



## 다층신경망 학습 알고리즘 변화에 따른 건물 냉방부하 예측 모델의 성능 비교 평가

### Comparative Evaluation of Building Cooling Load Prediction Models with Multi-Layer Neural Network Learning Algorithms

성남철\* · 홍구표\*\*

Namchul Seong\* · Goopyo Hong\*\*

\* Main author, Senior Researcher, Dept. of Architectural Engineering, Kangwon National Univ., Samcheok, South Korea (inamchul@kangwon.ac.kr)

\*\* Corresponding author, Assistant Professor, Dept. of Architectural Engineering, Kangwon National Univ., Samcheok, South Korea (goopyoh@kangwon.ac.kr)

#### ABSTRACT

**Purpose:** In this study, among the methods of applying machine learning when predicting the load of a building, the cooling load of a building was predicted using a neural network model. To investigate the appropriateness of the learning algorithm of the multi-layer neural network model, the main purpose is to compare the predictive performance according to the change in the learning algorithm. **Method:** Among the learning algorithms applicable to multilayer neural networks, a total of 16 algorithms were used to predict the cooling load and compare the prediction results. The input variables of the input layer of the neural network model are outdoor dry bulb temperature, outdoor humidity, and Seasonally Data. The training period is 70% and the test period was 30%. The number of layers in the hidden layer is 3, the number of neurons is 20, and Epochs is 100. CvRMSE and MBE are used as performance index of the prediction model. The maximum, minimum, average, and standard deviation of the 20 prediction results are calculated, and the prediction performance according to the change in the learning algorithm was compared. **Result:** As a result of analyzing the predictive performance for each learning algorithm, the predictive performance according to the learning algorithm was different. Considering the results and deviations of the two indicators of predictive performance comprehensively, the model using the Levenberg-Marquardt (LM) learning algorithm is judged to have the best predictive performance.

#### KEYWORD

다층신경망  
건물 냉방부하  
예측모델  
학습 알고리즘

Multi-Layer Neural Network  
Cooling Load  
Prediction Model  
Learning Algorithms

#### ACCEPTANCE INFO

Received Jul. 4, 2022  
Final revision received Jul. 19, 2022  
Accepted Jul. 25, 2022

© 2022. KIEAE all rights reserved.

## 1. 서론

통계에 따르면 건축물은 전 세계 최종 에너지 소비량의 약 35%를 차지하고 있는 것으로 조사되고 있으며, 이는 전 세계 온실가스 배출량의 3/4 수준이다[1]. 건축물은 운전단계에서 에너지 대부분을 소비하며, 특히 거주자에게 쾌적한 환경을 제공하기 위하여 약 50% 이상의 에너지를 공기조화에 사용되고 있다[2]. 그러므로 건축물에서의 에너지소비를 절약하기 위해서는 건물의 운전과 운영단계에서 효율적인 에너지 사용과 관리가 이루어져야 하며 이를 위해 정확한 건물의 에너지 수요와 부하 예측이 요구된다. 건물의 에너지소비량과 부하 예측을 위한 다양한 연구가 이루어지고 있으며, 이들 중 최근에는 기계학습과 인공지능을 기반으로 하는 기법이 주목받고 있고[3, 4] 기계학습 기법으로 예측 정확성을 높이는 연구도 진행되고 있다[5].

본 연구에서는 기계학습 방법 중 인공신경망(ANN, Artificial Neural Networks)의 종류인 다층신경망(Multi-Layer Neural Network)을 이용하여 건물 부하 예측 시에 건물의 부하를 정확하고 효과적으로 예측하고자 한다. 다층신경망을 이용한 예측 모델은 학습 알고리즘의 변화에 따라 예측성능이 변화하며 적절한 학습 알고

리즘의 선택이 중요하다. 에너지소비량 예측[6]과 실내환경 요소의 예측[7]에 관한 연구 결과에서도 이와 같은 중요성이 확인되었으며, 부하 예측을 위한 다층신경망 모델에도 적절한 학습 알고리즘의 선택이 필요하다.

따라서 본 연구에서는 기존의 부하 예측 시 학습 알고리즘의 비교 연구에서[8] 발전하여 다양한 학습 알고리즘을 추가로 적용하고, 여러 성능지표를 이용하여 학습 알고리즘의 변화에 따른 부하 예측 모델의 성능을 평가하였다. 다층신경망을 학습 알고리즘의 변화에 따른 예측성능 비교 평가는 건물 부하 예측 모델의 최적화와 성능향상에 활용될 수 있다.

## 2. 다층신경망을 이용한 건물 냉방부하 예측 모델

### 2.1. 시뮬레이션을 이용한 데이터 학습데이터 생성

본 연구에서는 건물의 냉방부하를 예측하기 위해 선행된 연구[9, 10]와 같이 업무용 표준건물의 시뮬레이션 결과로 생성된 데이터를 예측 모델의 학습에 활용하였다. 업무용 표준건물은 DOE의 Building Energy Codes Program의 표준건물 중에서 Commercial Prototype Building Models의 Middle Office Building[11]을 이용하였다. Fig. 1.은 Middle Office Building을 모델링한 그림이다.




Fig. 1. Modelling of middle office building

Table 1. Simulation condition of reference building (Middle office building)

Component	Features
Building Type	Middle-Scale Office
Total Building Area	4982 [m <sup>2</sup> ]
Weather Data and Site Location	TRY Seoul (latitude: 37.57°N, longitude: 126.97°E)
HVAC Operation Schedule	7:00~18:00
Internal Gain	Lighting 10.76 [W/m <sup>2</sup> ] People 18.58 [m <sup>2</sup> /person] Plug and Process 10.76 [W/m <sup>2</sup> ]
Envelope	Wall, Roof 0.157 [W/m <sup>2</sup> ·K] Window 1.29 [W/m <sup>2</sup> ·K] SHGC 0.581
SetPoint	Cooling 26 [°C]
Cooling Period	4/1~10/31
HVAC Sizing	Auto Calculated
Output Timestep	1 Hour

표준건물은 국내 상황을 고려하여 외벽과 최상층 지붕의 열관류율은 건축물의 에너지절약설계기준[12] 중부 2지역의 기준으로 변경하였다. 시뮬레이션을 위한 기상 데이터는 서울지역의 기상 데이터를 활용하였다. 그 밖의 데이터 생성을 위한 시뮬레이션의 주요 조건을 요약하여 정리하면 Table 1.과 같다. 시뮬레이션을 통해 건물의 냉방부하를 출력하였고 1시간 단위로 데이터를 생성하였다. 전체 시뮬레이션 기간은 1년 8,760시간이고 냉방 기간에 해당하는 4월 1일부터 10월 31일까지 데이터를 생성하였으며, 생성된 데이터는 5,136세트이다.

## 2.2. 건물 냉방부하 예측을 위한 다층신경망 모델

본 연구에서는 Matlab(R2020a)의 Neural Networks Toolbox에 포함되어있는 신경망 모델을 사용하여 다층신경망(Multi-Layer Neural Network)을 구성하고 건물의 냉방부하를 예측하였다. 다층신경망은 입력층(input layer), 은닉층(hidden layer), 출력층(output layer) 등 여러 층으로 구성된 신경망 모델을 말하며, 은닉층의 개수에 따라 얕은(Shallow) 신경망과 심층(Deep) 신경망으로 나뉜다[13]. 작성된 신경망의 구조와 입출력[6]은 Fig. 2.와 같다. 입력층은 학습을 위한 입력변수로 구성된다. 입력변수의 수에 따라 신경망 모델의 예측정확도는 변화하는 것으로 알려져 있으며 예측 결과에도 영향을 미친다[14]. 냉방부하 예측을 위한 입력층의 변수는 외기 건구온도, 외기 습도, 그리고 시간 데이터(Seasonally Data)로 하

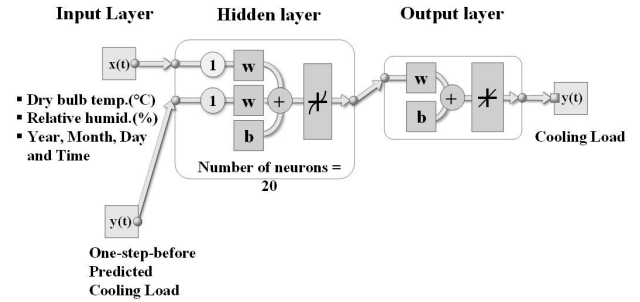


Fig. 2. Structure of multi-layer neural network

Table 2. Values of structural parameters and learning parameters

Division	Condition
Number of hidden layers	3
Number of neurons	20
Epochs	100
Training Data Size	70%

였다. 은닉층에서는 입력층으로부터 수신된 값이 내부의 뉴런(neuron)을 통해 신경망 학습이 수행된다. 출력층은 학습 결과에 따른 예측값인 냉방부하를 출력한다.

## 2.3. 신경망 입력조건과 데이터 전처리

### 1) 신경망 입력조건

정확한 예측 결과를 위하여 신경망의 입력조건 중 입력 매개변수를 설정하였다. 입력 매개변수는 구조적 매개변수(Structural parameter)와 학습 매개변수(Learning parameter)로 구분되는데, 구조적 매개변수는 신경망의 구조를 이루고 있는 은닉층과 그 내부에 존재하는 뉴런(neuron)으로 실제 학습이 이루어지는 곳이며 그 수에 따라 학습 용량이 결정된다. 학습 매개변수인 Epoch는 학습 단위로서 1회는 전체 데이터셋을 완전히 한 번 통과하는 것을 의미한다[15]. 학습에 사용되는 데이터의 양(Training Data Size)에 따라 신경망 모델의 예측정확도는 변화할 수 있는데 기존의 연구[16]를 참고하여 가장 일반적인 정확도를 갖는 70%로 설정하였다. 신경망 모델의 입력조건 조정에 의한 최적화 방법[17]에 따라서 예측정확도는 향상될 수 있으나 본 연구에서는 기존 최적화된 입력 파라미터를 참고하였으며, 적용된 신경망 입력조건은 Table 2.와 같다.

### 2) 데이터 전처리(preprocess)

데이터 전처리는 신경망의 학습 시 학습 및 예측성능 향상에 도움도움이 되도록 데이터를 가공하는 행위[18]를 말하며 그 종류로는 데이터의 특성을 고려하여 결측치, 이상치, 모순데이터 등을 제거하는 작업인 Data Cleaning, 2개 이상의 중복된 데이터를 병합하는 Data Integration, 데이터의 차원을 축소하여 데이터를 1자리 이내로 변환하거나 요약, 집화화 등을 수행하는 Data Transformation, 그 외에 방대한 데이터를 일정 시간 단위로 축소하는 Data Reduction과 Data Balancing 등이 있다. 본 연구에서는 생성된 건물 데이터의 특성을 고려하여 부하가 발생하지 않는 경우 0의 값을 제거하는 Data Cleaning과 데이터의 차원을 변환하는 Data

Transformation을 이용하였다. 냉방부하가 0인 시간의 데이터를 제거하여 2,772개의 데이터셋으로 변환하였으며, 숫자는 1의 소수점 두 자리까지로 변환하였다.

### 3. 다층신경망 학습 알고리즘과 성능 평가 방법

#### 3.1. 학습 알고리즘 종류

본 연구에서 비교한 학습 알고리즘의 종류는 Table 3.과 같으며 다층신경망 모델에 사용 가능한 학습 알고리즘은 Matlab(R2020a)의 Neural Networks Toolbox[19]를 참고하였다. 학습 알고리즘의 상세한 이론에 관한 내용은 지면상 생략한다. 학습 알고리즘은 가장 많이 사용되는 Levenberg-Marquardt(LM) 이외에도 베이스 정규화(BR), BFGS 준뉴턴(BFG), 탄력적 역전파(RP), 스케일링된 켈레 기울기(SCG), Powell/Beale 재시작 알고리즘을 사용한 켈레 기울기(CGB), Fletcher-Powell 켈레 기울기(CGF), Polak-Ribiere 켈레 기울기(CGP), 1스텝 할선법(OSS), 가변 학습률 경사 하강법(GDX), 모멘텀을 사용한 경사 하강법(GDM), 경사 하강법(GD)을 각각 사용하여 다층신경망을 학습시켰다.

#### 3.2. 예측성능 평가 방법

각 모델의 냉방부하 예측성능은 ASHRAE(American Society of Heating, Refrigerating and Air-Conditioning Engineers), FEMP(US DOE Federal Energy Management Program), IPMVP(International Performance Measurement and Verification Protocol)

의 M&V(Measurement and Verification) guideline에 따라 평가하였다. Table 4.와 같이 ASHRAE[20], FEMP[21], IPMVP[22]은 각각의 Measurement and Verification(M&V) 프로토콜(protocol)을 제시하고 있으며, Building Energy Model의 예측정확도 기준을 정하고 있다. 본 연구에서는 변동계수(CvRMSE, Coefficient of Variation of the Root Mean Square Error)와 평균편향오차(MBE, Mean Bias Error)를 모델의 예측 성능지표로 사용하였다. CvRMSE는 분산을 고려해 추정값들의 흩어진 정도를 의미하며, MBE는 데이터들의 편향성을 통하여 추정값들이 목표값에 얼마나 근접하게 근접을 형성하는지를 추적하여 오차를 파악하는 오차분석 지표이다. CvRMSE와 MBE를 구하는 식은 다음과 같다(Eq. 1).(Eq. 2).

$$CvRMSE = \left[ \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n-p} \right]^{1/2} / \bar{y} \times 100 \quad (Eq. 1)$$

$$MBE = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)}{(n-p) \times \bar{y}} \times 100 \quad (Eq. 2)$$

- 여기서,
- $n$  : 데이터의 개수
- $y_i$  : 생성된 데이터 값
- $\hat{y}_i$  : 예측된 데이터 값
- $\bar{y}$  : 생성된 데이터 평균
- $p$  : 독립변수의 수

모델의 정확한 예측성능을 평가하기 위해 각 학습 알고리즘을 사용하여 냉방부하의 예측을 20회씩 반복하여 수행한 후 예측 성능지표인 CvRMSE와 MBE의 최대, 최소, 평균, 표준편차를 산출하여 비교하였다.

### 4. 예측성능 결과 및 비교분석

#### 4.1. CvRMSE 예측성능 평가

Fig. 3.은 각 알고리즘의 예측성능 중 학습 기간의 CvRMSE의 결과를 나타낸다. 각 학습 알고리즘에 따른 예측성능 결과 중 CvRMSE의 평균값은 ASHRAE guideline 14의 기준인 30% 이내로 모두 정확성을 확보하는 것으로 나타났다. 그러나 경사 하강법 계

Table 3. Multi-Layer neural network learning algorithms

Type	Features
LM	Levenberg-Marquardt
BR	Bayesian regularization backpropagation
BFG	BFGS quasi-Newton backpropagation
RP	Resilient backpropagation
SCG	Scaled conjugate gradient backpropagation
CGB	Conjugate gradient backpropagation with Powell-Beale restarts
CGF	Conjugate gradient backpropagation with Fletcher-Reeves updates
CGP	Conjugate gradient backpropagation with Polak-Ribiere updates
OSS	One-step secant backpropagation
GDX	Gradient descent with momentum and adaptive learning rate backpropagation
GDM	Gradient descent with momentum backpropagation
GD	Gradient descent backpropagation

Table 4. Acceptable calibration tolerance

Calibration Type	Index	Acceptable Value*		
		ASHRAE guideline 14	FEMP	IPMVP
Monthly	MBE monthly	±5%	±5%	±20%
	CvRMSE monthly	15%	15%	-
Hourly	MBE hourly	±10%	±10%	±5%
	CvRMSE hourly	30%	30%	20%

\* Lower values indicate better calibration.

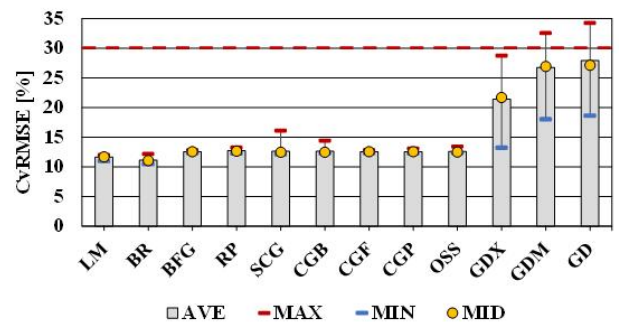


Fig. 3. Model accuracy of multi-layer neural network models according to training algorithm(CvRMSE) - Training period

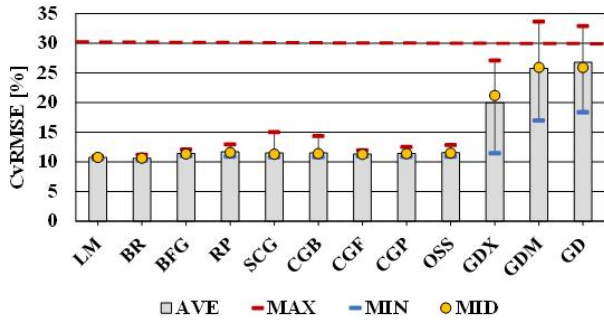


Fig. 4. Model accuracy of multi-layer neural network models according to training algorithm (CvRMSE) - Testing period

열을 응용한 GDX, GDM, GD 학습 알고리즘을 사용한 모델의 경우 예측 결과의 편차가 매우 크게 나타나며 일부 결과에서 30% 이상의 예측성능을 나타내어 기준을 만족하지 못하였다. 모델 중 LM 학습 알고리즘을 이용한 모델과 BR 학습 알고리즘을 이용한 모델의 CvRMSE 평균값이 약 11%대의 가장 우수한 예측성능을 보였으며, 그 외 BFG, RP, SCG, CGB, CGF, CGP, OSS 학습 알고리즘을 사용한 모델의 학습 기간 CvRMSE의 평균값은 12.56~12.71% 사이의 값을 나타냈다. 20회 반복 학습에 의한 학습 기간의 CvRMSE의 최솟값, 평균값이 가장 낮은 모델은 BR 학습 알고리즘을 사용한 모델이며, 최댓값은 가장 낮은 모델은 LM 학습 알고리즘을 사용한 모델이 가장 낮았다.

Fig. 4.는 각 알고리즘의 예측성능 중 시험 기간의 CvRMSE의 결과를 나타낸다. 학습 기간의 결과와 마찬가지로 시험 기간의 각 CvRMSE의 평균도 ASHRAE guideline 14의 기준인 30% 이내로 모두 정확성을 확보하는 것으로 나타났다. 시험 기간의 예측성능 결과에서도 경사 하강법 계열을 응용한 GDX, GDM, GD 학습 알고리즘을 사용한 모델의 경우 예측 결과의 편차가 매우 크게 나타나며 최댓값을 포함하여 일부 결과에서 30% 이상의 예측성능을 나타내어 기준을 만족하지 못하였다. 그 외 BFG, RP, SCG, CGB, CGF, CGP, OSS 학습 알고리즘을 사용한 모델의 시험 기간 CvRMSE의 평균값은 11.34~11.68% 사이의 값을 나타냈으며, 모델 중 LM과 BR 학습 알고리즘을 이용한 모델의 CvRMSE 평균값이 약 10%의 값으로 가장 우수한 예측성능을 보였다. 20회 반복 학습에 의한 시험 기간의 CvRMSE의 최댓값이 가장 낮은 모델은 LM 학습 알고리즘을 사용한 모델이며, BR 학습 알고리즘을 사용하였을 때 최솟값과 평균값이 가장 낮았다.

#### 4.2. MBE 예측성능 평가

Fig. 5.는 각 알고리즘의 예측성능 중 학습 기간의 MBE를 나타낸다. 각 학습 알고리즘에 따른 예측성능 결과 중 MBE의 평균값은 경사 하강법 계열을 응용한 GDX, GDM, GD 학습 알고리즘을 사용한 모델을 제외하고 ASHRAE guideline 14의 기준인  $\pm 10\%$  이내를 만족하는 정확성을 확보하는 것으로 나타났다. 나머지 모델들은 3.12%~4.53% 사이의 값을 나타냈으며, 5% 이내로 매우 정확한 예측성능을 보였다. GDX 학습 알고리즘을 사용한 모델은 14.16%, GDM 학습 알고리즘을 사용한 모델은 19.46%, GD 학습 알고리즘을 사용한 모델은 20.47%로 예측성능이 기준에 미치지 못하며 부하




Fig. 5. Model accuracy of multi-layer neural network models according to training algorithm (MBE) - Training period




Fig. 6. Model accuracy of multi-layer neural network models according to training algorithm (MBE) - Testing period

예측 모델로 사용하기 적합하지 않다. 20회 반복 학습에 의한 학습 기간의 MBE의 최댓값, 최솟값, 평균값이 가장 낮은 모델은 BFG 학습 알고리즘을 사용한 모델이다.

Fig. 6.은 각 알고리즘의 예측성능 중 시험 기간의 MBE를 나타낸다. 학습기간과 마찬가지로 각 학습 알고리즘에 따른 예측성능 결과 중 MBE의 평균값은 경사 하강법 계열을 응용한 GDX, GDM, GD 학습 알고리즘을 사용한 모델을 제외하고 ASHRAE guideline 14의 기준인  $\pm 10\%$  이내를 만족하는 정확성을 확보하는 것으로 나타났다. 나머지 모델들은 3.01%~4.59% 사이의 값을 나타냈으며, 5% 이내로 매우 정확한 예측성능을 보였다. GDX 학습 알고리즘을 사용한 모델은 13.64%, GDM 학습 알고리즘을 사용한 모델은 18.51%, GD 학습 알고리즘을 사용한 모델은 20.01%로 예측성능이 기준에 미치지 못하며 부하 예측 모델로 사용하기 적합하지 않다. 20회 반복 학습에 의한 학습 기간의 MBE의 평균값은 CGF 학습 알고리즘을 사용하였을 때 가장 낮았다.

#### 4.3. 종합 분석

Table 5.는 각 학습 알고리즘을 사용하여 20회를 반복한 예측성능 결과 중 CvRMSE의 최솟값, 최댓값, 평균값 및 표준편차를 요약하여 정리한 것이다. 학습 기간의 CvRMSE 평균값은 BR 학습 알고리즘을 사용한 모델이 11.16%로 가장 예측성능이 우수하였으며, 시험 기간의 CvRMSE 평균값도 BR 학습 알고리즘을 사용한 모델이 10.60%로 예측성능이 가장 우수하였다. 아주 근소한 차이로 LM 학습 알고리즘을 사용한 모델이 학습 기간에서는 11.64%, 시험 기간에서는 10.74%로 우수한 예측성능을 보였다. 그러나 시험 기간에서

평균값 이외의 예측성능은 LM 학습 알고리즘을 사용한 모델이 최솟값 10.48%, 최댓값은 10.94%로 더 정확한 예측성능을 나타냈으며, 표준편차도 0.12로 더 작아서 일정한 예측성능을 나타내었다.

Fig. 3.과 Fig. 4.에서도 확인할 수 있듯이 CvRMSE의 표준편차는 대부분 모델에서 학습 기간과 시험 기간 모두 1 미만으로 나타나 예측 결과가 일정하게 분포하는 것을 알 수 있으나, SCG와 CGB 학습 알고리즘을 사용한 모델의 예측 결과의 편차가 각각 학습 기간에서 0.85, 0.47, 시험 기간에서 0.89, 0.74로 다소 크게 나타났다. 특히 경사 하강법 계열의 GD, GDM, GD 학습 알고리즘을 사용한 모델은 표준편차가 학습 기간에서는 3.80~4.22, 시험 기간에서 3.71~4.19로 예측성능이 낮은 것 외에 예측 결과도 일정하지 않은 것을 확인하였다.

Table 6.은 각 학습 알고리즘을 사용하여 20회를 반복한 예측성능 결과 중 MBE의 최솟값, 최댓값, 평균값 및 표준편차를 요약하여 정리한 것이다. 학습 기간의 MBE 평균값은 BFG 학습 알고리즘을 사용한 모델이 3.09%로 가장 예측성능이 우수하였으며, 시험 기간의 MBE 평균값은 GCF 학습 알고리즘을 사용한 모델이 2.82%로 가장 예측성능이 우수하였다.

Fig. 5.와 Fig. 6.에서도 확인할 수 있듯이 MBE의 표준편차는 SCG, CGB, OSS 학습 알고리즘을 사용한 모델이 편차가 1 이상으로 나타나 일정하지 않은 예측 결과를 나타내는 것을 알 수 있으며, 모델에서 학습 기간과 시험 기간 모두 1 미만으로 나타나 예측 결과

가 일정하게 분포하는 것을 알 수 있다. 표준편차가 가장 적은 예측 모델은 학습 기간에서는 LM 학습 알고리즘을 사용한 모델의 표준편차가 0.51로 가장 일정한 예측 결과를 나타내는 것으로 나타났으며, 시험 기간에서는 CFG 학습 알고리즘을 사용한 모델의 표준편차가 0.55로 가장 일정한 예측 결과를 나타내었다. 경사 하강법 계열의 GD, GDM, GD 학습 알고리즘을 사용한 모델은 표준편차가 학습 기간에서는 3.43~4.39, 시험 기간에서 3.65~4.11로 예측성능이 낮은 것 외에 예측 결과도 일정하지 않은 것을 확인하였다.

CvRMSE는 분포적인 일치도를 평가하는 개념이며, MBE는 오차의 합산을 평가하는 지표로 활용된다[23]. 따라서 예측성능의 두 지표의 결과와 편차들을 종합적으로 고려할 때 LM 학습 알고리즘을 사용한 모델이 MBE 성능지표가 다소 높지만 가장 우수한 예측성능을 갖는 모델로 판단된다.

경사 하강법 계열의 GD, GDM, GD를 학습알고리즘으로 사용한 모델들은 손실 함수의 기울기를 통해 함수의 최솟값을 찾는 알고리즘이다. 이러한 경사 하강법의 단점으로는 지역 최솟값(Local Minima) 문제가 꼽힌다. 이것은 손실 함수의 그래프가 복잡해짐으로써 유일한 최솟값을 찾기 어려울 때 발생하는 문제로 주로 학습률에 기인하는 것으로 알려져 있다. 경사 하강법 계열의 학습 알고리즘이 다른 알고리즘들에 비하여 예측성능이 크게 떨어진 것은 이러한 문제가 발생한 것으로 판단된다.

이처럼 다층신경망의 예측성능은 같은 조건 내에서도 학습 알고

Table 5. CvRMSE of load prediction result

Type	Min.		Max.		Ave.		SD	
	Training	Testing	Training	Testing	Training	Testing	Training	Testing
LM	10.99	<b>10.48</b>	<b>12.02</b>	<b>10.94</b>	11.64	10.74	0.30	<b>0.12</b>
BR	<b>10.46</b>	10.21	12.17	11.21	<b>11.16</b>	<b>10.60</b>	0.65	0.31
BFG	12.30	10.97	12.79	12.08	12.56	11.43	0.17	0.37
RP	12.24	10.91	13.23	12.94	12.71	11.68	0.31	0.67
SCG	12.09	10.78	16.10	14.99	12.61	11.49	0.85	0.89
CGB	12.29	10.80	14.41	14.33	12.63	11.49	0.47	0.74
CGF	12.31	10.92	12.84	11.95	12.56	11.34	<b>0.16</b>	0.28
CGP	12.25	10.82	13.09	12.48	12.57	11.43	0.22	0.40
OSS	12.35	10.88	13.41	12.83	12.60	11.53	0.26	0.44
GD	13.22	11.43	28.74	27.09	21.41	19.97	4.22	4.19
GDM	18.02	16.96	32.52	33.64	26.74	25.75	3.80	3.90
GD	18.61	18.34	34.25	32.90	27.92	26.82	3.98	3.71

Table 6. MBE of load prediction result

Type	Min.		Max.		Ave.		SD	
	Training	Testing	Training	Testing	Training	Testing	Training	Testing
LM	3.13	2.77	4.75	5.00	4.16	4.15	<b>0.51</b>	0.68
BR	3.15	2.91	5.46	6.05	4.53	4.59	0.63	0.87
BFG	<b>1.97</b>	1.92	3.76	3.84	<b>3.09</b>	3.01	0.55	0.67
RP	2.72	2.35	4.82	4.81	3.51	3.25	0.58	0.72
SCG	2.02	1.81	8.38	8.09	3.51	3.37	1.39	1.39
CGB	1.98	<b>1.77</b>	7.03	7.66	3.39	3.20	1.13	1.32
CGF	2.33	2.04	<b>4.00</b>	<b>3.78</b>	3.12	<b>2.82</b>	0.60	<b>0.55</b>
CGP	2.37	2.29	4.56	4.53	3.23	3.13	0.72	0.75
OSS	2.12	1.94	5.85	5.94	3.39	3.27	1.03	1.09
GD	4.46	4.39	21.03	19.94	14.16	13.64	4.39	4.11
GDM	10.74	9.67	23.91	24.30	19.46	18.51	3.43	3.65
GD	11.74	11.43	25.99	26.71	20.47	20.01	3.66	3.68

리즘의 변화에 따라서 예측성능이 다르게 나타났다. 따라서 다층신경망의 학습 알고리즘을 부하 예측에 적용할 때는 예측하고자 하는 데이터의 형태, 크기, 종류 등을 고려하여, 가장 좋은 결과를 얻을 수 있는 적절한 알고리즘의 선택이 필요하다.

## 5. 결론

본 연구에서는 다층신경망을 이용한 건물의 냉방부하 예측 모델에 여러 학습 알고리즘을 적용한 후 학습 알고리즘을 변화시킨 모델들의 예측성능 평가를 통해 학습 알고리즘의 예측성능 특징을 살펴 보았다. 생성된 데이터를 이용하여 역전파 알고리즘 기반의 다층신경망 모델의 부하 예측 결과를 성능지표를 활용하여 비교 평가하였으며, 그 결과 모델의 학습 알고리즘 변화에 따라 예측성능의 차이를 확인하였다.

예측성능을 CvRMSE로만 평가하는 경우 BR 학습 알고리즘을 사용한 예측 모델이 가장 우수한 성능을 보였고, MBE로만 평가하는 경우 CGF 학습 알고리즘을 사용한 예측 모델이 가장 우수한 성능을 보였다. 일반적으로 비선형 회귀 예측에 가장 적합한 것으로 알려진 LM 학습 알고리즘을 사용한 예측 모델이 MBE 성능지표는 다소 높지만, 모든 예측성능은 기준치를 만족하는 동시에 예측성능도 우수하며 결과도 일정한 것을 확인할 수 있었다.

공조 설비 분야에서의 주요 예측 대상인 에너지소비량, 냉난방 부하와 같은 시계열 형태의 데이터는 LM 학습 알고리즘을 사용한 비선형 회귀 예측 모델을 적용하는 것이 가장 유리한 것으로 판단된다. 경사 하강법 계열의 학습 알고리즘을 사용한 예측 모델은 예측 결과의 오차도 크게 나타났으며, ASHRAE guideline 14의 기준을 만족하지 못하는 경우도 빈번하며 예측 결과도 일정하지 않은 것으로 나타났다.

학습 조건과 예측 대상에 따라서 학습 알고리즘 사용의 적정성이 달라질 수 있다. 건물 부하 예측을 위해 신경망 모델을 사용하는 경우 적절한 학습 알고리즘을 선택하여야 하며, 본 연구의 결과가 건물 부하 예측 모델의 학습 알고리즘 선택에 도움이 될 수 있을 것으로 기대된다.

학습 알고리즘은 모델을 훈련하는 데 사용된 데이터에 대해서는 비교적 잘 작동하지만 새로운 데이터에서는 일반화되지 않는 과적합 현상이 발생할 수 있다. 본 연구에서는 이와 같은 과적합 여부는 수행하지 못하였다. 향후 연구에서는 다양한 건물을 이용하여 여러 패턴의 부하와 더 많은 데이터를 적용하여 부하 예측 모델의 성능향상에 관한 다양한 연구를 추가로 수행할 예정이며, 학습 알고리즘 이외의 예측성능을 향상하기 위한 다양한 접근이 필요하다.

## Acknowledgement

이 논문은 2021년도 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임(No.2021R1A6A3A01087034).

이 연구는 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. 2020R1C1C1010801).

## References

- [1] IEA, 2019 Global status report for buildings and construction, 2019.
- [2] DOE, An assessment of energy technologies and research opportunities. Quadrennial Technology Review. 2015, pp.12-19.
- [3] M.W. Ahmad, M. Mourshed, Y. Rezgui, Trees VS Neurons: Comparison between random forest and ANN for high-resolution prediction of building energy consumption, Energy and Buildings, 2017, 147, pp.77-89.
- [4] D. Koschwitz, J. Frisch, C. van Treeck, Data-driven heating and cooling load predictions for non-residential buildings based on support vector machine regression and NARX recurrent neural network: A comparative study on district scale, Energy, 2018, 165, pp.134-142.
- [5] 박상구, 문현준, 김수덕, 자기회귀시차분포 모델을 적용한 병원 건물의 시간별 난방부하 예측, 한국: 한국생활환경학회지, 제25권 제1호, 2018, pp.43-51. // (S.K. Park, H.J. Moon, S. Kim, Application of an autoregressive distributed lag model for the hourly heating load prediction of a hospital building, Journal of The Korean Society of Living Environmental System, 25(1), 2018, pp.43-51.)
- [6] J.H. Kim, N.C. Seong, W.C. Choi, Comparative evaluation of predicting energy consumption of absorption heat pump with multilayer shallow neural network training algorithms, Buildings, 12(1), 2021, p.13.
- [7] J. Kim et al., Assessment of ANN algorithms for the concentration prediction of indoor air pollutants in child daycare centers, Energies, 15(7), 2022, p.2654.
- [8] 성남철, 홍구표, 건물 냉방부하 예측을 위한 다층신경망 학습 알고리즘의 비교, 한국: 대한건축학회 학술발표대회 논문집, 제42권 제1호, 2022.04, pp.580-581. // (N.C. Seong, G. Hong, A comparison of multi-layered neural network learning algorithms for forecasting building cooling loads, Conference of AIK, 42(1), 2022.04, pp.580-581.)
- [9] N.C. Seong, J.H. Kim, W. Choi, Adjustment of multiple variables for optimal control of building energy performance via a genetic algorithm, Buildings, 2020, 10(11), p.195.
- [10] 이철원, 성남철, 최원창, Python을 이용한 냉동기 에너지소비량 예측 모델의 성능 개선 및 비교 평가, 한국: 한국건축환경설비학회 논문집, 제15권 제3호, 2021, pp.252-264. // (C.W. Lee, N.C. Seong, W. Choi, Performance improvement and comparative evaluation of the chiller energy consumption forecasting model using Python, Journal of Korean Institute of Architectural Sustainable Environment and Building Systems, 15(3), 2021, pp.252-264.)
- [11] K. Field, M. Deru, D. Studer, Using DOE commercial reference buildings for simulation studies, Proceedings of SimBuild, 4(1), 2010, pp.85-93.
- [12] 국토교통부, 건축물의 설비기준에 관한 규칙, 국토교통부 고시 제 2017-467호. // (Ministry of Land, Infrastructure and Transport, Rules on the Building Equipment Standards, Korea MOLIT, 2017.)
- [13] D.E. Kim, M. Gofman, Comparison of shallow and deep neural networks for network intrusion detection, In 2018 IEEE 8th Annual Computing and Communication Workshop and Conference (CCWC), 2018.01, pp.204-208. IEEE.
- [14] 성남철, 최기봉, 최원창, 인공지능망 입력 변수에 따른 송풍기 풍량 예측모델 개발 및 평가, 한국: 한국건축환경설비학회 논문집, 제13권 제3호, 2019, pp.191-202. // (N.C. Seong, K.B. Choi, W. Choi, Development and Evaluation of predictive model for fan air flow rate according to artificial neural network input variables, Journal of Korean Institute of Architectural Sustainable Environment and Building Systems, 13(3), 2019, pp.191-202.)
- [15] J.H. Kim, N.C. Seong, W.C. Choi, Forecasting the energy consumption of an actual air handling unit and absorption chiller using ANN models, Energies, 13(17), 2020, p.4361.
- [16] J.H. Kim, N.C. Seong, W.C. Choi, Cooling load forecasting via predictive optimization of a nonlinear autoregressive exogenous (NARX) neural network model, Sustainability, 11(23), 2019, p.6535.
- [17] J.H. Kim, N.C. Seong, W.C. Choi, Modeling and optimizing a chiller system using a machine learning algorithm, Energies, 12(15), 2019, p.2860.
- [18] D.S. Joo, D.J. Choi, H. Park, The effects of data preprocessing in the determination of coagulant dosing rate, Water Research, 34(13), 2000, pp.3295-3302.

- 
- [19] 얇은 다층 신경망 훈련시키고 적용하기 - MATLAB & Simulink - MathWorks 한국, <https://kr.mathworks.com/help/deeplearning/ug/train-and-apply-multilayer-neural-networks.html#bss3311-2>, 2022.05.04. // (Train and Apply Multilayer Shallow Neural Networks - MATLAB & Simulink - MathWorks Korea, <https://kr.mathworks.com/help/deeplearning/ug/train-and-apply-multilayer-neural-networks.html#bss3311-2>, 2022.05.04.)
- [20] ASHRAE. Measurement of Energy and Demand Saving, 2014.
- [21] L.J. Webster, J. Bradford, M.V. Guidelines: Measurement and verification for federal energy projects, version 3.0; Technical Report; U.S. Department of Energy Federal Energy Management Program: Washington, DC, USA, 2008.
- [22] Efficiency Valuation Organization, International Performance Measurement & Verification Protocol; EVO: North Georgia, AL, USA, 2016.
- [23] 공동석 외 3인, 성능진단 데이터로 보정된 모델을 이용한 기존건축물의 에너지시뮬레이션 기법, 한국: 설비공학논문집, 제26권 제5호, 2014, pp.231-239. // (D.S. Kong et al., Existing building energy simulation method using calibrated model by energy audit data, Korean Journal of Air-Conditioning and Refrigeration Engineering, 26(5), 2014, pp.231-239.)