

실온하강시간 예측을 위한 신경망 모델의 개발

양 인 호[†], 김 광 우*

서울대학교 공학연구소, *서울대학교 건축학과

Development of Artificial Neural Network Model for the Prediction of Descending Time of Room Air Temperature

In-Ho Yang[†], Kwang-Woo Kim*

Research Institute of Engineering Science, Seoul National University, Seoul 151-742, Korea

Department of Architecture, Seoul National University, Seoul 151-742, Korea

(Received August 7, 2000; revision received October 20, 2000)

ABSTRACT: The objective of this study is to develop an optimized Artificial Neural Network (ANN) model to predict the descending time of room air temperature. For this, program for predicting room air temperature and ANN program using generalized delta rule were developed, and learning data for 27 spaces using systems of experimental design were collected through simulation for predicting room air temperature. ANN was trained and the ANN model having the optimized values - learning rate, moment, bias, number of hidden layer, and number of neuron of hidden layer was presented.

Key words: HVAC(공조설비), Predictive control(예측제어), ANN(Artificial Neural Network, 인공신경망)

기 호 설 명

ρ_{air} : 공기의 밀도 [kg/m³]

C_{air} : 공기의 비열 [J/kg°C]

V_{air} : 실의 용적 [m³]

T_{air} : 공기 온도 [°C]

T_{out} : 외기 온도 [°C]

Δt : 계산시간 간격 [sec]

h_m : 각 면의 대류열전달 계수 [W/m²°C]

A_m : 각 벽체의 면적 [m²]

A_f : 가구의 표면적 [m²]

V_{sa} : 급기량 [m³/sec]

T_{sa} : 공급온도 [°C]

V_{in} : 침기량 [m³/sec]

Q_{c-p} : 인체발생열의 현열 대류성분 [W]

Q_{c-l} : 조명발생열의 현열 대류성분 [W]

Q_{c-e} : 기기발생열의 현열 대류성분 [W]

a : 신경세포의 활성화값

δ : 신경세포의 델타값

e : 신경세포의 에러값

o : 출력 패턴값

t : 목적 패턴값

w : 연결가중치

[†] Corresponding author

Tel.: +82-2-880-7066; fax: +82-2-885-8057

E-mail address: forinho@hanmail.net

하첨자

i : 은닉층 신경세포

도에 무관한 상호작용계수를 사용했을 때의 편차의 차이는 R290+R134a에 대하여 평균 0.19%이고, R134a+R600a에 대하여는 평균 0.98%로 나타났다.

온도에 의존하는 상호작용계수를 사용하여 Peng-Robinson⁽¹⁰⁾ 상태방정식으로 구한 증발개시점 압력과 실험에서 구한 값의 절대 편차는 R290+R134a와 R134a+R600a에 대하여 각각 평균 0.65%와 0.78%로 계산되었으며, 본 연구의 실험데이터는 Holcomb et al.,⁽⁴⁾ Kleiber,⁽⁵⁾ 그리고 Bobbo et al.⁽⁶⁾의 실험데이터와 잘 일치하였다.

후 기

본 연구는 과학기술부 중점 국가연구개발사업 및 교육부 BK21 사업의 지원으로 수행되었으며 이에 감사하는 바이다. 편집을 도와준 박한서 군에게도 감사한다.

참고문헌

1. Chung, E. Y. and Kim, M. S., 1996, Vapor-liquid equilibrium of R-32/134a refrigerant mixtures, Proc. SAREK Winter Annual Conf., pp. 66-70.
2. Kim, C. N., Park, Y. M., Lee, B. K. and An, B. S., 1997, Investigation of vapor-liquid equilibrium of HFC32/134a system, Korean Journal of Air-Conditioning and Refrigeration Engineering, Vol. 9, pp. 527-535.
3. Kim, C. N. and Park, Y. M., 1998, Investigation of vapor-liquid equilibrium of HFC-125/134a system, Korean Journal of Air-Conditioning and Refrigeration Engineering, Vol. 10, pp. 238-250.
4. Holcomb, C. D., Magee, J. W., Scott, J. L., Outcalt, S. L. and Haynes, W. M., 1997, Selected thermodynamic properties for mixtures of R-32 (Difluoromethane), R-125 (Pentafluoroethane), R134A (1, 1, 1, 2-Tetrafluoroethane), R-143A (1, 1, 1-Trifluoroethane), R-41 (fluoromethane), R-290 (Propane), and R-744 (Carbon dioxide), NIST Technical Note 1397.
5. Kleiber, M., 1994, Vapor-liquid equilibria of binary refrigerant mixtures containing Propylene or R134a, Fluid Phase Equilibria, Vol. 92, pp. 149-194.
6. Bobbo, S., Stryjek, R., Elvassore, N. and Bertucco, A., 1997, A recirculation apparatus for vapor-liquid equilibrium measurements of refrigerants. binary mixtures of R600a, R134a and R236fa, Fluid Phase Equilibria, Vol. 150, pp. 343-352.
7. Higashi, Y., 1999, Vapor-liquid equilibria for the binary Difluoromethane (R-32)+Propane (R-290) mixture, Int. J. Thermophysics, Vol. 20, No. 2, pp. 507-517.
8. Kim, M. S., Mulroy, W. J. and Didion, D. A., 1994, Performance evaluation of two azeotropic refrigerant mixtures of HFC-134a with R-290 (Propane) and R-600a (Isobutane), ASME J. of Energy Resources Technology, Vol. 116, pp. 148-154.
9. Morrison, G. and McLinden, M. O., 1993, Azeotropy in refrigerant mixtures, Int. J. Refrig., Vol. 16, pp. 129-137.
10. Peng, D. Y. and Robinson, D. B., 1976, A new two-constant equation of state, Ind. Eng. Chem. Fundam., Vol. 15, pp. 59-64.
11. McLinden, M. O., Klein, S. A., Lemmon, E. W. and Peskin, A. P., 1998, NIST Thermodynamic and Transport Properties of Refrigerants and Refrigerant Mixtures (REFPROP), Version 6.0, National Institute of Standards and Technology, Boulder, CO, U.S.A.
12. Higashi, Y., 1994, Critical parameters for HFC134a, HFC32 and HFC125, Int. J. Refrig., Vol. 17, pp. 524-531.
13. Sato, H., Higashi, Y., Okada, M., Takaishi, Y., Kagawa, N. and Fukushima, M., 1994, JAREf, HFCs and HCFCs, Ver. 1.0, Japanese Association of Refrigeration, Tokyo, Vol. 1.
14. Prausnitz, J. M., Lichtenthaler, R. N. and Azevedo, E. G., 1986, Molecular thermodynamics of fluid-phase equilibria, Prentice Hall, 2nd ed., p. 586.

j : 출력층 신경세포

1. 서 론

건물의 공조설비에서 사용되는 에너지는 건물 전체 에너지 소비량의 절반 정도로 주요 부분을 차지하고 있으며, 적절한 운전방법을 이용하면 효과적인 에너지 절약이 가능하다.

여기서, 공조설비의 에너지 절약운전을 위한 가장 효과적인 방법은 건물내에 사람들이 근무하는 재실 시간대에만 공조설비를 운전함으로써 최소 시간 동안만을 작동시켜 이상적인 에너지 절약운전을 실현하며, 동시에 재실자들에게 쾌적한 환경을 제공하는 것이다.

Fig. 1은 공조공간의 난방시 온도변화를 나타내고 있다. 에너지 절약을 위해서는 실온은 재실 시간대에만 허용 설정온도범위(throttling range) 내에 유지되도록 제어된다. 따라서 재실이 시작되는 시점에서 설계온도에 도달하기 위해서는 미리 공조설비를 기동시켜야 하며, 이에 대한 방법은 기존의 연구^(1,2)에서 제시되었다. 또한 건물의 축열효과 때문에 재실종료 이전에 미리 공조설비를 정지시켜도 실온이 설정온도 범위 이내에 있게 할 수 있으므로 열환경조건을 만족시키면서 에너지 절약이 가능하다.

여기서 정확한 정지시각의 예측을 위해서는 공조정지(열공급 중단) 시점으로부터 설정온도 하한까지 실온이 하강하는 시간(이하 실온하강시간이라 함)에 대한 정확한 예측이 필요하다. 그러나 실온하강시간은 외기조건, 건물의 구조체의 축열




Fig. 1 Variation of room air temperature according to HVAC operation.

특성, 설정온도 및 허용 온도변화 범위, 재실 스케줄, 설비의 용량 등 여러 가지 이유 때문에 정확한 예측이 어렵다.

여기서, 건물의 실온하강시간 예측방법에는 공조정지시의 실온, 외기온, 공급열량 등과 같은 몇 가지 인자들을 고려한 전열해석 프로그램이나 회귀식 같은 수학적 해법이 있다.

그러나, 공조제어제는 엄밀하게 비선형이고, 기기의 특성은 해마다 변하고 또 건물부하 자체의 응답도 변화하여, 실온하강에 영향을 미치는 변수들의 조건은 계속 변하므로 정확한 실온하강시간 예측이 불가능하다.

따라서, 공조설비나 건물 같은 시스템의 모든 요소를 고려하여 정확한 실온하강시간을 예측하기 위해서는 이전의 건물의 운전자료를 토대로 한 "학습"의 개념이 도입되어야만 한다.⁽³⁾

여기서 학습을 통해 해를 구할 수 있는 기법이 인공신경망(또는 신경망; Artificial Neural Network, ANN) 모델이며, 이것은 인간 뇌의 정보처리방법을 토대로 한 것으로 과거의 축적된 자료를 토대로 학습을 통하여 해를 구하는 것이다.

신경망 모델을 이용하여 실온하강시간을 예측하기 위해서는 실온하강과 관련된 요소들을 고려한 모델이 필요하다.

따라서, 본 연구의 목적은 다양한 건물에 적용 가능한 실온하강시간 예측을 위한 최적화된 신경망 모델을 개발하는 데 있다.

2. 신경망 프로그램의 개발

2.1 학습의 개요

신경망에게 지능을 부여하기 위해서 가장 먼저 해야 할 일은 신경망을 학습시키는 것이다. 그리고 학습과정은 신경망으로 하여금 일련의 자료들을 경험하도록 하는 것을 통해 이루어지며, 신경망은 주어진 학습규칙에 따라 스스로 자신의 연결가중치를 조절하여, 주어진 자료들로부터 자기 나름대로 지식을 얻게 된다. 이렇게 일단 학습된 신경망은 학습된 자료에 대해서는 우리가 원하는 결과를 정확하게 출력하며, 학습되지 않았거나 학습된 자료의 일부 파손, 왜곡, 잡음 섞인 자료의 입력시에도 연결가중치들에 저장된 자신의 내적 지식에 따라 적절한 결과를 출력하게 된다.

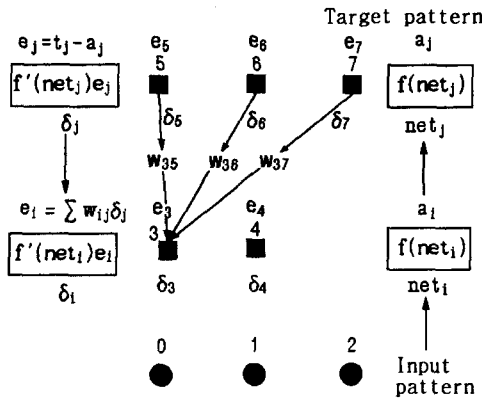


Fig. 2 Structure of back propagation learning.

여기서, 실은하강시간 예측을 위한 신경망의 역전파(back propagation) 학습 알고리즘의 기본 원리는 Fig. 2에 나타난 것처럼, 입력층의 각 유닛에 입력패턴을 주면, 이 신호는 각 유닛에서 변환되어 중간층에 전달되고 최후에 출력층에서 신호를 출력하게 된다. 이 출력값과 기대값을 비교하여 차이를 줄여 나가는 방향으로 연결가중치를 조절하고, 상위층에서 역전파하여 하위층에서는 이를 근거로 다시 자기층의 연결가중치를 조정해 나가며 학습을 진행한다.

2.2 역전파 학습의 흐름

본 연구에서의 실은하강시간 예측을 위한 신경망 프로그램에서 신경망 학습은 다음과 같은 단계로 이루어진다.

- (1) 입력층 신경세포에 입력패턴을 제시한다.
- (2) 식(1)을 이용, 신경망을 동작시켜 활성화함수 값을 계산한다. 바이어스를 사용할 경우 이를 포함시킨다.

$$a_j = \frac{1}{1 + \exp(-net_j + bias_j)} \quad (1)$$

- (3) 식(2)를 이용, 출력층 신경세포들의 에러와 델타를 구해 이를 은닉층으로 역전파한다.

$$\begin{aligned} \delta_j &= f'(net_j) \cdot e_j = \frac{\partial f(net_j)}{\partial net_j} \cdot e_j \\ &= a_j(1 - a_j) \cdot (t_j - a_j) \end{aligned} \quad (2)$$

여기서, $f'(net_j)$: 출력층 신경세포 j 의 활성화함수의 미분값

- (4) 식(3)을 이용, 역전파된 델타로부터 은닉층 신경세포들의 에러와 델타를 구해 이를 역전파한다.

$$\begin{aligned} \delta_i &= f'(net_i) \cdot e_i = \frac{\partial f(net_i)}{\partial net_i} \cdot e_i \\ &= a_i(1 - a_i) \cdot e_i \end{aligned} \quad (3)$$

여기서, $e_i = \sum_j w_{ij} \delta_j$

$f'(net_i)$: 은닉층 신경세포 i 의 활성화함수의 미분값

- (5) (4)과정을 입력층 바로 위층까지 반복한다.
- (6) 출력층과 모든 은닉층의 에러와 델타가 구해졌으면, 식(4)를 이용하여 일반화된 델타규칙에 의해 학습률(α)을 적용하여 연결가중치를 조절한다. 모멘트(β)를 사용할 경우 이를 포함시키며, 바이어스를 사용할 경우, 식(5)를 이용하여 바이어스도 조절한다.

$$w(new)_{ij} = w(old)_{ij} + \alpha \delta_j a_i + \beta \Delta w_{ij}(old) \quad (4)$$

$$bias(new)_j = bias(old)_j + \alpha \delta_j a_i + \beta \Delta bias_j(old) \quad (5)$$

- (7) (1)~(6)과정을 모든 입력패턴에 대해 반복한다.
- (8) (4)과정을 신경망이 완전히 학습될 때까지 반복한다.
- (9) 학습을 종료한다.

- (10) 학습이 종료된 신경망에 측정 시점별 입력자료를 제시하여 신경망을 회상시켜 각 시점에서의 실은하강시간을 계산한다.

3. 실은예측을 위한 전열해석 프로그램의 개발

3.1 실은예측 프로그램의 개요

신경망의 학습을 통해 보다 정확한 해를 구하기 위해서는 가능한 한 정확하고 많은 예제 데이

터가 필요하다. 이를 위해 좋은 방법은 적용하고자 하는 실제 건물을 운전한 자료를 얻는 방법이 이상적이다. 그러나, 본 연구에서처럼 신경망 모델을 이용하여 실온하강시간을 예측하기 위해서는 다양한 조건에 대한 학습자료를 이용하여 신경망 모델을 최적화할 필요가 있고, 이를 위해서는 많은 예제 데이터가 필요하며, 실제건물의 운전을 통해 수집된 자료를 이용하여 여러 건물에 적용할 수 있는 신경망 모델의 최적화를 위한 학습자료를 얻는 것은 현실적인 한계가 있다. 따라서, 여러 가지 변수에 대해 다양하게 시뮬레이션을 실시하여 학습자료를 구할 수 있는 프로그램이 필요하다. 본 연구에서는 이러한 다양한 조건에 대한 학습자료를 구할 수 있는 실온 예측 프로그램을 개발하여 다양한 조건에 대한 학습자료를 구할 수 있도록 하였다.

3.2 전열해석 모델의 열평형 방정식

Fig. 3은 실온을 계산하기 위한 실내공기 모델을 나타내고 있다. 실온은 각 표면의 온도, 열전달계수, 공급열량과, 기기, 조명, 인체의 대류발열 성분 및 침기부하에 의해 결정된다. 표면에서의 대류열전달과 침기 및 내부발열에 의한 열평형식은 식(6)과 같다. 이 식을 이용하여 다음 타임 스텝에서의 실온을 계산할 수 있다.

$$\begin{aligned} \rho_{air} C_{air} V_{air} \frac{T_{air}^{\beta+1} - T_{air}^{\beta}}{\Delta t} &= \sum h_m A_m (T_m^{\beta+1} - T_{air}^{\beta+1}) \\ &+ h A_f (T_f^{\beta+1} - T_{air}^{\beta+1}) \quad (6) \\ &+ \rho_{air} C_{air} V_{sa} (T_{sa} - T_{air}^{\beta+1}) \\ &+ \rho_{air} C_{air} V_{in} (T_{out}^{\beta+1} - T_{air}^{\beta+1}) \\ &+ Q_{c-p} + Q_{c-l} + Q_{c-e} \end{aligned}$$

4. 실온하강시간 예측을 위한 신경망 모델의 최적화

4.1 신경망 모델 최적화의 개요

건물의 실온하강시간 예측에 신경망 모델을 적용하기 위해서는 먼저 신경망 모델의 최적화 작업이 필요하다. 여기서 신경망 모델의 최적화는 여러값의 최소화를 의미하며 가능하면 적은 학습

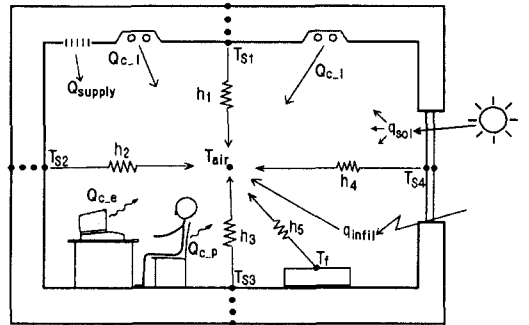


Fig. 3 Factors affecting room air temperature.

횟수, 즉 빠른 시간에 적용하고자 하는 문제의 특성에 적용하는 것이다.

여기서 신경망을 건물의 실온하강시간 예측에 적용할 경우 일반적인 예측이나 제어에 적용할 때와 다른 점은 매우 다양한 변화 요소들이 존재한다는 것이다. 그렇다고 건물에 적용할 때마다 사용자가 신경망 모델을 최적화하여 적용한다는 것은 어려운 일이다. 또한, 신경망 모델에서 입력층과 출력층 세포의 수는 입력요소와 출력요소의 성분수에 따라 결정되지만, 그밖의 은닉층 수와 은닉층 신경세포의 수 및 학습률과 같은 요소들은 신경망 모델 설계자에 의해 얼마든지 조정될 수 있다. 그리고, 그것을 어떻게 구성하느냐 하는 것은 신경망의 학습효율을 높이고 학습시간을 줄이는 데 매우 결정적인 역할을 하게 된다.

그러나, 이러한 것들을 결정하는 데 도움을 줄 만한 기준은 아직까지 발표된 것이 많지 않다. 결국, 적용하려는 문제의 성격에 맞게 이러한 요소들을 결정하여 최적화해야 한다.^(4,5)

여기서, 신경망 모델 요소의 최적화 요소로는 신경망의 학습성능에 영향을 주는 요소로 학습률 (learning rate), 모멘트(moment), 은닉층 수, 은닉층 신경세포의 수, 바이어스(bias)가 있다.

4.2 신경망 모델의 입출력 변수의 결정

신경망 모델을 이용하여 학습을 하기 위해서는 결정하고자 하는 문제에 영향을 미치는 인자들을 입력변수로 하여 학습을 하게 된다. 건물에서 실온하강시간 예측에 영향을 미치는 인자에는 건축적인 요소, 시스템적인 요소, 기상적인 요소 등 여러 가지가 있다. 그리고 이들을 구분하면, 건물

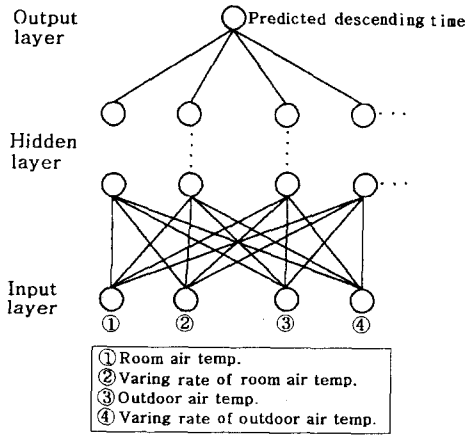


Fig. 4 The structure of input/output for predicting descending time of room air temperature.

에서 공조가 실시되는 시간 동안 변하지 않는 인자, 장기적으로 변하는 인자, 단기적으로 변하는 인자로 나누어질 수 있다. 본 연구의 목적은 공조공간에서 실온하강시간을 예측하고자 하는 것이므로, 공조가 중지되는 시간대에 단기적으로 변화하는 인자들을 입력요소로 하여야 한다. 따라서 본 연구에서는 변화하는 요소인 현재의 실온과 외기온을 입력요소로 하고, 이때 현재의 실온, 외기온뿐만 아니라 일정시간 전의 실온 및 외기온 변동률을 계산하여, 입력요소에 포함시켜 단시간의 미래의 변동까지 어느 정도 고려할 수 있도록 하였다.

출력요소는 공조설비를 정지시켜 설정온도에 하한 때까지의 실온하강시간이며, 이에 대한 신경망 모델의 구조는 Fig. 4와 같다.

4.3 실험계획법을 이용한 전열해석 프로그램 시뮬레이션

전열해석 프로그램을 이용하여 실온을 계산하고 이를 통해 목표온도까지 하강하는 시간을 계산하여 신경망 학습을 위한 학습자료를 만들고, 이러한 학습자료가 다양한 형태의 대상공간을 대표하기 위해서는 수많은 시뮬레이션이 필요하다. 예를 들면, 실온변동에 영향을 미치는 변수가 9개이고 이에 대하여 3수준으로 변화시킬 경우에도 $3^9 (= 19,638)$ 회의 많은 컴퓨터 시뮬레이션이

요구되어 분석이 거의 불가능하게 된다.

각 변수들에 대한 건물실온하강시간 예측을 위해서는 이러한 설계변수들의 조합에 의한 수많은 횟수의 시뮬레이션을 실시해야 하지만, 통계적인 방법인 실험계획법을 이용하면 일부의 실험만을 실시하여도 전체 시뮬레이션 계산치와 동일한 결과를 유도할 수 있다.⁽⁶⁾

4.3.1 인자배치 및 시뮬레이션 조건의 설정

실험계획법에 의해 각 변수에 대한 시뮬레이션을 실시하기 위해 실온에 영향을 미치는 요소에 대한 대표적인 변수를 선정하였다. 선정된 시뮬레이션 변수로는 대상공간의 바닥면적, 천장고, 창면적비, 차폐계수, 실내 발열부하, 인접조건((a) 1면이외기에 면하고 나머지가 공조 공간에 면한 경우, (b) 2면은 외기에 면하고 나머지는 공조 공간에 면한 경우, (c) 4면이 외기에 면한 경우), 목표온도, 벽체구조(Table 1), 슬래브 두께이다.

이러한 요소들을 이용하여, 3수준의 $L_{27}(3^9)$ 직교배열표를 이용하여 Table 2와 같이 시뮬레이션 조건을 구성하였다.

4.3.2 실온하강시간 학습자료 작성

실온하강시간에 대한 학습자료를 작성하기 위하여 실온예측 프로그램이 재실시간대의 실제 건물제어와 같은 방법으로 on/off하여 실온을 설정온도 허용변동폭 이내에서 유지되도록 하여 시뮬레이션할 수 있도록 하였다.

프로그램 출력 내용은 외기온, 외기온 변동률, 실온, 실온 변동률, 목표온도까지 도달하는 시간이며 Fig. 5에서처럼 목표온도(허용변동폭의 하한)까지 하강하는 시간은 주로 외기조건 및 공조




Fig. 5 Differences of descending time according to initial conditions.

Table 1 Structure of wall and slab in simulation room

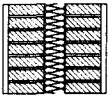
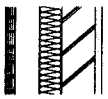
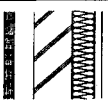


type	section	composition of material			
		material	thick-ness(mm)	thermal conductance(W/m ² ·°C)	thermal capacity(J/m ³ ·°C)
exterior wall		mortar	10	0.930	1,796,145
		cement brick	90	1.396	1,582,686
		styrofoam	50	0.036	37,681
		cement brick	90	1.396	1,582,686
		mortar	10	0.930	1,796,145
		stone	30	2.349	1,997,093
		air	50	0.026	1,162
		styrofoam	50	0.036	37,681
		concrete	50	1.628	2,021,838
plaster board		9	0.326	1,062,614	
	stone	30	203.525	2,439,906	
	air	50	0.026	1,162	
	concrete	70	1.628	2,021,838	
	styrofoam	50	0.036	37,681	
	plaster board	9	0.326	1,062,614	
interior wall		plaster board	9	0.326	1,062,614
		styrofoam	40	0.036	37,681
		plaster board	9	0.326	1,062,614
slab		concrete	100	1.628	2,021,838
			120		
			140		

Table 2 Conditions for simulation

No.	① Floor Area (m ²)	② Ceiling Height (m)	③ Window Area Ratio (%)	④ Window Trans- parency Ratio (%)	⑤ Indoor Heat Load (W/m ²)	⑥ Ambient Condition	⑦ Lower Limit of Setpoint Temp. (°C)	⑧ Wall Type	⑨ Slab Thickness (mm)
1	50	2.4	0.2	0.50	15	a	19	A	100
2	50	2.4	0.2	0.50	25	b	20	B	120
3	50	2.4	0.2	0.50	35	c	21	C	140
4	50	2.6	0.4	0.68	15	a	19	B	120
5	50	2.6	0.4	0.68	25	b	20	C	140
6	50	2.6	0.4	0.68	35	c	21	A	100
7	50	2.8	0.6	0.85	15	a	19	C	140
8	50	2.8	0.6	0.85	25	b	20	A	100
9	50	2.8	0.6	0.85	35	c	21	B	120
10	100	2.4	0.4	0.85	15	b	21	A	120
11	100	2.4	0.4	0.85	25	c	19	B	140
12	100	2.4	0.4	0.85	35	a	20	C	100
13	100	2.6	0.6	0.50	15	b	21	B	140
14	100	2.6	0.6	0.50	25	c	19	C	100
15	100	2.6	0.6	0.50	35	a	20	A	120
16	100	2.8	0.2	0.68	15	b	21	C	100
17	100	2.8	0.2	0.68	25	c	19	A	120
18	100	2.8	0.2	0.68	35	a	20	B	140
19	250	2.4	0.6	0.68	15	c	20	A	140
20	250	2.4	0.6	0.68	25	a	21	B	100
21	250	2.4	0.6	0.68	35	b	19	C	120
22	250	2.6	0.2	0.85	15	c	20	B	100
23	250	2.6	0.2	0.85	25	a	21	C	120
24	250	2.6	0.2	0.85	35	b	19	A	140
25	250	2.8	0.4	0.50	15	c	20	B	120
26	250	2.8	0.4	0.50	25	a	21	A	140
27	250	2.8	0.4	0.50	35	b	19	C	100

정지시의 실온에 따라 T_1, T_2, T_3 로 달라지게 된다.

4.4 신경망 모델의 최적화

다양한 인자들을 가진 건물에서 정확한 실온하강시간 예측을 위해서는 신경망 모델의 최적화가 필요하다. 본 절에서는 신경망 모델의 최적화를 위해 신경망 모델의 학습요소인 학습률, 모멘트 값, 은닉층 수, 은닉층 신경세포의 수, 바이어스와 같은 요소들에 대한 최적값을 구하고자 한다.

신경망의 최적화는 27개의 대상공간에 대한 각각의 학습자료의 학습을 통한 최적화를 의미한다. 따라서 학습요소들을 인자를 단계별로 변화시켜 가며 총 에러(total error)값이 최소가 되는 최적값을 구하도록 하며, 전체를 최적화하기 위해서는 복합적인 인자들이 있기 때문에 하나의 변수를 변화시킬 때 다른 변수들은 고정시켜 놓고 비교 평가하게 된다. 실온예측 프로그램의 시뮬레이션을 통해 구해진 학습자료 중에서 오차(정규화된 값 중에서 0.1 이하, 0.9를 초과한 값)




Fig. 6 Patterns of total error according to learning rate (No. 10~18).




Fig. 7 Patterns of total error according to moment (No. 19~27).

를 가진 자료를 제거하고 실온하강시간에 대한 신경망 학습을 실시하였다. 학습자료는 100개를 정하고, 학습자료에 대해서 각각 3,000회 학습을 실시하였다.

4.4.1 학습률 변화에 따른 학습결과

학습률은 연결 가중치들을 업데이트하는 데 사용된 각각의 에러의 크기를 결정하므로 신경망 학습에서 중요한 역할을 하게 된다.

Fig. 6은 실온하강시간에 대한 학습률 변화에 따른 총 에러의 변화를 나타내고 있으며, 학습률이 0.5 이상일 때와 0.2 이하일 때를 제외하면 커다란 차이를 보이지 않고 있으며 학습률이 0.4일 때 총 에러 값이 가장 작게 나타나고 있다.

4.4.2 모멘트 변화에 따른 학습결과

모멘트의 목적은 역전파 학습 알고리즘의 수렴을 가속시키는 것이다. 즉, 연결 가중치 조절식에 관성을 줌으로써 학습성능을 향상시키고, 학습시간을 단축시키기 위한 것이다.

Fig. 7은 실온하강시간에 대한 모멘트 변화에 따른 총 에러의 변화를 나타내고 있으며, 모멘트 값이 0.75 이하일 때는 총 에러 값이 거의 일정하게 나타나며, 0.85일 때 총 에러가 전반적으로 가장 작게 나타나고, 이 값을 벗어나면 총 에러가 크게 나타나고 있다.

4.4.3 은닉층 수의 변화에 따른 학습결과

은닉층 수는 신경망을 학습하는 데 필요한 계산의 효율과, 임출력 변수 사이의 관계에 대한 복잡 정도의 학습에 영향을 미칠 수 있다. 더 많은 은닉층이 있다면, 역전파 학습 사이클마다 더 많은 시간을 필요로 한다.




Fig. 8 Patterns of total error according to number of hidden layer (No. 1~9).

입출력 변수 사이의 관계가 더 복잡해짐(비선형)에 따라 복잡함을 학습하기 위해 더 많은 은닉층이 필요하다. 따라서 학습시간과 적용하고자 하는 문제의 특성을 고려하여 적절한 은닉층 수와 은닉층 신경세포의 수를 결정해야 한다.

본 연구에서는 27개 대상공간의 학습자료에 대해서 은닉층 수를 다층 퍼셉트론에서 많이 사용되는 1개, 2개, 3개의 3단계로 변화시키며 학습을 실시하였다.

Fig. 8은 실온하강시간에 대한 은닉층 수 변화에 따른 총 에러의 변화를 나타내고 있으며, 그림 S에 나타난 것처럼 은닉층 수가 2개일 때 가장 작은 총 에러를 보이는 것을 알 수 있다.

4.4.4 은닉층 신경세포수 변화에 따른 학습결과

Fig. 9는 실온하강시간에 대한 신경세포수의 변화에 따른 총 에러의 변화를 나타내고 있으며, 최대값과 최소값의 차이는 9% 정도로 나타나고 있으며, 신경세포수가 4개일 때 가장 작은 총 에러 값을 나타내고 있다.




Fig. 9 Patterns of total error according to number of neuron of hidden layer (No. 10~18).




Fig. 10 Patterns of total error according to bias (No. 19~27).

4.4.5 바이어스 값 변화에 따른 학습결과

바이어스 값의 유무에 따른 신경망 모델을 평가하기 위해, 학습률 0.75, 모멘트 0.9, 은닉층 수 1개, 은닉층 신경세포수 8개로 하였다.

27개 대상공간의 학습자료에 대해서 바이어스를 사용하지 않는 경우(unused)와 사용하는 경우(variable)를 비교하여 학습하였다.

Fig. 10은 실온하강시간에 대한 바이어스 값 변화에 따른 총 에러의 변화를 나타내고 있으며, 바이어스를 사용할 때와 사용하지 않을 때를 비교했을 때, 총 에러는 차이가 크게 나타나지는 않지만, 바이어스를 사용했을 때 대체로 총 에러가 작으므로 실온하강시간 예측에 바이어스가 있어야 함을 알 수 있다.

4.4.6 신경망 학습 요소에 대한 최적값의 선정

신경망 모델의 최적화를 위해서 학습요소들을 변화시켜 신경망의 성능을 평가한 결과를 종합하면, 실온하강시간 예측을 위한 신경망 학습요소들의 최적값 및 최적화된 신경망 모델의 구조는 Table 3, Fig. 11과 같다.

Table 3 Optimized values of learning factors

factors	optimized value
learning rate	0.40
moment	0.85
number of hidden layer	2
number of neuron of hidden layer	4
bias	variable

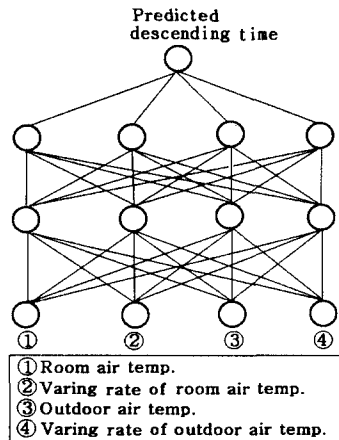


Fig. 11 Optimized structure of ANN model.

4.5 최적화된 신경망 모델의 평가

신경망 학습요소들의 최적화에서 각 요소들의 최적값은 각각의 대상공간에 대한 학습을 통해서 전체적으로 에러를 최소화하는 값을 구한 것이므로, 이렇게 만들어진 최적화된 신경망 모델이 전체 대상 공간에 대해서 실온하강시간을 정확하게 예측할 수 있는지를 평가할 필요가 있다.

따라서, 본 절에서는 실온예측 프로그램을 이용해 작성한 27개의 대상공간에 대한 실온하강시간 입출력 학습자료와 최적화된 신경망을 이용하여 일정횟수 학습시킨 다음, 신경망 회상(recall)을 통해 출력결과를 실제값과 비교 평가함으로써, 최적화된 신경망 모델의 성능을 평가하고자 한다.

4.5.1 회상결과 평가항목

신경망의 성능을 평가할 때 주로 사용되는 기준을 기존의 연구에서 보면 최대에러, 에러제곱평균, 에러제곱평균의 제곱근, 평균 바이어스 에러, 변동계수, 결정계수와 같은 요소들이 있다.

위에서 언급한 평가 요소들 중에서 에러제곱평균, 에러제곱평균의 제곱근, 평균 바이어스 에러, 변동계수는 에러의 평균 또는 에러제곱의 평균과 비슷한 의미를 가지고 있다. 최대에러의 경우는 학습자료 중에서 하나의 잘못된 자료가 있을 경우에도 이것이 최대에러로 나타나게 되어 정확한 평가가 어렵게 될 수도 있다. 이러한 점을 고려하여, 본 연구에서는 회상결과의 평가기준을 에러의 평균(ME), 에러의 표준편차인 에러

제곱평균의 제곱근⁽⁷⁾(RMS : root mean square error), 결정계수⁽⁸⁾(R² : coefficient of determination 또는 multiple correlation coefficient)로 하였고, 각 계산식은 다음과 같다.

$$ME = \frac{1}{N} \sum_{i=1}^N (t_i - o_i) \tag{7}$$

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N (t_i - o_i)^2} \tag{8}$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (o_i - t_i)^2}{(t - \bar{t})^2} \tag{9}$$

4.5.2 최적화된 신경망 모델의 평가결과

최적화된 신경망 모델을 이용하여 건물의 실온하강시간 예측을 위해서는 최적화된 신경망 모델이 모든 대상공간에 대해 정확한 실온하강시간을 계산할 수 있는지에 대한 평가가 필요하다. 따라서 본 절에서는 최적화된 신경망 모델인 Table 3과 Fig. 11의 모델을 이용하여 27개의 대상공간에 대한 각각 90개의 실온하강시간 학습자료에 대한 평가를 하였다.

여기서 학습횟수는 5,000회로 하여 학습을 실시하고, 결과를 회상(recall)시켜 실온예측 프로그램의 시뮬레이션 값과 최적화된 신경망 모델의 학습값과의 비교를 통해 최적화된 신경망 모델의 실온하강시간 예측에의 적응성을 파악하였다.

Fig. 12는 학습횟수의 증가에 따른 총 에러의 변화의 예를 나타내고 있다. 500회 정도의 학습횟수까지는 급격히 총 에러가 1.4 정도로 감소하다




Fig. 12 Pattern of total error according to learning number.




Fig. 13 Correlation of simulation and ANN learning.

가, 학습횟수의 증가에 따라 총 에러는 완만하게 계속 감소하고 있으므로, 학습횟수를 증가시키면 더 정확한 결과를 얻을 수 있음을 알 수 있다.

Fig. 13은 대상공간에 대한 90개 학습자료의 실제값(시뮬레이션 결과)과 학습결과와의 비교를 나타낸 것이다. 결정계수가 0.9869로 선형관계가 뚜렷하게 나타나고 있어, 최적화된 신경망 모델이 대상공간에 대해 정확하게 입출력 관계를 학습하고 있음을 알 수 있다.

27개 대상공간에 대한 실온하강시간의 학습에 의한 회상결과, 실제값에 대한 에러의 평균을 비교했을 때, 전열해석 시뮬레이션에 의한 값의 평균이 0.634시간에서 0.945시간의 분포를 나타내고 있으며, 이 값과 학습에 의한 회상값의 차이인 에러의 평균은 0.032시간(1.92분)에서 최대 0.053시간(5.94분)으로 나타났다.

아울러 결과의 정확성을 나타내는 대표적인 평가항목인 결정계수를 보면, 0.910~0.987로 나타나 최적화된 신경망 모델이 27개 대상공간에 대한 실온하강시간을 비교적 정확하게 예측할 수 있음을 알 수 있다.

5. 결 론

본 연구는 다양한 형태의 건물에서 실온하강시간 예측을 위한 최적화된 신경망 모델을 개발하기 위한 것으로, 이를 위해 실온하강시간에 영향을 주는 인자들을 고려하여 신경망 입출력 구조를 만들고, 실온 예측프로그램을 이용하여, 다양한 형태의 건물에 대한 학습자료를 작성하였다.

이것을 본 연구에서 개발된 신경망 학습프로그램에 제시하여, 학습을 실시하여 신경망 학습요소에 대한 최적값을 구하고, 신경망 회상을 통해 최적화된 모델의 평가를 하였다. 본 연구결과는 다음과 같다.

(1) 실온하강시간 예측을 위한 신경망 모델 학습 요소들에 대한 최적값은 학습률 0.75, 모멘트 0.9, 은닉층 수 1개, 은닉층 신경세포수 8개, 바이어스는 variable로 할 때로 나타났다.

(2) 최적화된 모델에 대한 신경망 회상결과, 신경망 모델의 정확도를 나타내는 대표적인 지수인 결정계수가 0.910~0.987로 나타나, 최적화된 신경망 모델이 실온하강시간을 정확하게 예측할 수 있음을 알 수 있다.

아울러 최적화된 신경망 모델을 이용하여 실제 건물에 적용하는 데 필요한 적정 허용오차, 측정 시간간격 등과 같은 요소들에 대한 연구가 이루어지고, 실제 건물에 적용을 통해 성능을 검증하여, 향후 공조설비 최적운전에 유용하게 이용될 수 있을 것으로 판단된다.

후 기

본 연구는 BK21 "건물성능 향상을 위한 건축 기술개발" 분야 연구결과의 일부임.

참고문헌

1. Yang, I. H. and Kim, K. W., 1997, A study on the application of artificial neural network for optimal operation of HVAC systems, Journal of the Architectural Institute of Korea, Vol. 13, No. 8.
2. Yang, I. H., 1987, A study on determining the optimal preheating time of building using learning method, Journal of the Architectural Institute of Korea, Vol. 14, No. 7.
3. TRANE, 1990, TRACE 600 Engineers Manual, p. 43.
4. Lee, S. W., 1993, Learning machine-neural network, Ohm Inc., p. 289.
5. Zurada, Jacek M., 1992, Artificial neural systems, Info Access Distribution Pte LTD, p. 210.
6. Suk, H. T., 1995, A study on the development of load prediction equation and design guidelines for the energy conservation of office buildings, Ph.D. Dissertation, Seoul National University, p. 79.
7. Anstett, M. and Kreider, J. F., 1993, Application of neural networking models to predict energy use, ASHRAE Transaction Vol. 99, Part 1, p. 511.
8. Kreider, J. F. and Wang, X. A., 1991, Artificial neural networks demonstration for automated generation of energy use predictors for commercial buildings, ASHRAE Transaction, IN-91-9-3, p. 777.