를 필터링할 필요가 있다. 열역학 기반 성능예측 모델링에 관한 많은 연구 논문들⁽⁹⁻¹¹⁾의 공통적 결론은 정상상태 운전조건 하에서 성능계수의 역수 $1/COP$ 와 증발기축 부하의 역수 $1/Q_e$ 는 다음과 같은 경

험적 선형관계를 갖는다는 것이다.

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

선형적 관계의 원인은 정상상태 하에서 냉동기의 응축기와 증발기의 열교환 과정에서 발생하는 비가역성이 증발기축 부하 Q_e 에 비례하는 특성을 나타내기 때문이다. 이러한 경험적 사실은 측정된 데이터로부터 성능 예측에 필요한 준정상 상태의 데이터를 추출하는데 유용한 정보가 된다. ANFIS의 훈련을 위해서는 수 일간의 데이터로부터 모든 증발기축 부하 영역에 대하여 최대한 많은 준정상 상태 데이터를 추출해야 하며 이는 1분 간격으로 측정된 데이터의 적분 평균 시간을 최대한 작게 해야 함을 의미한다. Browne and Bansal⁽¹²⁾의 동특성 실험결과에 의하면 200RT 급 스크류 냉동기의 시상수는 약 2분 정도 이었다. 본 연구에서는 이 시상수 크기를 감안하여 비정상 상태의 영향을 최소화하기 위해 1분 간격으로 측정된 데이터를 10분 평균하였다. 5분, 15분, 20분 평균 등을 시도하였으며 데이터 분석결과에 의하면 정상상태에 근사하면서 취할 수 있는 최소 시간 평균은 10분 정도임을 경험적으로 파악하였다. 기동, 정지 등과 같은 비정상 상태 구간 운전결과와 평균치는 정상상태의 값에서 벗어나게 되며 이러한 비정상 상태의 값들을 배제하기 위해 다음과 같은 조건을 적용하였다: 1) 냉수 출구온도가 설계 정상상태 온도(본 연구 장치에서는 $7.5^\circ\text{C} \pm 0.5^\circ\text{C}$ 편차의 범위를 벗어나거나, 2) 열역학적 경험식 (1)의 직선성에서 벗어날 때.

Fig. 2는 6월초 4일간(1,3,5,7일)에 걸쳐 취득한 데이터 중에서 냉동기가 운전되는 구간에서만 10분 평균하여 얻어진 성능계수와 증발기축 부하의 관계를 나타낸다. Fig. 2(a)는 계측된 10분 평균 데이터를 모두 나타낸 것이고 Fig. 2(b)는 위의 준정상 조건에 드는 데이터만 필터링하여 나타낸 것이다.

5. ANFIS 기반 성능 예측 모델

5.1 입력변수의 선정

경험식 (1)의 함수관계를 보다 정량적으로 규명하기 위한 연구 결과들⁽⁹⁻¹¹⁾에 따르면, 식(1)은 냉각수 입구 온도 T_{cwi} , 냉수 출구온도 T_{ewo} 와 밀접한 관계가 있음을 알 수 있다. 마찬가지로 연관될 수 있는 냉각수 출구 온도 및 냉수 입구 온도는 냉각

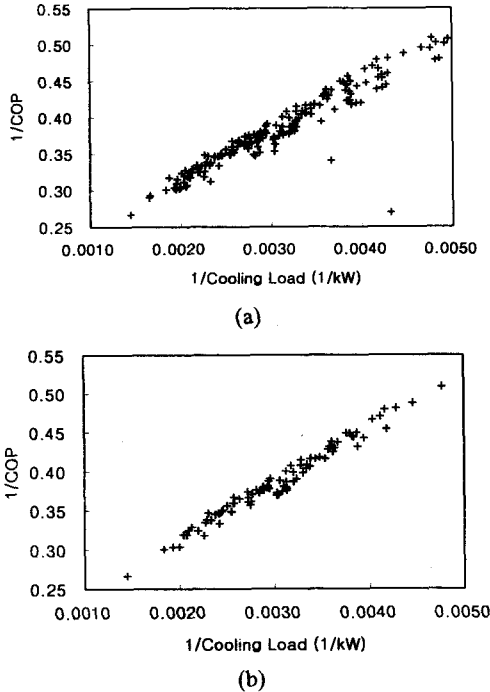


Fig. 2 10 minutes-average data points sampled during June 1st, 3rd, 5th and 7th of 2000 (b) data points filtered through the quasi-steady state criteria from the data points of (a)

처리 부하와 연동되며 열교환기 성능에 반영되므로 입력변수의 수를 줄이기 위해 일반적으로 생략된다. 따라서, ANFIS 기반 퍼지 모델은 다음과 같은 함수관계를 갖는 것으로 가정한다.

$$1/COP = f(1/Q_e, T_{cwi}, T_{ewo}) \quad (2)$$

보다 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.⁽⁹⁻¹²⁾

5.2 ANFIS 구조 설계

주어진 대상을 모사하기 위해 필요한 ANFIS 구조의 설정조건에 대해서는 일정한 규칙이 없다. ANFIS 운용 예에 따르면^(4,5), 멤버십 함수형태로서 일반화된 종함수 (generalized bell function)가 선호되므로 본 연구에서도 같은 함수를 선택하였다. 입력변수는 식 (2)에 주어진 3개의 변수로 정하였으며 각 입력변수 별로 필요한 멤버십 함수의 수

는 2개로 설정하였다. 입력변수 별로 3개의 멤버십 함수를 설정한 경우, 훈련된 ANFIS는 실제 냉동기의 특성을 다소 over-fitting 하였다. 열역학 모델에 근거한 성능계수의 거동을 보면 해당 입력변수들의 영향이 선형에 가까웠으므로 멤버십 함수의 수도 이에 근사하도록 2개로 설정하는 것이 모델과 실험결과의 오차를 줄일 수 있었다. 결과적으로 적용된 ANFIS의 구조는 Fig. 3과 같다.

Fig. 3에서 퍼지 규칙의 수는 $2^3 = 8$ 개, 노드의 수는 34개이다. 조건부의 멤버십 함수 (비선형 종함수)와 관련된 비선형 변수의 개수는 $6 \times 3 = 18$ 개, Sugeno 형태의 추론법에 의한 결론부의 선형 변수의 개수는 $8 \times 4 = 32$ 개다. ANFIS의 훈련은 조건부 및 결론부의 50개 변수의 최적치를 구하는 것을 의미한다. ANFIS에서 제안된 혼합형 훈련규칙은 주어진 훈련 데이터 집합에 대하여 결론부 선형 변수들을 최소 오차자승 기법으로 구한 후, 결정된 선형 변수 값들에 대하여 오차의 변화율을 입력부로 역전시켜(back-propagation) 비선형 변수 값들을 gradient descent 기법으로 찾는 것이다. 이러한 과정은 최종 오차가 설계 범위에 도달할 때까지 반복되거나, 정해진 횟수만큼 반복하여 ANFIS를 훈련한다.⁽⁴⁾

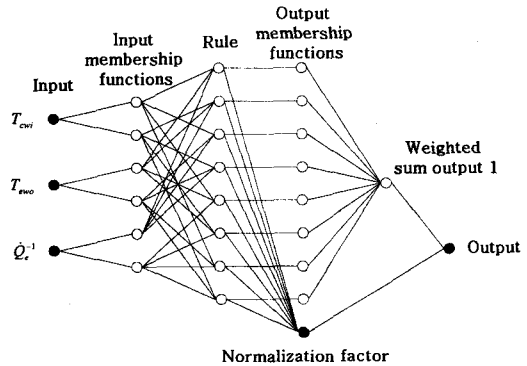


Fig. 3 The ANFIS architecture for the prediction of chiller performance

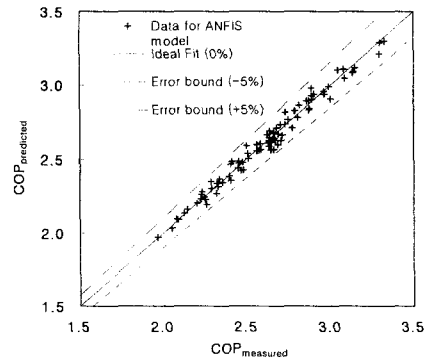
5.3 ANFIS 훈련

ANFIS 훈련에 필요한 데이터는 입구변수 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.

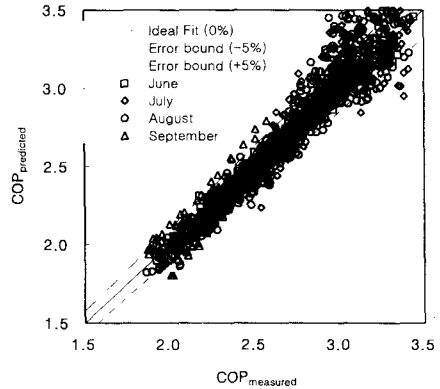
본 연구에서는 6월부터 9월까지 수집된 데이터를 토대로 냉동기 진단에 필요한 데이터의 조건에 대하여 연구해 본다.

Fig. 4(a)는 6월초의 4일 동안 수집한 데이터를 이용하여 구성된 ANFIS 모델의 근사성능을 나타낸다. ANFIS 훈련에 사용된 동일한 데이터를 근사하는 정도가 약 $\pm 5\%$ 범위에 드는 것을 알 수 있다. 이는 전술한 Klein과 McClintock가 제안한 방법에 의한 실험측정 오차가 약 5%임과도 관련이 있다. 따라서, 오차를 줄이기 위한 추가적 노력은 의미가 없다. 이렇게 훈련된 모델을 이용하여 예측한 냉동기 성능과 6월부터 9월까지의 냉동기 성능 측정 데이터를 비교한 결과가 Fig. 4(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. 4(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.5에 나타내었다. Fig.5(a)는 해당 모델의 훈련결과를 나타낸다. Fig.4(a)의 경우처럼 실험오차 때문에 오차범위는 대략 $\pm 5\%$ 이다. 하지만 냉동기가 운전될 수 있는 대부분의 영역에 대한 시험 데이터가 포함되어 있는 관계로 Fig. 5(b)에서 보는 바와 같이 6월부터 9월까지의 데이터에 대하여 $\pm 5\%$ 오차 범위로 성능 예측을 하고 있음을 알 수 있다.

Fig.4와 5의 결과에서 알 수 있듯이 ANFIS 예측 성능을 개선하기 위해서는 모든 부하 영역에서 충분한 데이터를 갖추고 있어야 한다. 냉동기 성능진단이 가능한 시기와 적절한 데이터 측정 시간을 파악하기 위하여 6, 7 및 9월중에 데이터도 수집하였다. 수집한 데이터를 이용하여 훈련한 ANFIS의 예측성능을 Fig. 6-8에 걸쳐 나타내었다. 6월과 7월의 경우에도 데이터 수집 일수가 열흘 이상이 되면 냉동기 진단에 필요한 고부하 영역(COP가 높은 영역)의 데이터가 존재하여 훈련된 ANFIS의 신뢰성을 향상시킨다. 그러나, peak 냉방 부하가 적은 9월의 경우 열흘 간의 데이터 수집에도 불구하고 고부하 영역 데이터의 부족으로 인하여 고부하 영역에서의 예측성능이 저하됨을 알 수 있다.



(a)



(b)

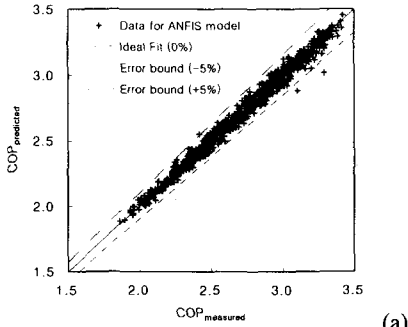
Fig. 4 (a) Fitting performance of ANFIS trained with the data sampled during June 1st, 3rd, 5th and 7th of 2000 (b) prediction performance

Fig.4에서 8까지의 결과를 정리하면 현장에서 데이터 수집 시 데이터의 실시간 모니터링이 가능하면서 10분 평균 데이터를 화면에 나타낼 수 있어야 한다. 냉동기 진단 경험 사례가 많아지면 경험에 의하여 준정상 상태 조건에 부합한 10분 평균 데이터의 축적 상황을 보고서 ANFIS 훈련에 필요한 데이터의 양부를 판단할 수 있다. 냉동기 진단용 PC가 네트워크에 연결되어 있는 경우에는 원격으로 냉동기 진단 전문가가 훈련 데이터의 적정성을 판단하고 동시에 해당 냉동기의 성능도 예측하는 것이 가능할 것이다.

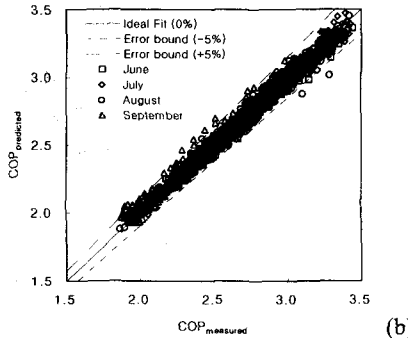
5.4 ANFIS 모델에 의한 냉동기 성능 예측

아래의 Fig.9은 Fig. 4-8에 걸쳐 훈련된 ANFIS들을 이용하여 냉동기 표준조건에서 예측된 냉동기 성능의 비교를 보여준다. 냉동기 시험 표준조건⁽¹³⁾에 따르면, 냉각수 입구 온도 T_{cwi} 및 냉수 출구 온도 T_{cwo} 가 각각 32°C , 7°C 로 유지되어야 한다.

Fig. 9에 따르면 데이터가 부족했던 6월초 4

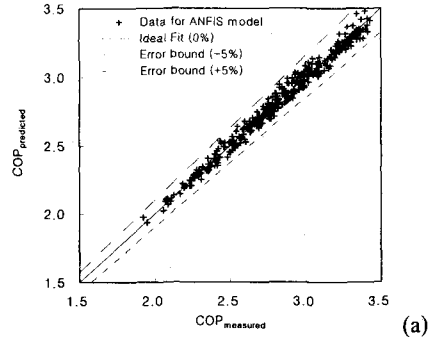


(a)

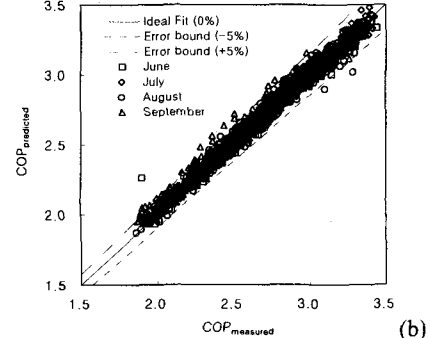


(b)

Fig. 5 ANFIS training (a) training data sampled during 18 days in August of 2000 (b) prediction performance

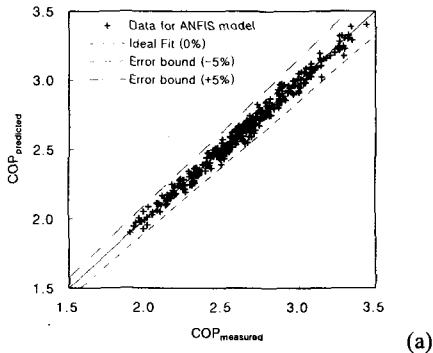


(a)

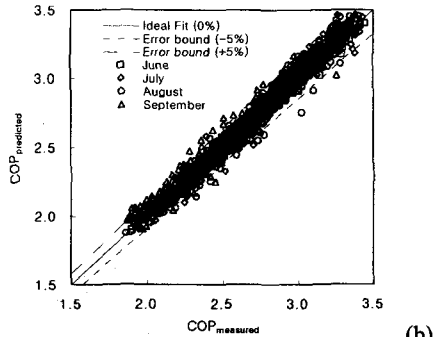


(b)

Fig. 7 ANFIS training (a) training data sampled during 10 days in July of 2000 (b) prediction performance

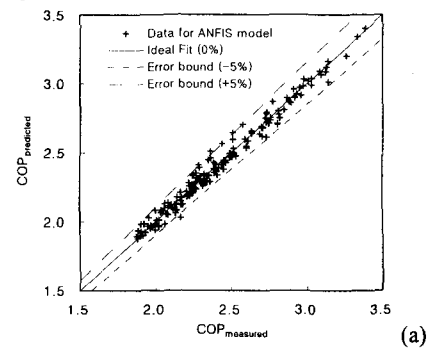


(a)

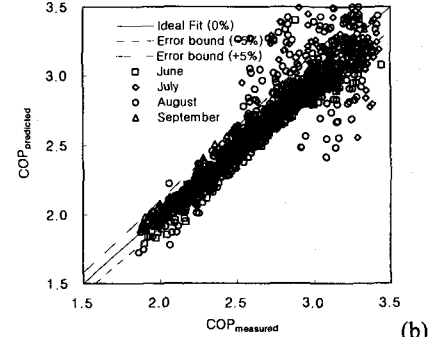


(b)

Fig. 6 ANFIS training (a) training data sampled during 13 days in June of 2000 (b) prediction performance



(a)



(b)

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

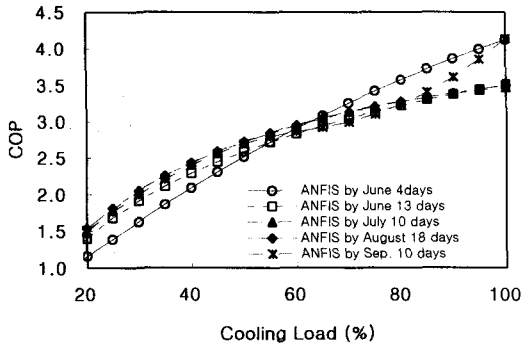


Fig. 9 Comparison of COP predicted at the standard test condition⁽¹³⁾ according to ANFIS trained in Fig.4 through 8

일간의 경우와 고부하 영역 운전 데이터가 일부 부족했던 9월의 경우 6, 7, 8월 데이터에 의한 예측결과와 상이하여 결과를 신뢰할 수 없다. 이는 부하 전 영역에 걸쳐 시험데이터가 분포하지 않기 때문이다. 결과적으로 peak 냉방부하가 존재하는 6월부터 8월 말까지는 경험적으로 열흡 정도면 냉동기 진단에 필요한 모든 부하 영역의 데이터를 취득할 수 있음을 의미한다. 9월의 경우에는 추가적인 연구가 필요하긴 하지만 초순을 벗어나면 충분한 데이터를 얻지 못한 가능성이 있다. 이 이외의 기간에서는 고부하 영역 데이터의 부족으로 COP의 정확한 예측이 불가능하다.

6. 결론

냉동기의 성능 진단을 위한 ANFIS 알고리즘의 적용 결과 다음과 같은 결론을 얻었다.

- (1) 냉수 출구온도 범위, 1/COP와 1/Q_c 간의 직선성을 고려한 준정상 상태 데이터의 추출이 가능하며 시간 평균 간격은 최소 10분 이상이 요구된다.
- (2) 퍼지 규칙 수는 입력변수 별 2개가 적절하며 그 이상이 되면 계산량이 급증하며 overfitting의 경향이 있다. 냉동기 성능 진단에 ANFIS가 유용하게 사용되기 위해서는 열역학적 해석결과나 경험식 등을 최대한 활용해야 한다.
- (3) ANFIS 훈련에 필요한 데이터는 냉동기의 모든 운전범위에 걸쳐 고르게 분포해야 좋은 예측 성능을 기대할 수 있다. 연구결과, 6월부터 8월 사이에 열흡 이상의 데이터 수집이 필요하다. 이 때, 예측성능 오차범위는 실험오차 범위인 ±5% 이내이다.

본 연구는 과학기술부 특정연구개발사업 중 중점국가연구개발사업(기체설비요소기술개발)의 지원으로 수행되었습니다.

참고문헌

- (1) Centrifugal and Rotary Screw Water - Chilling Packages (CRWC) from <http://www.ariprimenet.org/ari-prog/direct.nsf>
- (2) Swider, D.J., Browne, M.W., Bansal, P.K., Kecman, V., Modelling of vapour-compression liquid chillers with neural networks, *J. of Applied Thermal Engineering* 21 (2001) 311-329
- (3) A. Palau, E. Velo, L. Puigjaner, Use of neural networks and expert systems to control a gas/solid sorption chilling machine, *Int J. Refrig* 22 (1) (1999) 59-66.
- (4) Jang, J.-S. R., ANFIS: Adaptive-Network-based Fuzzy Inference Systems, *IEEE Transactions on Systems, Man, and Cybernetics*, Vol. 23, No. 3, pp. 665-685, May 1993.
- (5) Jang, J.-S. R., Fuzzy Modeling Using Generalized Neural Networks and Kalman Filter Algorithm, *Proc. of the Ninth National Conf. on Artificial Intelligence (AAAI-91)*, pp. 762-767, July 1991.
- (6) T. Takagi and M. Sugeno, Fuzzy Identification of Systems and its Application to Modeling and Control, *IEEE Transactions on Systems, Man & Cybernetics*, vol. 15, 116-132, 1985.
- (7) E.H. Mamdani, J.J. Ostergaard, E. Lembessis, Use of Fuzzy Logic for Implementing Rule-based Control of Industrial Processes, *Advances in Fuzzy Sets, Possibility Theory, and Applications*, Plenum Press, pp. 307-323, 1983
- (8) Klein, S. J. and McClintock, F. A., 1953, "Describing uncertainties in single sample experiments," *Mech. Eng.*, Vol. 75, pp. 3-8.
- (9) Browne, M. W. and Bansal, P. K., 1998, "Steady-state model of centrifugal liquid chillers," *Int. J. Refrig.*, Vol. 21, No. 5, pp. 343-358.
- (10) Gordon, J. M., Ng K. C., and Chua, H. T., 1995, "Centrifugal chillers: thermodynamic modelling and a diagnostic case study," *Int. J. Refrig.*, Vol. 18, No. 4, pp. 253-257.
- (11) 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.
- (12) M.W. Browne and P.K. Bansal, Modelling of In-Situ Liquid Chillers, Eighth International Refrigeration Conference at Purdue University, pp. 425-432, West Lafayette, IN, USA, July 2000
- (13) 한국공업규격, KS B 6270-85 원심 냉동기, 공업진흥청, 1985.