

이중외피 건물의 개구부 및 난방설비 제어를 위한 인공지능망의 적용

문진우, 김상민*, 김수영**†

한밭대학교 설비공학과, *현대건설 연구개발본부, **연세대학교 주거환경학과

Application of Artificial Neural Network for Optimum Controls of Windows and Heating Systems of Double-Skinned Buildings

Jin Woo Moon, Sang-Min Kim*, Sooyoung Kim**†

Department of Building and Plant Engineering, Hanbat National University, Daejeon 305-719, Korea

*Research and Development Division, Hyundai Eng. and Construction Co., Ltd. Gyeonggi-do 446-716, Korea

**Department of Housing and Interior Design, Yonsei University, Seoul 120-749, Korea

(Received January 26, 2012; revision received July 2, 2012)

ABSTRACT: This study aims at developing an artificial neural network(ANN)-based predictive and adaptive temperature control method to control the openings at internal and external skins, and heating systems used in a building with double skin envelope. Based on the predicted indoor temperature, the control logic determined opening conditions of air inlets and outlets, and the operation of the heating systems. The optimization process of the initial ANN model was conducted to determine the optimal structure and learning methods followed by the performance tests by the comparison with the actual data measured from the existing double skin envelope. The analysis proved the prediction accuracy and the adaptability of the ANN model in terms of Root Mean Square and Mean Square Errors. The analysis results implied that the proposed ANN-based temperature control logic had potentials to be applied for the temperature control in the double skin envelope buildings.

Key words: Artificial neural network(인공 지능망), Thermal environment control(열환경 제어), Double skin envelope(이중외피), Model optimization(모델 최적화)

기 호 설 명

$TEMP_{IN}$: 실내 온도(°C)	N_h	: 숨겨진 층 뉴런의 수
$TEMP_{PR}$: 현재 제어 사이클에서 다음 제어 사이클까지의 실내온도 변화(°C)	N_o	: 출력층 뉴런의 수
N_i	: 입력층 뉴런의 수	N_d	: 학습 데이터 세트의 수
		$\Delta Temperature$: 다음 제어 사이클까지의 실내온도 변화(°C)

1. 서 론

최근 이중외피 기술은 에너지, 실내환경 및 구조 측면에서의 장점을 바탕으로 건물에 다양하게 적

† Corresponding author

Tel.: +82-2-2123-3142; fax: +82-2-313-3139

E-mail address: sooyoung@yonsei.ac.kr

용되고 있다.⁽¹⁾ 이중외피가 적용된 건물에 형성되는 중공층(cavity)과 관련된 요소인 차양장치의 조절 각도, 개구부의 개구율, 기류모드 등에 대한 효과적 제어는 실내 열, 빛 환경 등의 적절한 유지, 건물 에너지, 경제성 및 환경성능 향상에 영향을 미치고 있는 것으로 나타났다.⁽²⁾ 다양한 연구를 통하여 중공층 요소의 효과적 제어방법 및 이중외피가 적용된 건물에서 소비되는 에너지 평가가 시도되고 있으며, 특히 외피에 설치된 개구부의 개방방법 및 개방비율에 관련되어 규칙중심 접근법(rule-based approach)과 최적 제어이론(optimal control theory)등에 근간한 제어전략이 분석되어지고 있다.^(3, 4)

규칙중심 접근법은 가장 일반적으로 적용되는 방법이며 상대적으로 단순한 규칙과 시스템 요소가 적용되어, 제어로직(control logic) 개발 및 시스템 적용이 용이하여 건물에서 소비되는 에너지 제어 등에 효율적으로 활용된다.

그러나 규칙중심 접근법에는 제어 과정상 주관적인 규칙이 사용되기 때문에 최적화된 방법이라 단정 지을 수 없는 단점이 있으므로, 이 접근법이 이중외피 건물에서의 열 환경과 에너지소비 효율성의 개선에 효과적으로 적용되기 위하여 현재 일반적으로 적용되고 있는 제어 방법에 대한 최적화 과정이 이루어져야 한다.

따라서 본 연구에서는 기존 규칙중심 접근법의 한계점을 최소화하고 이를 효과적으로 활용하기 위하여, 인공지능망(Artificial Neural Network, ANN) 모델을 적용하여 이중외피 개구부의 최적화된 작동과 난방시스템 제어의 영향에 따라 변화하는 실내 온도를 최적으로 유지하기 위한 효율적인 에너지 제어전략을 제안한다.

이를 위하여, 이중외피의 개구부 작동 및 난방 시스템에 대한 제어로직(control logic)의 개발, 인공지능망의 적용을 통한 예측제어(predictive control) 및 적응제어(adaptive control)의 실현, 그리고 예측의 정확성 및 적응성의 측면에서 개발된 인공지능망 모델의 최적화 및 성능평가가 실시되었다.

2. 제어 로직 및 인공지능망 모델 개발

2.1 온도 제어로직(control logic) 개발

본 연구에서 개발된 온도 제어로직의 구조는 3단계로 구성되어 있다. 구조에 대한 세부 흐름도는 Fig.

1에 나타나 있다. 첫 번째 단계에서는 개구부의 개방 조건에 따른 다음 제어 사이클(control cycle)까지의 실내 온도 변화(Δ Temperature)를 예측한다. 실내 온도 변화는 현재 제어 사이클에서 다음 제어 사이클까지의 실내 온도 상승 혹은 하강 등의 변화량을 의미한다. 이러한 변화를 예측하기 위하여, 인공지능망 모델이 적용되어 Table 1에 명시된 4가지의 개구부 개방조건에 대한 온도 변화 예측이 실시된다.

다음 단계에서는 난방 시스템의 현재 작동 상태에 따른 최적의 개구부 개방 상태가 결정된다. 난방시스템이 작동중인 경우에서 최적의 개구부 개방 상태는 현재의 실내 온도를 최대한 상승 혹은 현재 상태로 유지하는 경우로 볼 수 있다. 예를 들면, Table 1에 나타난 개구부 개방상태인 case 1~case 4의 조건에 대한 실내온도 변화 예측값이 각각 $+0.1^{\circ}\text{C}$, -0.2°C , $+0.5^{\circ}\text{C}$, -1.0°C 로 계산될 경우, 최적의 개방 상태는 세 번째 경우(case 3)로 결정된다.

마지막 단계에서는 난방 시스템의 작동을 결정하고 개구부의 개방 상태를 이전 단계에서 결정된 최적 방법으로 전환한다. 예를 들어, 현재 난방시스템이 작동 중이고 실내 온도와 다음 제어 사이클까지의 상승 혹은 하강 온도의 합이 설정된 난방시스템 작동 범위인 $20^{\circ}\text{C} \sim 23^{\circ}\text{C}$ 중 최고 온도인 23°C 를 초과하면, 현재 단계에서 난방 시스템의 작동을 멈추고 동시에 개구부 개방 상태를 최적화된 방법으로 전환된다.

난방 시스템이 작동하고 있지 않은 경우에도 유사한 과정을 통하여 시스템 작동과 개구부 개방상태를 결정하게 된다. 이러한 예측 제어에 의하여 실내 온도는 보다 안정적으로 유지될 수 있을 것으로 예상되며, 그 효과는 Fig. 2에 나타난 실내 온도 비교에 의하여 설명된다.^(5, 6) 또한, 인공지능망 로직(ANN logic)에 의하여 제어되는 실내 온도는 전통적인 로직(conventional logic)에 의한 온도에 비교하여 시스템 작동 범위를 벗어나는 정도가 줄어들 것으로 예상된다. 예측 제어를 바탕으로 한 이러한 효과는 기존의 다양한 연구에서 증명된 바 있다.^(5, 6)

2.2 인공지능망 모델 개발

인공지능망은 인간의 신경망 구조와 학습과정을 기반으로 Warren McCulloch와 Walter Pitts에 의해 개발되었으며, 예측과 적응의 우수성을 바탕으로 비선형 혹은 불규칙한 역학성을 내포한 시스템의 제어

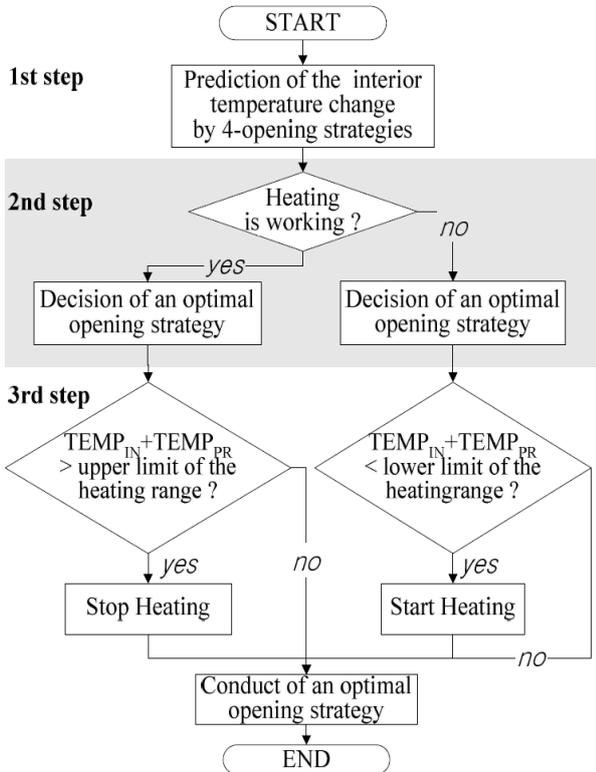


Fig. 1 A logic for controlling openings and heating system.

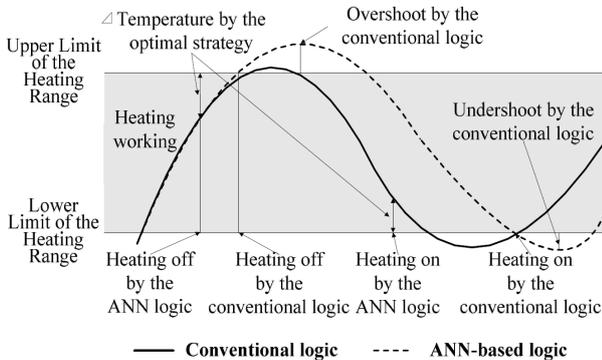


Fig. 2 Conceptual air temperature profiles by the conventional and ANN-based logics.

Table 1 Opening conditions

cases	Opening conditions	
	Opening at internal skin	Opening at external skin
1	closed	closed
2	closed	open
3	open	closed
4	open	open

에 효과적으로 적용되고 있다.⁽⁷⁾ 열 환경 제어를 위한 인공지능망 적용 및 개선된 효과를 증명하기 위한 다양한 연구가 진행되고 있다.^(5, 6) 특히 Moon et al.은 인공지능망 모델을 이용하여 최적의 난방, 난방 및 습도조절을 통한 주거 건물 열 환경 제어법을 제시하였다.⁽⁵⁾ 이 연구에서는 열과 습기를 동시에 제어함으로써 PMV(Predicted Mean Vote)와 같은 종합적 쾌적 요소의 제어가 가능하게 되었으며, 전통적 제어 방법과의 비교를 통하여 안정성과 우수성이 증명되었다. 그 외에도 바닥 복사 냉난방 시스템, 태양열 주택 난방 시스템, 공기조화 냉난방(HVAC) 시스템 등 다양한 열 환경 제어 시스템의 제어를 위한 인공지능망 적용의 우수성이 증명되었다.⁽⁸⁻¹¹⁾

인공지능망이 적용되어 에너지소비 제어가 이루어지는 건물에서 가장 중요하게 작용하는 실내 온도변화는 건물외피를 통한 열전도, 환기 및 침기, 태양 일사, 실내 발열 부하 등에 의한 열전달 과정에 의하여 영향을 받는다. 특히, 이중 외피 건물에서의 실내 온도 변화를 결정하는 요소는 외기 조건, 태양 일사, 중공층 온도, 외피의 크기 및 특성, 이중 외피의 개구부 개방 상태, 환기 및 침기량, 실내 온도, 실내 발열 부하 등으로 정리된다. 이 중 외피 건물의 실내 온도 변화에 영향을 미치는 과정과 요소들은 Fig. 3에 요약되어 있다. 이러한 영향 요소는 실내 온도 변화를 예측하기 위하여 본 연구에서 개발된 인공지능망 모델에 입력변수로 적용되었다.

본 연구에서는 초기 인공 지능망 모델 개발을 위하여 Matlab 및 Matlab 상의 신경망 구조 박스(Neural network toolbox)가 활용되었다.⁽¹²⁾ 적용된 모델 구조 및 매개변수는 Fig. 4와 Table 2에 요약되어 있다. 각각 하나의 입력층, 숨겨진 층, 출력층으로 구성되어 있으며, 각 층의 뉴런 수는 7, 15, 1로 계획되었다. 건물 개개의 형태 및 실내조건과 관련되는 실내 발열부하 요소와 외피의 크기 및 특성은 입력 뉴런에서 제외되었다.

또한, 입력층 뉴런에는 실내온도(-10~40℃), 실내 온도 변화(-10~10℃), 외기 온도(-20~40℃), 중공층 온도(-20~80℃), 수직면 태양일사(0~1,100 W/m²), 실내측 개구부 개방상태(0 : 닫힘, 1 : 열림), 및 실외측 개구부 개방 상태(0 : 닫힘, 1 : 열림)가 입력값으로 설정되며, 각 입력값은 0~1사이의 값을 가지도록 치환되어 입력된다. 또한 숨겨진층의 뉴런수(15)는 Table 2의 수식에 의해 결정되었다.^(13, 14)

개발된 인공지능망 모델의 결과값은 현재로부터 다음 제어 사이클까지의 실내 온도 변화량이며, 본

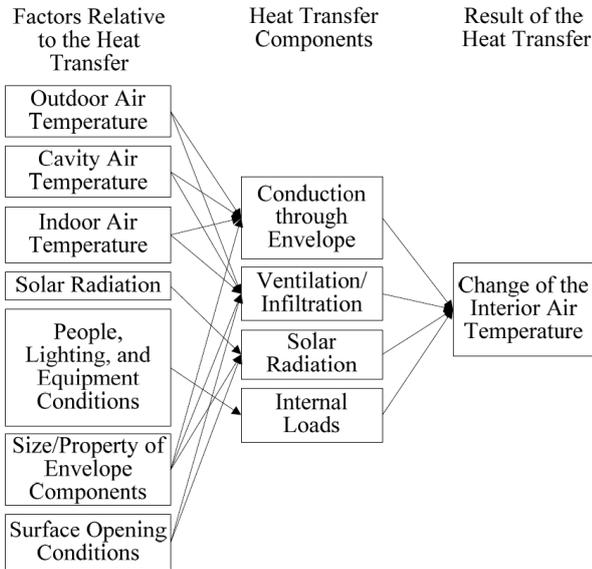


Fig. 3 Influential factors to indoor air temperature.

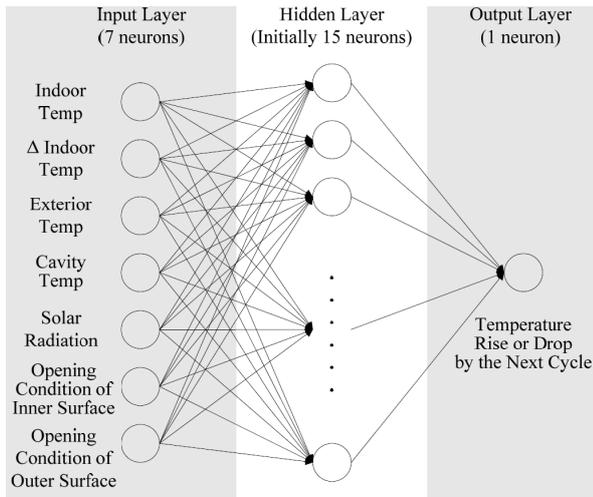


Fig. 4 Structure of the developed ANN model.

연구에서는 제어 사이클의 간격이 5분으로 설정되었다. 또한, 전이함수(transfer functions), 학습을 위한 매개변수(learning rate, moment, algorithm)는 발견적 해결방법(heuristic approach)에 근거하여 기존 연구들에서 제시한 값을 초기값으로 설정되었다.^(8, 12) 이러한 초기값은 최적화의 과정을 통하여 가장 정확한 결과값을 도출할 수 있도록 변경되었다. 학습(training), 최적화(optimization), 체크(check)를 위한 데이터는 Fig. 5~Fig. 6에 정리된 이중외피 모듈에서 측정된 데이터를 이용하였다.

대상으로 사용된 이중외피 모듈은 경기도 안산(위도 37°17', 경도 126°49')에 위치한 3층 건물의 1층

Table 2 Components of developed ANN model

Structure	Input Layer	<ul style="list-style-type: none"> Number of neurons : 7 i) indoor air temperature ii) indoor air temperature change from preceding ten minutes iii) exterior air temperature iv) cavity temperature v) solar radiation vi) opening condition of inner surface vii) opening condition of outer surface
	Hidden Layer	<ul style="list-style-type: none"> Number of neurons : 15 using $N_h = 2 \times N_i + 1$^(13, 14)
	Output Layer	<ul style="list-style-type: none"> Number of neuron : 1 (ΔTemperature by the next cycle)
Transfer Functions	Hidden Neurons	<ul style="list-style-type: none"> Tangent Sigmoid
	Output Neurons	<ul style="list-style-type: none"> Pure Linear
Training Method	<ul style="list-style-type: none"> Training goals : 0.01 K² for air temperature(MSE : Mean Square Error) Epoch : 1,000 times⁽⁸⁾ Learning rate : 0.75⁽⁸⁾ Moment : 0.9⁽⁸⁾ Algorithm : Levenberg-Marquardt^(5-8, 20) Number of data sets : 121 using $N_d = (N_h - (N_i + N_o) / 2)$⁽¹⁵⁾ Data Managing Technique : sliding-window method 	

에 설치되었다. 건물의 배치 및 중공층 내에서의 공기 흐름의 개념은 Fig. 6에 나타나 있다. 건물의 장축(long axis)은 북쪽에서 서쪽으로 26° 회전되어 배치되었으며, 모듈이 설치된 부분은 사무용 공간과 연결된 복도 부분으로 구성되었다. 중공층에 설치된 개구부의 크기는 가로 0.60 m, 세로 0.35 m로 구성되어 있으며, 공기는 외부로부터 중공층의 하부로 유입되어 상부로 유출되었다. 중공층과 실내공간이 연결된 내부외피에 설치된 창문은 닫혀있으며, 이중외피에 적용된 유리의 물리적 특성은 Table 3에 요약되어 있다.

외부기상 조건분석을 위하여 외기온도, 외부일사, 중공층으로 유입되는 수직일사가 측정되었다. 중공층의 온도변화를 분석하기 위하여 중공층 내부의 온도 및 중공층을 구성하고 있는 내부와 외부외피표면의 온도가 측정되었다. 외부에서 중공층으로 유

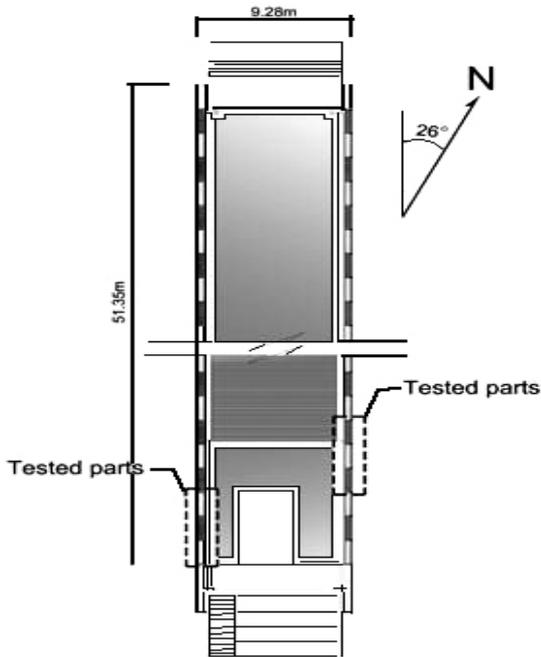


Fig. 5 Layout of the tested building.

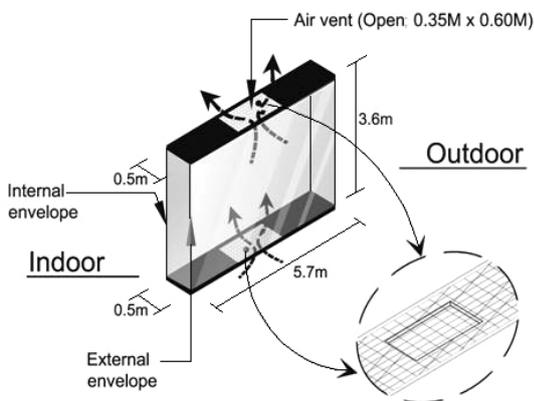


Fig. 6 Opening and air flow in the cavity.

Table 3 Thermal properties of glazing

Properties	Internal skin	External skin
U value[W/m ² K]	2.830	5.680
Solar heat gain coefficient	0.755	0.855
Absorption coefficient	0.101	0.095
Reflection coefficient	0.126	0.075

입되는 기류속도 및 중공층을 거쳐 외부로 유출되는 기류의 속도도 측정되었다. 모든 데이터는 데이터 로거(data logger)에 의하여 5분 간격으로 자동으로 측정되어 txt 파일로 변환된 후 저장되었다.

모델의 학습(model training)을 위하여 121세트의

데이터가 구성되었으며, 세트의 수는 Table 2 상에 주어진 식에 의해 계산되었다.⁽¹⁵⁾ 측정된 날은 각각 2008년 1월 1일(학습 데이터), 5일(최적화 데이터), 2일(체크 데이터, 청천공)과 11일(체크 데이터, 담천공)이었으며, 데이터 측정은 내측 개구부는 닫혀 있고 외측 개구부는 개방되어 있으며 난방 장치는 작동되고 있지 않은 모듈로부터 실시되었다.

3. 테스트 결과 및 고찰

3.1 개발 모델의 최적화

개발된 초기 모델의 정확도 및 안정성을 높이기 위하여 최적화 과정이 실시되었다. 최적화 과정은 Yang and et al.이 실시한 방법론을 적용하였으며⁽⁸⁾ 개발된 모델의 중요 요소인 숨겨진 층의 수(number of hidden layer), 숨겨진 층의 뉴런 수(number of neurons in the hidden layer), 학습률(learning rate) 및 모멘트(moment)에 대한 최적의 값을 찾기 위하여 순차적으로 진행되었다. 최적화를 위한 각 단계별 결정 과정은 4단계로 구성되었으며, 각 단계별 세부 조건은 Table 4에 정리되어 있다.

각 요소에 대한 최적값은 모델에서 예측된 실내온도 변화값과 실제 측정된 실내온도 변화값의 차이(RMS : Root Mean Square 및 MSE : Mean Square Error)가 최소가 되는 값으로 결정되었다. 최적화 과정에는 2008년 1월 5일에 대상 모듈에서 측정된 288개의 데이터 세트가 사용되었다.

최적화의 첫 번째 단계인 숨겨진 층의 수를 결정하기 위하여 1~5개의 숨겨진 층에 대한 모델 예측

Table 4 Optimization process for ANN model

Steps	Number of Hidden Layer	Number of neurons in the hidden layer	Learning rate	Moment
1 st step	Deciding Optimal Value	Initial Value (15)	Initial Value (0.75)	Initial Value (0.90)
2 nd step	Optimal Value	Deciding Optimal Value	Initial Value (0.75)	Initial Value (0.90)
3 rd step	Optimal Value	Optimal Value	Deciding Optimal Value	Initial Value (0.90)
4 th step	Optimal Value	Optimal Value	Optimal Value	Deciding Optimal Value

값과 실제 측정값이 비교되었다. 이 과정을 위하여 숨겨진 층의 뉴런수, 학습률, 모멘트의 초기값은 각각 15, 0.75, 0.90로 고정되었다.

예측값과 측정값 간의 RMS, MSE 및 최대 차이값을 이용하여 분석된 각 단계의 대상 요소값 변화에 대한 인공지능망 모델의 예측 성능은 Table 5에 정리되어 있다. RMS, MSE는 모든 경우에 대하여 초기 인공지능망 모델에서 계획된 학습의 목표(RMS : 0.1 K, MSE : 0.01 K²)보다 적은 값으로 안정적인 것으로 나타났다. 특히, 숨겨진 층이 4개일 경우에 가장 정확한 것으로 나타났으며(RMS : 0.0175 K, MSE : 0.0003 K²), 이 때의 최대 차이값은 0.4562와 -0.4315 K였다. 이를 통하여 최적의 숨겨진 층의 수는 4개로 결정되었다.

두 번째 과정인 숨겨진 층 내의 최적 뉴런 수를 결정하기 위하여 10~20개의 뉴런 수를 가지는 모델들의 예측값에 대한 비교가 실시되었다. 이 과정에서는 숨겨진 층의 수는 전 단계에서 도출된 값인 4로 설정되었고, 나머지 매개변수(학습률 및 모멘트)는 초기값으로 고정되었다. 모든 경우의 RMS 및 MSE는 Table 5에 나타난 바와 같이 학습 목표값에 비교하여 현저히 낮았으며, 최적의 뉴런 수는 RMS와 MSE가 각각 0.0243 K 및 0.0006 K²인 10으로 분석되었다.

Table 5 RMS, MSE maximal differences of the tested ANN models

Components		RMS (K)	MSE (K ²)	Maximal difference	
				Positive (K)	Negative (K)
Number of hidden layers	1	0.0200	0.0004	0.4612	-0.3838
	2	0.0228	0.0005	0.4501	-0.4499
	3	0.0282	0.0008	0.4608	-0.4594
	4	0.0175	0.0003	0.4562	-0.4315
	5	0.0240	0.0006	0.4332	-0.4681
Number of neurons in the hidden layers	10	0.0164	0.0003	0.4324	-0.4608
	11	0.0208	0.0004	0.5544	-0.4827
	12	0.0177	0.0003	0.4479	-0.4273
	13	0.0206	0.0004	0.4648	-0.4773
	14	0.0214	0.0005	0.4805	-0.4029
	15	0.0175	0.0003	0.4562	-0.4315
	16	0.0243	0.0006	0.5071	-0.4539
	17	0.0230	0.0005	0.4556	-0.4758
	18	0.0196	0.0004	0.4651	-0.3957
	19	0.0220	0.0005	0.5989	-0.5089
20	0.0216	0.0005	0.4307	-0.4813	

Learning rates	0.00	0.0211	0.0004	0.5475	-0.5140
	0.05	0.0218	0.0005	0.4247	-0.4823
	0.10	0.0192	0.0004	0.5805	-0.3603
	0.15	0.0199	0.0004	0.4530	-0.3737
	0.20	0.0224	0.0005	0.5631	-0.3708
	0.25	0.0214	0.0005	0.5140	-0.4524
	0.30	0.0202	0.0004	0.4420	-0.4987
	0.35	0.0202	0.0004	0.5331	-0.5126
	0.40	0.0174	0.0003	0.4885	-0.5048
	0.45	0.0259	0.0007	0.4819	-0.4426
	0.50	0.0167	0.0003	0.4892	-0.3523
	0.55	0.0181	0.0003	0.4132	-0.4806
	0.60	0.0234	0.0005	0.4618	-0.4825
	0.65	0.0190	0.0004	0.4150	-0.5136
	0.70	0.0231	0.0005	0.5125	-0.4361
	0.75	0.0164	0.0003	0.4324	-0.4608
	0.80	0.0204	0.0004	0.5468	-0.5226
	0.85	0.0214	0.0005	0.4603	-0.5091
	0.90	0.0254	0.0006	0.5133	-0.4731
	0.95	0.0213	0.0005	0.4689	-0.3260
1.00	0.0218	0.0005	0.5385	-0.4813	
Moments	0.00	0.0178	0.0003	0.4574	-0.4418
	0.05	0.0162	0.0003	0.5223	-0.4398
	0.10	0.0238	0.0006	0.4483	-0.4328
	0.15	0.0168	0.0003	0.4380	-0.4284
	0.20	0.0181	0.0003	0.4354	-0.4606
	0.25	0.0245	0.0006	0.4734	-0.4326
	0.30	0.0162	0.0003	0.4033	-0.4067
	0.35	0.0195	0.0004	0.4234	-0.4345
	0.40	0.0172	0.0003	0.4432	-0.4593
	0.45	0.0181	0.0003	0.4711	-0.5124
	0.50	0.0229	0.0005	0.5117	-0.4413
	0.55	0.0182	0.0003	0.4547	-0.4429
	0.60	0.0187	0.0004	0.5391	-0.4342
	0.65	0.0208	0.0004	0.5824	-0.3683
	0.70	0.0220	0.0005	0.4313	-0.4640
0.75	0.0192	0.0004	0.4699	-0.2697	
0.80	0.0220	0.0005	0.4389	-0.3796	
0.85	0.0225	0.0005	0.4941	-0.4174	
0.90	0.0164	0.0003	0.4324	-0.4608	
0.95	0.0181	0.0003	0.5008	-0.3601	
1.00	0.0201	0.0004	0.4798	-0.4167	

최적화의 세 번째 단계는 최적의 학습률을 결정하기 위한 것으로, 학습률이 0.00에서 1.00까지 0.05씩 증가하는 경우 대한 분석이 실시되었다. 숨겨진 층의 수와 숨겨진 층의 뉴런 수는 이전 단계에서 도출된 값인 4와 10이 적용 되었으며, 모멘트는 초기값으로 설정된 0.90로 적용되었다. 분석 결과 최적의 학습률은 RMS 및 MSE가 각각 0.0164 K, 0.0003 K²인 0.75로 나타났다.

마지막 최적화 단계는 최적의 모멘트 값을 결정하는 것으로써, 이 과정에서 학습률과 마찬가지로 0.00에서 1.00까지 0.05씩 증가하는 모델의 성능이 비교되었다. 나머지 매개변수인 숨겨진 층, 숨겨진 층의 뉴런 수, 학습률은 이전 단계에서 도출된 4, 10, 0.75로 각각 고정되었다. Table 5에 요약된 바와 같이 모든 모델들은 안정적인 결과를 나타냈으며, 최적의 모멘트는 0.30인 것으로 분석되었다. RMS와 MSE는 각각 0.0162 K와 0.0003 K²인 것으로 분석되었다. 일련의 과정을 바탕으로 본 연구에 적용된 이중외피건물에 대한 최적제어를 위한 최적의 인공지능망 모델을 적용하기 위한 조건은 숨겨진 층, 숨겨진 층의 뉴런수, 학습률 및 모멘트는 각각 4, 10, 0.75 및 0.30인 것으로 분석되었다.

3.2 최적 모델의 성능 평가

예측된 실내온도 변화값과 측정된 실내온도 변화값의 차이 분석(RMS 및 MSE)을 적용하여 최적화된 인공지능망 모델의 성능 평가가 실시되었다. 이를 위하여, 청천공(2008년 1월 2일)과 담천공(2008년 1월 11일)에 측정된 데이터가 적용되어 분석되었다.

각 측정일의 일사량과 중공층 온도의 변화분포는 Fig. 7~Fig. 8에 나타나 있다. 청천공 조건일 경우,

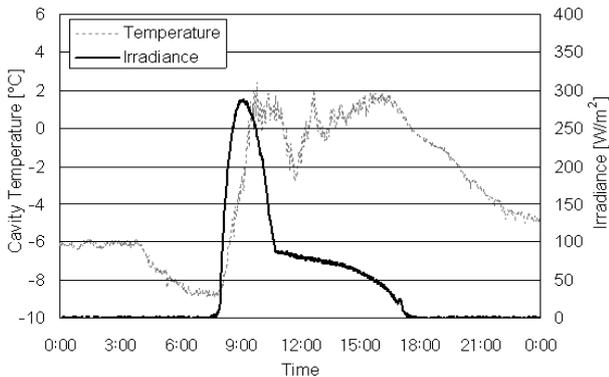


Fig. 7 Irradiance and cavity temperature under clear sky(East-facing facade).

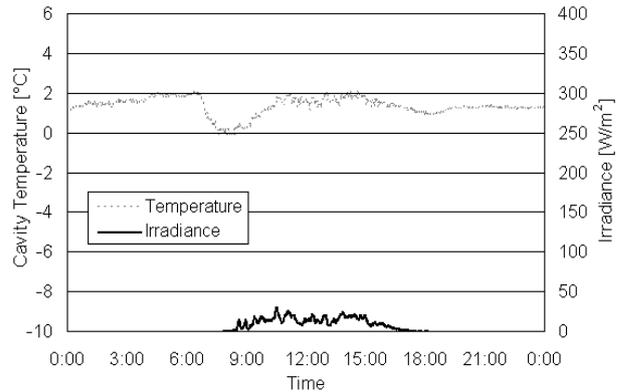


Fig. 8 Irradiance and cavity temperature under overcast sky(East-facing facade).

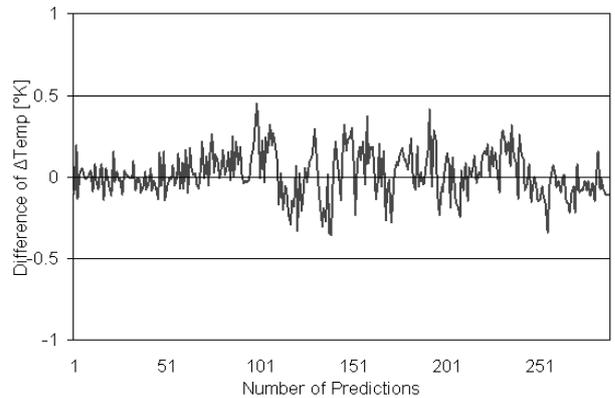


Fig. 9 Difference of ΔTemperature(clear sky).

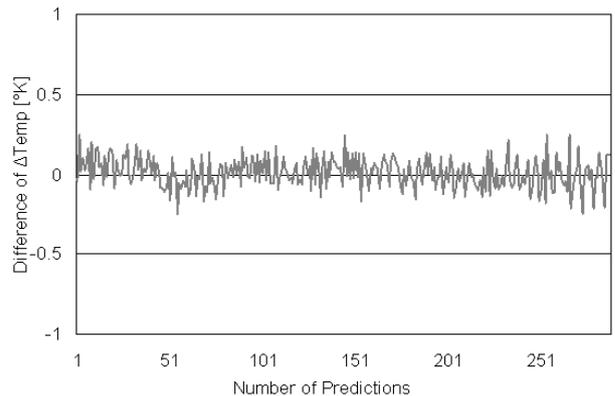


Fig. 10 Difference of ΔTemperature (overcast sky).

오전의 일사는 이중외피모듈의 수직면에 최대 287.1 W/m²로 도달하고 있으며, 그 결과 오전 8~10시 사이 중공층 온도가 급격히 상승하고 있다. 담천공일 경우 측정일 중 최대 일사량은 30.7 W/m²로 나타나 중공층 온도 상승에 현저한 영향을 미치지 못하는 것으로 분석된다. 그 결과 최고 중공층 온도는 청천

공의 경우보다 변화가 적으며 안정적으로 형성되고 있는 것으로 나타났다.

각 측정일의 실내 온도 변화량과 예측된 실내 온도 변화량의 차이는 Fig. 9~Fig. 10에 나타나 있다. 청천공 조건일 경우, 최대 차이값은 0.446 K와 -0.353 K이며, RMS 및 MSE는 각각 0.020 K 및 $0.0004 K^2$ 로 분석되어, 개발된 인공지능망 모델의 목표값을 만족시키는 것으로 밝혀졌다. 담천공 조건일 경우 역시 각각 0.009 K와 $0.0001 K^2$ 로써 안정적이며, 최대 차이값은 0.248 K와 -0.248 K로 나타났다.

측정 결과와 예측 결과의 유사성 분석을 통하여 개발된 인공지능망 모델의 예측 정확성과 상이한 외기 조건에 대한 적용을 통해 적응성이 증명되었다. 이러한 정확성 및 적응성을 바탕으로 인공지능망에 근간한 이중외피의 개구부 작동 및 난방 시스템 제어 로직의 적용이 가능할 것으로 예상된다.

4. 결 론

본 연구에서는 이중 외피 건물의 실내 온도제어를 위한 개선된 전략을 제시하기 위하여, 인공지능망을 적용한 이중외피의 실내 및 외측 개구부의 개방과 난방시스템의 작동을 제어하는 로직이 개발되었다. 인공지능망을 적용함에 따라 개구부와 난방 시스템에 대한 예측제어와 다양한 조건에 대한 적응제어가 가능할 것으로 분석되었다.

개발된 인공지능망 모델의 구조 및 학습방법을 위한 최적화 과정이 진행되었으며, 이를 통하여 최적의 숨겨진 층의 수, 숨겨진 층의 뉴런 수, 학습률, 모멘트는 각각 4, 10, 0.75, 0.3으로 결정되었다. 이러한 결과값을 적용한 모델을 제어로직에 사용함으로써 이중외피 건물의 개구부 및 난방시스템의 최적화된 제어가 유지되어, 실내온도의 적절한 조성과 에너지 효율을 향상할 수 있을 것으로 예상된다.

또한, 상이한 외기 환경 조건에 대한 적용 및 성능 평가를 실시하여 개발된 모델의 예측성 및 적응성이 확인되었다. 청천공 및 담천공 조건에 대하여 실시된 성능 평가에서 인공지능망 모델에서 예측된 실내온도 변화값과 실제 측정된 실내온도 변화값간의 차이(RMS 및 MSE)가 안정적으로 유지되는 것으로 나타나 개발된 인공지능망 모델의 예측정확성 및 적응성이 증명되었다. 이러한 예측정확성 및 적응성에 대한 연구결과를 바탕으로 인공지능망 모델은 이중외피 건물의 실내 온도 제어를 위한 로직

에 적용 가능할 것으로 예상된다.

본 논문에서 개발된 모델 및 제어로직은 겨울철 난방 시스템과 개구부 작동을 위한 것으로써 향후 연구를 통하여 여름철 및 중간기에 통합적으로 적용 가능한 전략 개발이 필요할 것으로 예상된다. 또한, 실험, 시뮬레이션 및 난방 시스템이 작용하는 건물로의 실제 적용 등을 통하여 제시된 방법에 대한 충분한 성능 평가 과정이 실시되어야 할 것이다.

후 기

이 논문은 2012년도 정부(교육과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구 사업임(과제번호 : 2012R1A1A1005272).

이 논문은 2011년도 정부(교육과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No.20110001398).

참고문헌

1. Kim, Y. M., Lee, J. H., Kim, S. M., and Kim, S., 2011, Effects of double skin envelopes on natural ventilation and heating loads in office buildings, *Energy and Buildings*, Vol. 43, pp. 2118-2126.
2. Sharmari, M. A., Alghoul, M. A., Sopian, K., Zain, M. F. M., and Elalaby, O., Perspectives of double skin facade systems in buildings and energy saving, 2011, *Renewable and Sustainable Energy Reviews*, Vol. 15, pp. 1468-1475.
3. Yoon, S. H. and Part, C. S., 2008, Static vs. dynamic control strategies of double skin systems, *Proceedings of Fall Annual Conference of the Korean Institute of Architectural Sustainable Environment and Building Systems*, pp. 90-95.
4. Yoon, K. S. and Park, C. S., 2010, Control levels of a double-skin facade, *Journal of the Architectural Institute of Korea*, Vol. 26, pp. 317-326.
5. Moon, J. W., 2011, Performance of ANN-based predictive and adaptive thermal-control methods for disturbances in and around residential buildings, *Building and Environment*, Vol. 48,

- pp. 15-26.
6. Lee, J. Y., Yeo, M. S., and Kim, K. W., 2002, Predictive control of the radiant floor heating system in apartment buildings, *Journal of Asian Architecture and Building Engineering*, Vol. 1, pp. 105-112.
 7. Stergiou, C. and Siganos, D., 2011, Neural Networks. Available from : http://www.doc.ic.ac.uk/~nd/surprise_96/journal/vol4/cs11/report.html.
 8. Yang, I. H., Yeo, M. S., and Kim, K. W., 2003, Application of artificial neural network to predict the optimal start time for heating system in building, *Energy Conversion and Management*, Vol. 44, pp. 2791-2809.
 9. Ben-Nakhi A. E. and Mahmoud, M. A., 2002, Energy conservation in buildings through efficient A/C control using neural networks, *Applied Energy*, Vol. 73. pp. 5-23.
 10. Argiriou, A. A., Bellas-Velidis, I., Kummert, M., and Andre, P., 2004, A neural network controller for hydronic heating systems of solar buildings, *Neural Networks*, Vol. 17, pp. 427-440.
 11. Morel, N., Bauer, M., El-Khoury, M., and Krauss, J., 2001, NEUROBAT, a predictive and adaptive heating control system using artificial neural networks. *International Journal of Solar Energy*, Vol. 21, pp. 161-201.
 12. MathWorks, 2005, MATLAB 14. Available from : <http://www.mathworks.com>.
 13. Datta, D., Tassou, S. A., and Marriott, D., 1997, Application of neural networks for the prediction of the energy consumption in a supermarket, *Proceedings of CLIMA 2000 Conference*, Brussels, Belgium, pp. 98-107.
 14. Yang, J., Rivard, H., and Zmeureanu, R., 2005, On-line building energy prediction using adaptive artificial neural networks, *Energy and Buildings*, Vol. 37, pp. 1250-1259.
 15. Kalogirou, S. A. and Bojic, M., 2000, Artificial neural networks for the prediction of the energy consumption of a passive solar building, *Energy*, Vol. 25, pp. 479-491.