
신경회로망을 이용한 증기표의 함수근사

이태환* · 박진현*

Function approximation of steam table using the neural networks

Tae-Hwan Lee* · Jin-Hyun Park*

요약

열성능 평가를 위한 수치해석에서는 온도, 압력, 건도, 체적, 엔탈피, 엔트로피 등의 열역학적 성질들의 수치값이 필요하다. 그러나 이러한 성질들을 포함하고 있는 증기표를 그대로 사용할 수 없기 때문에, 효과적으로 모델링하여야 한다. 이러한 관점에서 함수근사 특성을 가진 신경회로망을 하나의 대안으로 검토하였다. 신경회로망은 포화증기 영역과 과열증기 영역에 대해서 따로 구성하였다. 포화증기 영역에 대해서는 하나의 입력으로 7개의 출력을 얻을 수 있도록 하였으며, 각각 10개와 20개의 노드를 가진 은닉층을 구성하였다. 과열증기 영역에 대해서는 2개의 입력으로 3개의 출력을 얻을 수 있도록 하였으며, 각각 15개와 25개의 노드를 가진 은닉층을 구성하였다. 제안된 모델은 온도, 엔탈피, 엔트로피의 백분율오차가 대부분 $\pm 0.005\%$, 압력이나 비체적의 백분율오차도 대부분 $\pm 0.025\%$ 범위 내로 수렴시킬 수 있었다. 이 성공적인 결과로부터 증기표를 함수근사하는데 있어서 신경회로망이 아주 강력한 수단이 될 수 있음을 확인할 수 있었다.

ABSTRACT

Numerical values of thermodynamic properties such as temperature, pressure, dryness, volume, enthalpy and entropy are required in numerical analysis on evaluating the thermal performance. But the steam table itself cannot be used without modelling. From this point of view the neural network with function approximation characteristics can be an alternative. the multi-layer neural networks were made for saturated vapor region and superheated vapor region separately. For saturated vapor region the neural network consists of one input layer with 1 node, two hidden layers with 10 and 20 nodes each and one output layer with 7 nodes. For superheated vapor region it consists of one input layer with 2 nodes, two hidden layers with 15 and 25 nodes each and one output layer with 3 nodes. The proposed model gives very successful results with $\pm 0.005\%$ of percentage error for temperature, enthalpy and entropy and $\pm 0.025\%$ for pressure and specific volume. From these successful results, it is confirmed that the neural networks could be powerful method in function approximation of the steam table.

키워드

증기표(Steam table), 신경회로망(Neural network), 포화증기(Saturated vapor), 과열증기(Superheated vapor)

I. 서 론

전세계적으로 산업의 지속적인 발달은 에너지 소비량의 증가를 동반하며, 이는 배출가스로 인한 환경오염을 가속화시키고 있다. 최근에는 토쿄협약의 비준으로 각국에서는 배출가스의 감소를 위한 장·단기적 대책에 소홀 할 수 없는 심각한 상황이 되었다. 배출가스 감소를 위하여는 에너지 소비량을 줄이거나 환경오염 방지시설에 투자하는 직접적인 방법과 에너지를 소모하는 열장치(thermal equipment)의 효율을 향상시키는 간접적인 방법이 있다. 직접적인 방법은 효과적인 면에서 좋은 결과를 기대할 수 있지만, 경제발전에 저해요소로 작용하거나 원가상승으로 인한 기업의 경쟁력 약화로 이어질 수 있다는 단점이 있다. 이러한 단점을 보완할 수 있는 것이 열장치의 효율을 향상시키는 간접적인 방법이다.

열장치의 효율향상을 위한 선결조건은 설계단계에서 열성능(thermal performance)을 정확하게 예측하는 일이 될 것이다. 열장치 중에서 가장 대표적인 장치는 열교환기(heat exchanger)이며, 현재 열교환기의 성능예측을 위한 연구가 전세계적으로 활발하게 진행되고 있다[1-5].

열교환기는 주로 상변화(phase change)를 통한 잠열(latent heat)을 이용하여, 매질로는 에어콘(air conditioner) 등에서는 냉매(refrigerant), 발전소의 보일러(boiler) 등에서는 물(water)이 주로 사용된다. 이용되는 매질의 상(phase)은 주로 액상(liquid phase)과 기상(vapor phase)이며, 각각의 상이 단독적으로 존재하거나 혹은 혼합된 형태로 존재하기도 한다.

열교환기의 열성능 예측에는 이론해석이나 실험적인 방법보다는 정확성과 경제성을 두루 갖춘 수치해석이 선호도가 높다. 수치해석의 경우 먼저 매질의 열역학적 성질(thermodynamic properties)들에 대한 수치값을 알아야 하는데, 열역학적 성질들은 일정한 함수로 표현되지 않기 때문에 표[6]나 그래프의 형태로 제시된다. 그러나 증기표(steam table)나 그래프(chart)는 직접적으로 수치해석에서 이용할 수 없기 때문에, 함수근사(function approximation)하여야 한다. 따라서 증기표의 모델링은 열교환기의 효율과 성능예측에 지대한 영향을 미치게 되며, 그런 의미에서 매우 중요한 작업이라고 할 수 있다.

증기표를 곡선접합(curve fitting)하는데 있어서 열역학적 성질(thermodynamic properties) 사이의 관계를 결정하는 적절한 함수를 찾는 것이 관건이다. 변화폭이 큰 성질

에 대해서는 이런 함수를 찾기가 어려우므로 전체 구간을 몇 개의 소구간으로 나누어 곡선접합의 기술을 적용한다. 그러나 구간수가 적으면 전체적인 정밀도가 떨어지고, 구간수가 많으면 정밀도는 향상되지만 프로그램이 길어지고 복잡해진다는 단점이 있다. 가장 큰 단점은 두 구간의 경계에서 불연속이 생긴다는 점이다. 또한 반복법(iteration method)이 사용되기도 하는데 이 경우는 간접적인 방법이라고 할 수 있다.

증기표를 함수근사하는데 있어서 가장 중요한 점은 수치적인 정확성, 넓은 곡선접합 범위 및 직접적인 계산 등이라고 할 수 있다. 여기서는 기존 방법의 단점을 보완해줄 수 있는 대안으로서 신경회로망(neural network)[7-9]을 이용하여 증기표를 모델링하는 방법을 제안하고자 한다.

현재까지 증기표의 모델링에 신경회로망이 적용된 예는 없는 것으로 판단되며, 물의 습포화영역에 대하여는 본 저자에 의해서 제한적으로 적용된 바가 있다[10]. 본 연구에서는 신경회로망의 함수근사 특성을 물의 증기표 전체의 모델링에 적용하고자 한다.

II. 해석방법

증기표에서 구할 수 있는 열역학적 성질들에는 온도(temperature) T , 압력(pressure) P , 체적(volume) v , 엔탈피(enthalpy) h , 엔트로피(entropy) s , 건도(dryness) 혹은 질(quality) x 등이 있다. 체적, 엔탈피, 엔트로피 등의 용량성 성질(extensive property)들에 대하여는 총량을 질량으로 나눈 강도성 성질(intensive property)인 비성질(specific property)을 사용한다. 내부에너지(internal energy) u 도 또 다른 하나의 열역학적 성질이지만 증기표에는 잘 나타나지 않는다. 이것은 식(I)에서 구할 수 있는 양이기 때문이다.

$$u = h - Pv \quad (I)$$

그림 1은 물의 증기표의 각 성질들 사이의 관계를 횡축이 엔탈피 h , 종축이 압력 P 인 그래프로 나타낸 몰리에 차트(Mollier chart)이다. 성질들 사이의 관계가 아주 복잡하여 증기표의 함수근사가 쉽지 않음을 짐작할 수 있다.

물과 같이 상변화를 일으키는 물질은 낮은 온도(혹은 높은 압력)에서는 액체상태를 유지한다. 이 상태에서는

열을 가하여 온도상승(혹은 압력강하)이 일어나더라도 상변화를 동반하지는 않는다.

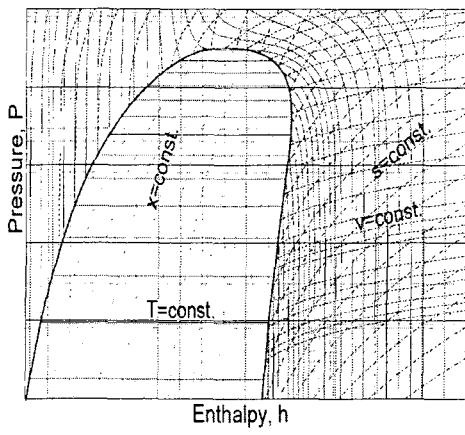


그림 1. 몰리에 차트
Fig. 1 Mollier chart

이 영역의 물을 압축수(compressed water) 혹은 과냉수(subcooled water)라고 부르며, 그림 1에 굵은 선으로 표시된 반타원형상의 원편 영역이다.

압축수상태에서 열을 가하여 온도상승(혹은 압력강하)이 일정한 상태에 도달하면, 온도(혹은 압력)의 변화는 일어나지 않고 단순히 액체상태의 일부가 기체상태로 변화하게 되어 액체와 기체가 공존하게 된다. 이 영역의 물을 포화(saturation)되었다고 말하며, 반타원형의 안쪽 영역이다. 액체만 존재하는 포화상태를 포화수(saturated water)라고 하며, 굵은 선으로 표시된 반타원의 원편 곡선이다. 기체만 존재하는 포화상태를 건포화증기(dry saturated vapor)라고 하며, 반타원형의 오른편 곡선이다. 이 두 곡선이 마주치는 꼭지점을 임계점(critical point)이라고 한다.

건포화증기상태의 물에 열을 가할 때 증기의 압력과 온도가 계속적으로 상승하게 되는데, 이 영역의 물을 과열증기(superheated vapor)라고 하며, 반타원형의 오른편 영역이다.

압축수는 에너지 상태가 낮기 때문에 본 연구에서는 포화증기와 과열증기만 취급한다.

습포화증기(wet saturated vapor)는 물과 증기가 공존하며, 이 상태에서는 포화온도가 결정되면 포화압력이 결정되고, 포화수나 건포화증기 각각에 대한 비체적, 엔트로피, 엔탈피가 결정된다. 그러나 액체와 기체가 공존하는

습포화증기에 대한 성질은 결정되지 않는다. 만약 건도를 알고 있다면, 습포화증기에 대한 열역학적 성질들은 다음의 식 (2)에 의해서 결정할 수 있다.

$$X = (1-x)X_f + xX_g \quad (2)$$

여기서 X 는 비성질(specific property)이며, 하침자 f 와 g 는 각각 포화수와 건포화증기를 나타낸다.

포화온도와 포화압력을 중복시키지 않는 한, 두 가지 성질을 알면 다른 성질들도 구할 수 있다. 그러나 습포화증기의 성질들은 식 (2)에 의해 결정할 수 있기 때문에 포화온도 혹은 포화압력에 대한 포화수와 건포화증기의 성질들을 구해서 식 (2)를 적용시키는 것이 편리하다. 따라서 포화온도와 건도, 혹은 포화압력과 건도 등의 두 성질을 입력으로 한 나머지 성질들을 구하는 것보다, 포화온도나 포화압력에 대한 포화수와 건포화증기의 성질들을 구해서 식 (2)를 적용하기로 한다.

과열증기 상태에서의 건도는 의미가 없으며, 온도와 압력도 상호의존적이지 않다. 따라서 온도, 압력, 비체적, 엔탈피, 엔트로피 등의 성질들 중에서 두 가지 성질만 알면 나머지 성질들을 구할 수 있다. 따라서 포화상태와 과열상태로 나누어서 해석을 진행하는 것이 효과적일 것으로 판단된다.

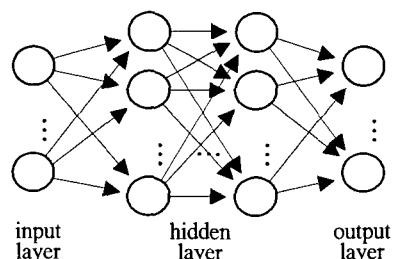


그림 2. 다층신경회로망
Fig. 2 Multi-layer neural network

일반적으로 신경회로망(neural network)은 함수근사(function approximation)에 적합하다고 알려져 있으며, 이러한 특성을 이용하여 증기표를 모델링한다. 본 연구에서 사용된 신경회로망의 구조는 그림 2와 같이 입력층(input layer), 은닉층(hidden layer), 출력층(output layer)으로 구성된 다층신경회로망(multi-layer neural network)이며, 각각

의 층은 다수의 노드(node)로 이루어진다. 또한 입력을 인가하였을 때 은닉층과 출력층의 출력을 구하는 활성화함수(activation function)는 쌍곡선함수(hyperbolic tangent function)를 선택하였으며, 신경회로망의 가중치 학습에는 오차역전파 알고리즘(error backpropagation algorithm)이 사용되었다.

III. 결과 및 고찰

물의 포화상태에서와 과열증기상태에서의 열역학적 성질들의 관계를 신경회로망을 사용하여 모델링하였다.

포화증기 영역의 열역학적 성질들을 구하기 위하여는 기본적으로 두 개의 열역학적 성질을 입력으로 주어야 한다. 이를 위한 방법에는 수많은 조합이 있을 수 있다. 그러나 증기표의 모델링에 신경회로망의 적용 가능성을 확인한다는 의미에서는 이 모든 조합에 대하여 확인할 필요는 없을 것으로 판단된다. 그래서 본 연구에서는 포화온도와 포화압력을 각각 입력으로 하는 두 가지 경우에 대해서만 고찰한다. 또한 완전한 열역학적 성질들을 얻기 위하여는 두 개의 입력이 필요하므로, 포화온도나 포화압력 외에 또 다른 성질(일반적으로 건도)을 입력으로 선택해야 한다. 이 방법은 필요한 성질들을 직접적으로 구할 수 있다는 장점이 있지만, 입력 데이터로 두 개의 성질을 사용하므로 모델링의 입력 데이터가 복잡해진다는 단점이 있다. 그러나 포화수와 진포화증기의 성질은, 포화온도나 포화압력 중 하나만을 입력으로 선정해도 얻을 수 있으며, 이를 바탕으로 식(2)를 이용한 단순 계산으로 습포화증기의 모든 건도에 대하여 열역학적 성질들을 결정지을 수 있다.

표 1은 입력이 포화온도인 경우와 포화압력인 경우의 출력을 보여준다. 출력 중에서 체적, 엔탈피, 엔트로피로 동일하다. 그러나 포화온도가 입력인 경우는 포화압력, 포화압력이 입력이 되는 경우는 포화온도가 출력이 된다는 점이 다르다. 따라서 하나의 입력에 7개의 출력이 발생한다.

표 1. 물의 성질(포화상태)
Table 1 Properties of water(saturated state)

	specification	
fluid	water	
state	saturated state	
input data	temperature (T)	pressure (P)
output data	pressure (P) volume (v_f, v_g) enthalpy (h_f, h_g) entropy (s_f, s_g)	temperature (T) volume (v_f, v_g) enthalpy (h_f, h_g) entropy (s_f, s_g)

포화증기 영역의 해석을 위하여 표 2와 같은 다층신경회로망을 구성하였다. 이 신경회로망은 입력을 포화온도로 하는 경우와 포화압력으로 하는 경우를 비교한다는 의미에서 동일하게 적용하였다. 입력은 포화온도나 포화압력 하나뿐이므로 한 개의 노드(node)로 구성되고, 출력은 표 1에서 알 수 있듯이 7 개의 노드로 구성되어야 한다. 입력층(input layer)과 출력층(output layer) 사이에는 각각 10 개의 노드와 20개의 노드로 이루어진 두 개의 은닉층(hidden layer)을 구성하였다.

표 2. 신경회로망의 구조(포화상태)
Table 2 Structure of neural network(saturated state)

layer	node	
input layer	1 nodes	
hidden layer	first layer	10 nodes
	second layer	20 nodes
output layer	7 nodes	
activation function	hyperbolic tangent function	

실제 학습(training)에 사용된 데이터는 70 개이며, 포화온도는 5°C에서 임계점인 374.14°C까지의 넓은 범위의 데이터를 사용하였다. 이에 따른 포화압력의 범위는 0.000872 MPa ~ 22.09 MPa이다. 이 데이터는 포화온도와 포화압력을 입력으로 하는 학습 모두에 동일하게 적용되었다.

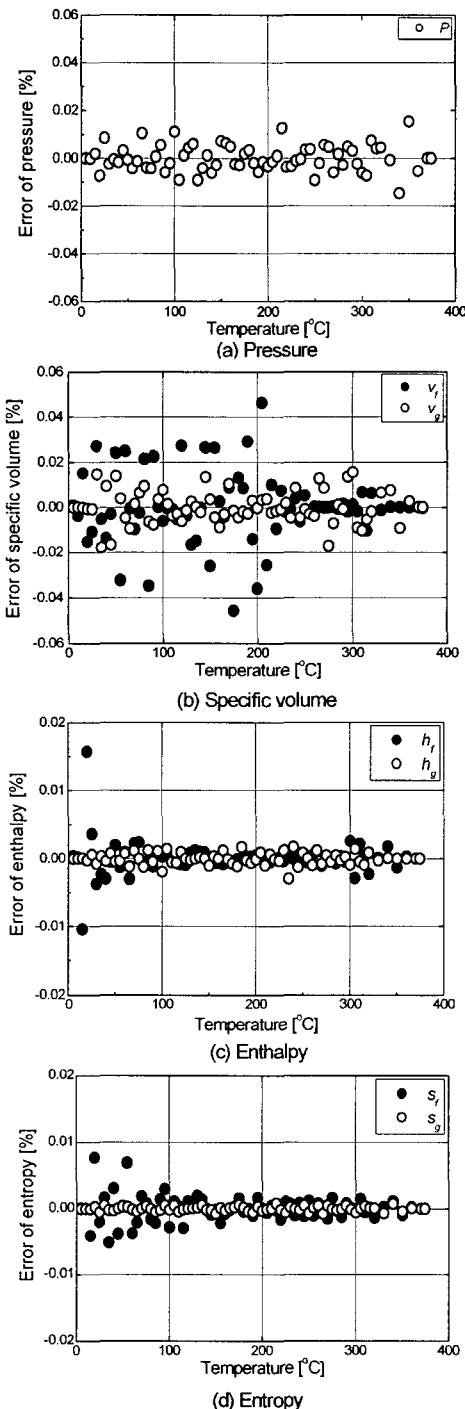


그림 3. 백분율오차(입력 : 온도)
Fig. 3 Percentage error(input : temperature)

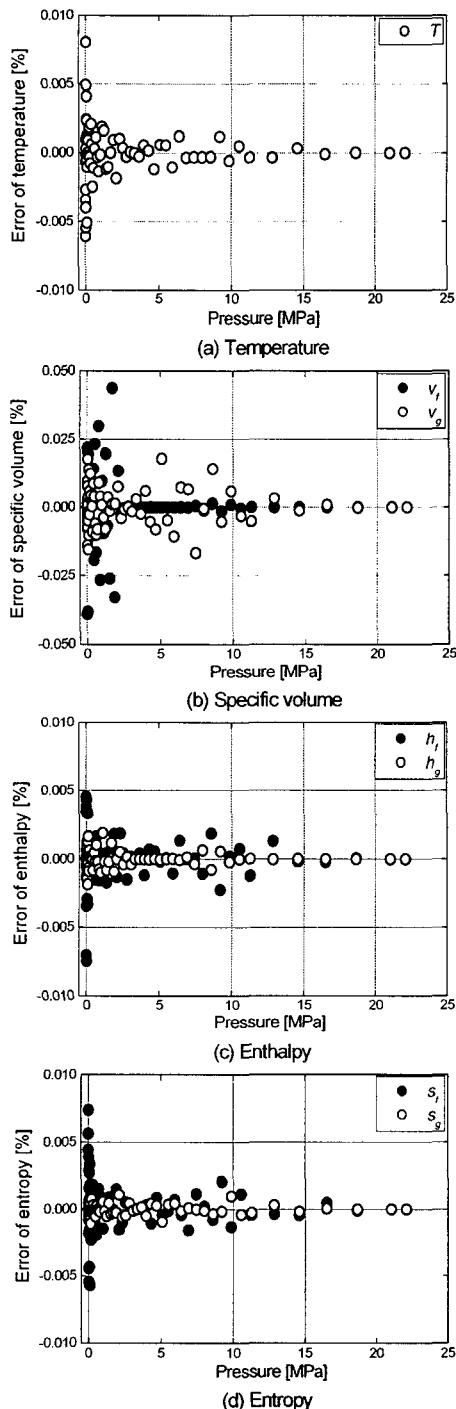


그림 4. 백분율오차(입력 : 압력)
Fig. 4 Percentage error(input : pressure)

포화상태에서 이러한 신경회로망을 구성하여 계산한 결과는 그림 3과 그림 4에 나타나 있다. 그림에 나타난 결과는 식 (3)과 같은 백분율오차(percentage error)이다.

$$\text{error} (\%) = \frac{X_{\text{model}} - X_{\text{true}}}{X_{\text{true}}} \times 100 \quad (3)$$

여기서 X 는 용량성 성질을 강도성으로 변환한 성질이며, 하첨자 true와 model은 각각 성질의 실제값과 모델링을 통하여 계산된 값을 나타낸다.

그림 3과 그림 4에서 보는 바와 같이 포화수의 비체적을 제외하면, 온도기준으로는 $\pm 0.01\%$, 압력기준으로는 $\pm 0.005\%$ 의 오차 범위까지 학습되어 상당히 정밀한 결과를 얻을 수 있었다. 그러나 엔탈피와 엔트로피에 비하여 포화압력과 비체적은 오차가 크게 나타났다. 학습된 데이터를 분석해 본 결과, 데이터의 함수 형태가 학습에 굉장히 큰 영향을 미친다는 사실을 확인하였다. 포화압력은 데이터로 사용된 최대압력과 최소압력의 차이가 굉장히 크다. 이같이 차수(order)가 달라지는 범위의 데이터는 좋을 학습 결과를 기대할 수 없었다. 경향이 유사한 건포화증기의 비체적에 대해서도 동일한 결과를 얻었다. 이러한 문제가 발생하는 이유는 표준화(normalization)가 어렵기 때문으로 판단된다. 이러한 단점을 해결하기 위하여 포화압력과 건포화증기의 비체적에 대해서는 입력 전에 자연로그함수를 취하였고, 계산된 결과에 다시 지수함수를 취하였다. 그 결과 그림 3(b)에서 보듯이 건포화증기가 포화수의 비체적보다 더 좋은 결과를 얻을 수 있었다.

과열증기의 경우는 온도가 압력을 결정짓지 못하기 때문에, 포화증기와는 달리 두 개의 성질을 입력으로 주어야 한다. 이 경우도 수많은 조합이 존재하지만, 여기서는 온도와 압력을 입력으로 선정하였다. 과열증기 영역에서는 포화증기 영역과는 달리 건도는 무의미하므로, 표 3에서 보는 바와 같이 비체적, 엔탈피, 엔트로피만이 학습의 결과로 출력된다.

과열증기에 대한 해석을 위하여 표 4와 같은 다층신경회로망을 구성하였다. 입력층은 온도와 압력에 대한 두 개의 노드(node)로 구성되고, 출력층은 3 개의 노드로 구성된다. 데이터가 포화증기의 경우보다 훨씬 많기 때문에 온도층은 각각 15 개의 노드와 25개의 노드로 구성하여 출력의 정밀성과 학습의 원활성을 기하였다.

표 3. 물의 성질(과열상태)
Table 3 Properties of water(superheated state)

	specification
fluid	water
state	superheated
input data	temperature (T) pressure (P)
output data	volume (v) enthalpy (h) entropy (s)

표 4. 신경회로망의 구조(과열상태)
Table 4 Structure of neural network
(superheated state)

layer	node	
input layer	2 nodes	
hidden layer	first layer	15 nodes
	second layer	25 nodes
output layer	3 nodes	
activation function	hyperbolic tangent function	

학습에 사용된 데이터는 545개이며, 온도범위는 $45.1^{\circ}\text{C} \sim 1300^{\circ}\text{C}$, 압력범위는 $0.01 \text{ MPa} \sim 60 \text{ MPa}$ 이다. 포화증기에서와 마찬가지로 압력과 비체적은 입력 전에 로그함수를 적용하였고, 학습시킨 결과에 다시 지수함수를 적용하여 원래의 함수로 환원하였다.

계산한 결과는 그림 5에 나타나 있다. 과열증기는 포화증기보다 오차가 더 적은 결과를 얻었으며, 이것은 온도층의 노드수와 입력 데이터의 수량에 기인한 것으로 보인다. 결과가 가장 좋지 않은 비체적도 포화증기보다 더 높은 정밀도를 가지는 것을 알 수 있다.

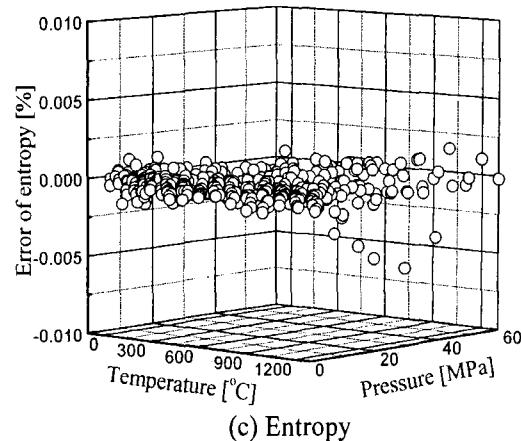
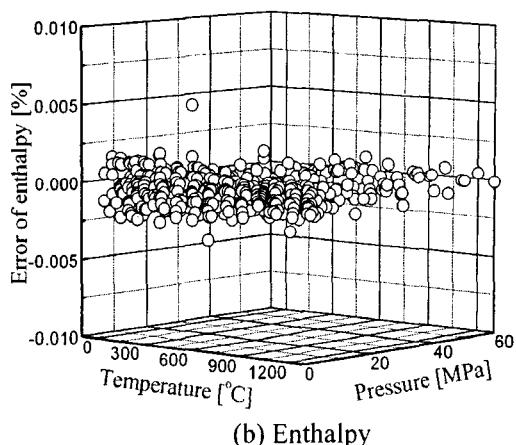
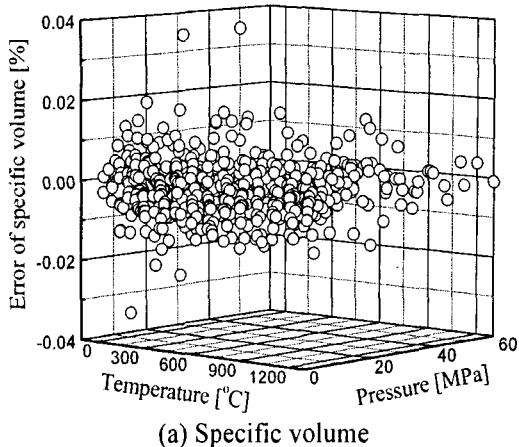


그림 5. 백분율오차(과열상태)
Fig. 5 Percentage error(superheated state)

전반적으로 백분율오차는 매우 만족할 만한 결과를 얻을 수 있었다. 함수형태가 학습에 적절한 온도나 엔탈피, 엔트로피는 대부분 $\pm 0.005\%$ 의 범위 내까지 학습되었다. 함수형태가 학습에 비교적 부적절한 압력과 비체적도 적절한 함수 변환을 통하여 $\pm 0.025\%$ 의 범위까지 학습시킬 수 있었다.

본 연구에 사용된 컴퓨터는 3.0 GHz의 IBM호환 기종이며, 일정하지는 않지만 포화증기에 대해서는 시간당 약 11,000회의 학습이 이루어졌으며, 과열증기에 대해서는 3,000회의 학습이 이루어졌다. 포화증기의 경우 RMS (root mean square) 오차의 차수(order)가 10^{-9} , 과열증기의 경우 10^{-10} 까지 학습되었다.

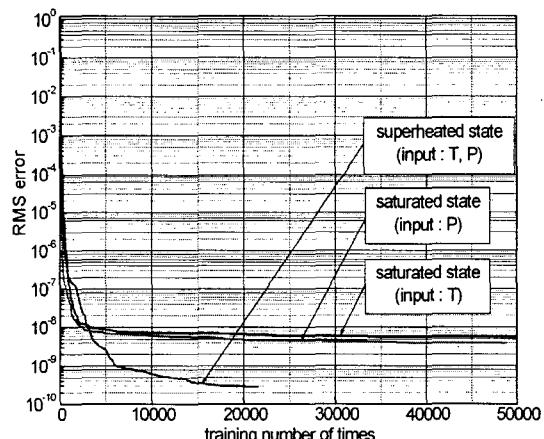


그림 6. RMS오차의 변화
Fig. 6 Variation of RMS error

그림 6은 학습이 진행됨에 따른 RMS오차의 변화추이를 보여준다. RMS오차는 학습 초기에 매우 불규칙하고 급격한 감소를 보이다가, 학습이 진행될수록 비교적 규칙적이고 감소폭도 줄어드는 경향을 보인다. 포화증기의 경우 입력이 온도이거나 압력이거나 관계없이 유사한 거동을 보여준다. 그러나 과열증기는 포화증기보다 훨씬 더 수렴이 빠르게 진행되었다. 이것은 과열증기가 포화증기보다 데이터의 수량과 은닉층의 노드수가 가 많기 때문으로 판단된다.

IV. 결 론

신경회로망의 함수근사 특성을 이용하여 물의 증기표를 종합적으로 모델링하였다. 그 결과 높은 정밀성을 가진 출력력을 얻을 수 있었으며, 이를 바탕으로 다음과 같은 결론을 내릴 수 있었다.

- (1) 신경회로망의 구조나 적절한 함수변환을 통하여 정밀성을 조절할 수 있고, 그 결과를 열성능 예측에 적용 가능하다.
- (2) 반복법을 사용하지 않아도 되기 때문에 계산이 적절적인 장점이 있다.
- (3) 넓은 범위를 모델링할 수 있기 때문에 프로그램이 간단해지고, 소구간의 경계에서 일어날 수 있는 불연속성에 대해 안전하다.

참고문헌

- [1] Domanski, P. A., EVSIM - An evaporator simulation model accounting for refrigerant and one dimensional air distribution, NISTIR 89-4133, 1989.
- [2] Mathur, G. D., Modeling and Simulation of Thermal and Hydrodynamic Performance of Heat Exchangers for Automotive Applications - Part I: Condensers, SAE 970829, pp. 11-19, 1997.
- [3] Mathur, G. D., Modeling and Simulation of Thermal and Hydrodynamic Performance of Heat Exchangers for Automotive Applications - Part II: Evaporators, SAE 970830, pp. 21-30, 1997.
- [4] 박병규, 이태환, 재습공조용 펀-관형 증발기의 열성능 모델링, 설비공학논문집, 제12권 제11호, pp. 1020-1030, 2000.
- [5] 이태환, 냉매회로와 유입공기온도가 증발기의 열성능에 미치는 영향, 진주산업대학교 산업과학기술연구소 논문집, 제8호, pp. 72-79, 2001.
- [6] 박영무, 박경근, 장호명, 김영일, 열역학, 사이텍미디어, 2000.
- [7] J. A. Zurada, Introduction to Artificial Neural Systems, West Publishing Company, 1992.
- [8] J. A. Freeman and D. M. Skapura, Neural Networks : Algorithms, Applications, and Programming Techniques, Addison-Wesley Publishing Company, 1991.
- [9] J. W. Hines, MATLAB Supplement to Fuzzy and Neural Approaches in Engineering, John Wiley and Sons, Inc, 1997.
- [10] 이태환, 신경회로망을 이용한 증기표의 모델링, 진주산업대학교 산업과학기술연구소보, 제 10호, pp.211-218, 2003.

저자소개



이 태환 (Tae-Hwan Lee)

1979년 2월 서울대학교 기계공학과
공학사
1981년 2월 서울대학교 대학원 기계
공학과 (공학석사)

1994년 8월 서울대학교 대학원 기계공학과 (공학박사)
1982년 3월 ~ 1983년 6월 (주)LG화학
1983년 7월 ~ 1989년 10월 현대중공업 선박해양연구소
1996년 3월 ~ 현재 : 진주산업대학교 메카트로닉스공학
과 부교수

※ 관심분야: 열전달, 열교환기, 냉동기기, 지능이론



박 진 현 (Jin-Hyun Park)

1992년 2월 : 부산대학교 전기공학
과 (공학사)
1994년 2월 : 부산대학교 대학원 전
기공학과 (석사)
1997년 2월 : 부산대학교 대학원 전기공학과 (공학박사)
1997년 3월 ~ 1999년 2월 : 부산정보대학 전임강사
1999년 3월 ~ 현재 : 진주산업대학교 메카트로닉스공학
과 부교수.
※ 관심분야: 지능제어, 진화알고리즘, 가변구조제어, 로
보텍스, 전력전자