



건물 에너지 분야의 인공지능 기반 연구 동향 분석 - 해외 저널 논문 중심으로 -

*Trends of Research on Building Energy Efficiency utilizing Artificial Intelligence Technologies
- Focused on International Journal Papers -*

윤여범* · 서병모** · 한진목*** · 이광호**** · 조슬연*****

Yeo Beom Yoon* · Byeongmo Seo** · Jinmog Han*** · Kwang Ho Lee**** · Soolyeon Cho*****

* Main author, Ph.D. Candidate, College of Design, North Carolina State Univ., United States (yeobeom_yoon@ncsu.edu)

** Coauthor, Ph.D. Student, College of Design, North Carolina State Univ., United States (bseo2@ncsu.edu)

*** Coauthor, Ph.D. Student, College of Design, North Carolina State Univ., United States (jhan25@ncsu.edu)

**** Coauthor, Associate Professor, Dept. of Architecture, Korea Univ., Korea (kwhlee@korea.ac.kr)

***** Corresponding author, Professor, School of Architecture, College of Design, North Carolina State Univ., United States (soolyeon_cho@ncsu.edu)

ABSTRACT

Purpose: Recently, there are many research projects conducted to achieve smart cities. Smart cities consist of smart buildings that include efficient energy supply and consumption systems. The Artificial Intelligence (AI) technologies became useful tools for this purpose due to their reliability of prediction accuracy and credibility. It is very important to better understand how the AI algorithms work and can be applied for specific areas of energy efficiency in buildings. This paper presents how AI technologies, such as Artificial Neural Network (ANN), Convolutional Neural Network (CNN), Recurrent Neural Network (RNN), and Long Short-Term Memory (LSTM), are currently being utilized in the energy efficiency research in buildings. **Method:** International journal papers are reviewed especially for those utilizing ANN, CNN, RNN, and LSTM algorithms in building science and technologies. In-depth analyses are conducted comparing specific approaches, research outcomes, advantages, and disadvantages of key papers. **Result:** Findings show that the ANN, CNN, RNN, and LSTM algorithms are mainly used for the prediction of building energy loads and system energy uses. Compared to other AI algorithms, the LSTM algorithms have higher prediction accuracies due to the characteristics of LSTM structure.

KEYWORD

건물에너지
인공신경망
합성곱 신경망
순환 신경망
장단기 메모리

Building Energy
Artificial Neural Network
Convolutional Neural Network
Recurrent Neural Network
Long-Short Term Memory

ACCEPTANCE INFO

Received Dec. 2, 2020

Final revision received Dec. 12, 2020

Accepted Dec. 15, 2020

© 2020. KIEAE all rights reserved.

1. 서론

1.1. 연구의 배경 및 목적

International Energy Agency (IEA)에서 발표한 전 세계 CO₂ 배출량 분석에 따르면 전 세계적으로 에너지 소비량의 증가함에 따라 화석 연료 연소를 통한 CO₂ 배출량 또한 증가하였으며 2017년 기준 1990년 대비 60%가 증가하였다[1]. CO₂는 대기 중에 100년 이상 남는 온실가스이기 때문에 온실가스 배출량을 줄일 수 있는 대책 마련이 시급하다[2]. 이에 따라 우리나라 정부는 온실가스 감축 목표로 2020년까지 Business As Usual (BAU) 대비 30%의 온실가스 배출량 감소를 목표로 하고 있으며, 2015년 제 21차 유엔기후변화협약 (United Nations Framework Convention on Climate Change; UNFCCC) 당사국 총회에서 합의된 파리협정에서는 2030년까지 BAU 대비 37%의 온실가스 배출량 감소시키는 것으로 목표를 상향 조정하였다[3].

온실가스 배출 및 에너지 문제가 전 세계 특히 각 나라의 대도시의 주요 문제로 대두되고 있으며 건축을 비롯한 도시 개발 및 재생사업 등 다양한 분야에서의 온실가스 배출 및 에너지 절감 대한 인식이 높

아지고 있다[4]. 환경문제 해결과 불필요한 에너지 낭비 절감 또는 에너지 수요와 공급의 균형을 맞추기 위해서는 효율적인 에너지 생산 및 공급을 위한 구체적인 방안이 요구된다. 또한, 효율적인 에너지 생산 및 공급을 위해서 선행적으로 에너지 수요량과 공급량에 대한 정교한 예측이 중요하다[5].

1.2. 연구의 방법 및 범위

건물에너지 분야에서는 정확한 건물에너지의 부하 및 소비량 예측을 위한 연구가 활발하게 진행되고 있다. 그 중 인공지능을 이용한 방법은 신뢰성과 예측 정확도가 높아 많은 연구에서 활용하고 있다 [6]. 특히, 외부 기상조건에 큰 영향을 받는 태양광과 풍력을 통해 생산되는 전기에너지양을 인공지능 기술을 활용하여 정확하게 예측하고 있다[7]. 하지만 현재 사용되고 개발되고 있는 인공지능 알고리즘이 많기 때문에 인공지능 알고리즘의 특성을 정확히 파악하고 목적에 맞는 인공지능 알고리즘을 활용하는 것이 매우 중요하다. 따라서 본 논문에서는 인공지능 알고리즘 중 활발하게 연구에 사용되고 있는 인공 신경망 (Artificial Neural Network; ANN), 합성곱 신경망 (Convolutional Neural Network; CNN), 순환 신경망 (Recurrent Neural Network; RNN), 그리고 장단기 메모리 (Long-Short Term Memory; LSTM)의 구조를 파악하고 건물에너지 분야에 사

용된 선행 논문들을 수집 및 분석하여 에너지 수요와 공급 매칭을 위해 적합한 인공지능 알고리즘 기술을 제안하고자 한다. 본 연구의 목표를 달성하기 위하여 해외 저널을 중심으로 각 인공지능 알고리즘을 분석하였다. 현재 국내에서도 인공지능 관련 연구가 활발하게 진행되고 있지만 미국을 100이라고 가정하였을 때 한국은 전문가 정성평가 부문에서 80.1, 논문 평가 부문에서 43.1, 그리고 특허평가 부문에서 47.4를 나타내고 있다[8]. 특히, 논문 평가와 특허평가 부문은 미국의 절반 수준으로 해외의 인공지능 기술 수준이 국내의 인공지능 기술 수준보다 앞서 있기 때문에[8] 현재 세계의 인공지능 기술 연구 동향을 정확히 인지하고자 본 논문에서는 해외 저널을 중심으로 연구 동향 분석을 진행하였다.

2. 인공지능 기술의 개념과 이론

2.1. 인공지능

인공지능은 지능적인 요소가 포함된 모든 기술을 총칭하는 가장 넓은 개념으로서, 인공지능을 구현하는 방법에 따라 기계학습(Machine Learning), 딥러닝(Deep Learning)으로 구분된다. 인공지능의 하위집단 개념인 기계학습은 1959년 Arthur Lee Samuel에 의해 처음 소개되었다[9]. 기계학습은 제공되는 데이터에 대해 분석하고 학습하며 학습한 내용을 기반으로 판단 및 예측하는 기술이다[10]. 기계학습의 하위집단 개념인 딥러닝은 기계학습의 알고리즘 중에서 인간의 두뇌를 모델로 한 인공신경망을 바탕으로 발전한 형태이다. 딥러닝은 스스로 학습하여 미래를 예측하는 기술이다. 딥러닝은 많은 데이터를 바탕으로 의사 결정을 내리며 많은 양의 연산을 처리할 수 있다[9].

건축 분야에서의 인공지능 관련 연구는 다른 분야에 비해서 뒤쳐지는 상황이나 점진적으로 증가하는 추세이며, 주로 기계학습 모델이 활용되고 있다[11]. 기계학습은 크게 학습방법에 따라 지도 학습(Supervised Learning), 비지도 학습(Unsupervised Learning), 강화 학습(Reinforcement Learning)으로 나뉜다.

본 논문에서는 지도 학습 알고리즘 중 ANN, CNN, 그리고 RNN에 대해 소개하고 해당 알고리즘을 활용한 건축 분야의 선행연구를 파악하여 본 연구의 적합한 알고리즘 기술을 제안하고자 한다.

2.2. 인공신경망

Fig. 1.은 ANN의 구조를 나타낸 것이며 크게 3단계로 입력층(Input Layer), 은닉층(Hidden Layer), 출력층(Output Layer)으로 구성되어 있다[12]. ANN의 기본 알고리즘인 전방 전달 신경망(Feed-forward Neural Network)은 입력층에서 은닉층을 거쳐 출력층까지 전달되는 방식으로 진행된다. 각 층에는 노드들로 구성되며 각 노드는 연결되어 있다. 입력층에서 뉴런들이 외부입력을 받으면 입력 데이터에 가중치가 적용되면서 활성화수를 통해 결과값을 출력한다. 결과 데이터에서 오차가 발생하는 경우, 해당 오차만큼 이전 계층으로 전파시켜 가중치를 갱신하는 과정이 반복되는데 이를 역전파(Back-propagation)라고 한다.

가중치를 갱신하는 방법으로는 경사 하강법(Gradient Descent)을 반복하여 최적의 값을 찾아낸다. 이 과정을 통해 ANN 모델의 최

소 오차율을 찾아내고 결과 데이터의 예측 정확도를 높게 된다. 그러나 ANN의 모든 입력 데이터는 독립적으로 인식되기 때문에, 지속해서 일어나는 시계열 데이터(Time-series Data)를 해석하기 어렵다는 단점이 있다[13].

2.3. 합성곱 신경망

Fig. 2.는 CNN의 구조를 나타낸다. ANN과 마찬가지로 여러 개의 층으로 구성되어 있으며 추가로 합성곱 계층(Convolutional Layer), 풀링 계층(Pooling Layer), 그리고 완전 연결 계층(Fully-connected Layer)이 포함되어 있다[14]. 각 계층에 대한 설명은 다음과 같다.

- 합성곱 계층에서는 이미지와 같은 3차원 데이터를 입력받으면 다음 계층에서도 3차원 데이터로 전달할 수 있도록 도와주는 역할을 한다. 즉, 기능 추출을 위해 이미지를 합성하는 필터를 포함하고 있으며 CNN의 핵심 계층이다.
- 풀링 계층에서는 합성곱 계층에서 온 데이터에서 고유의 특성을 추출하면서 크기를 줄이거나 특정 데이터를 강조하는 역할을 한다. 합성곱 계층과는 다르게 학습대상의 매개변수가 없으며 대상 영역에서 최대값 또는 평균으로 처리한다.
- 완전 연결 계층에서는 합성곱 계층과 풀링 계층에서 나온 결과를 취합하여 데이터를 정의된 라벨로 분류하는 역할을 한다. 가장 정확한 가중치를 결정하기 위해 자체적인 역전파 과정을 거치게 된다.

즉, CNN의 학습방법은 합성곱과 풀링 과정을 반복하면서 데이터의 고유 특징을 찾고 그 특징을 입력 데이터로 활용하여 완전 연결 계층으로 보내 분류를 수행하는 것이다. 하지만 CNN은 계산 과정이 오래 걸린다는 단점이 있다.




Fig. 1. Structure of Artificial Neural Network




Fig. 2. Structure of Convolutional Neural Network

2.4. 순환신경망

Fig. 3.은 RNN의 구조를 나타낸다. Fig. 3.에 나타난 A는 RNN의 한 덩어리이며 입력값인 x_t 를 받아 결과값 h_t 를 출력하게 된다. 그리고 A를 둘러싼 반복은 다음 단계에서도 이전 단계의 정보를 받는 것을 의미한다[15]. 이는 데이터 학습 과정에서 과거의 결과 데이터가 현재의 출력 데이터에 영향을 주는 구조이기 때문에 현재의 학습과 과거의 학습이 서로 연결 가능하다는 것을 의미한다[16]. 따라서 RNN은 시간적 상관관계를 가지고 있는 시계열 데이터 처리에 적합하다[17].

그러나, RNN은 많은 학습데이터를 처리할 때 학습률이 갱신되지 않는 경사 소실 (Gradient Vanishing) 문제가 발생하여 오랜 과거의 시계열 데이터가 반영되지 않는 한계점이 있다[15].

2.5. 장단기메모리의 구조

RNN의 단점을 극복하기 위해 1997년 Sepp Hochreiter과 Jürgen Schmidhuber가 LSTM을 소개하였다[18].

Fig. 4.는 LSTM의 구조를 나타낸다. LSTM 구조는 기존 RNN 구조를 개선하여 장기적인 학습을 위해 필요한 정보를 전송할 수 있도록 설계되었다[18]. LSTM의 핵심인 Cell State라고 불리는 특징 층을 통해 이전 학습에서 진행되었던 가중치의 기억 또는 제거 여부를 결정하는 미래 학습과 과거에서의 학습과 연결을 가능하게 도와준다[19].

LSTM의 구조는 기존 RNN의 메모리 셀에 망각 게이트 (Forget Gate), 입력 게이트 (Input Gate), 출력 게이트 (Output Gate)를 추가한 것으로 각 게이트에 대한 설명은 다음과 같다.

- Forget Gate에서는 현재 입력값과 이전 출력값을 고려해서, 직전 타임스텝의 Cell State로부터 얼마만큼의 값을 버릴지를 결정하는 역할을 한다.
- Input Gate는 들어오는 새로운 정보 중에서 어떤 값을 Forget Gate를 통해 값이 1차 변경된 Cell State에 얼마만큼의 값을 추가 할지 결정한다.




Fig. 3. Structure of Recurrent Neural Network[18]




Fig. 4. Structure of Long Short-Term Memory[18]

· Output Gate에서는 Input Gate를 거쳐 최종적으로 정해진 Cell State의 값과 현재 타임스텝의 입력값을 곱연산 하여 현재 타임스텝의 예측값 출력 및 Cell State 값을 다음 타임스텝으로 전달한다[18].

이러한 독특한 구조 덕분에, LSTM은 RNN 보다 긴 과정의 정보를 기억하고 학습하는데 특화되어 있다[20].

3. 연구 동향 분석

3.1. 연구 동향 분석 방법

건물에너지 분야의 인공지능 연구 트렌드를 파악하기 위해서 인공지능 기술 이름, Building, 그리고 Energy를 키워드로 입력하였다. 다른 분야의 연구가 검색되는 것을 방지하기 위해 논문제목, Abstract에 입력한 키워드가 표기되어 있는 선행연구들을 수집하여 분석하였다. 논문을 수집하기 위해서 Scencedirect 사이트와 Google Scholar를 활용하였다.

3.2. 건물에너지 분야에서의 인공지능 전망 선행연구

Fig. 5.는 건물에너지 분야에서의 연도별 ANN 관련 논문 편수를 나타낸다. 건물에너지 분야의 ANN 관련 논문 편수는 2000년도부터 증가하다가 2016년도부터 출판 편수가 급증하여 2020년 66편의 논문이 출판되었다.

Table 1.은 건물에너지 분야에서 ANN이 사용된 목적을 나타낸다. 최근 연구 동향을 파악하고자 2000년부터 2020년까지 출판된 논문의 연구 주제를 나타낸다. 예측을 위해 ANN을 사용한 논문이 144편으로 가장 많았으며, 최적제어에 40편, 성능평가에 17편, 최적 설계에 10편의 논문이 ANN 관련되어 출판되었다. 빌딩 리모델링 관련되어 5편, 빌딩 자재 관련하여 2편, 건물 모니터링 관련 2편이 출판된 것을 확인할 수 있다. 10편 이상 출판된 분야는 총 4개 분야로 다음과 같다.

예측 분야는 건물 전체 에너지 사용량 예측도 있지만, 냉방 혹은 난방만 예측한 논문도 많이 존재하였으며, 가스, 전기, 온수 사용량을 예측한 논문도 존재하였다. 에너지 사용량 뿐만 아니라 실내 온도, 실내 온열 쾌적감, 습도, 재실자를 예측한 논문도 존재하였으며, 태양광 시스템의 전기 발전량을 예측한 논문도 있다. 또한 자연채광과 일사량을 예측하는데 ANN도 활용하였다.

최적제어 분야는 태양광 시스템 패널의 태양 추적, 냉·난방 시스템의 최적제어, 이중외피의 창호 최적제어, Setback temperature 시




Fig. 5. Number of ANN Related Publications in the Field of Building Energy

작점 최적 제어 등이 존재하였다.

성능평가 분야는 대부분 HVAC 시스템의 성능평가 연구가 주를 이루었다. 에너지 저장장치, 냉동기, 지열 히트펌프, 스텐드 에어컨 등의 성능평가에 ANN을 활용하였다.

최적설계 분야는 건물 디자인, 패시브 디자인, 건물일체형 태양광 시스템, 이중외피, 지열 히트펌프의 최적설계에 ANN을 활용하였다.

Table 2.는 건물 에너지 분야에 ANN이 활용된 논문 중 일부를 보여준다.

Li et al. (2019)은 초기 설계 단계에서의 건물에너지 최적화를 위해 ANN을 활용하여 사무용 건물의 설계요소를 통한 냉·난방 및 조명에너지 소비량을 예측하였다. 입력 데이터로 창면적비, 건물의 길이 및 너비, 건물의 층수 및 층고, 방의 개수를 사용하였으며 냉·난방 및 전체 에너지 예측과 조명에너지예측에서 각각 5%와 10% 이내의 오차율을 보였다[21].

Reynolds et al. (2018)은 건물에너지 소비량을 절감하기 위해 ANN과 유전알고리즘을 결합한 모델 예측 제어 (Model Predictive Control)를 제안하였다. 입력 데이터로 날씨, 재실자 수, 실내 설정 온도 스케줄, 과거 실내온도를 사용하여 에너지 소비량을 예측하였다. 본 연구에서 구축된 모델은 예측 제어에 활용하여 2월에 약 25%의 난방 에너지 절감량을 보였다[22].

Gaballa and Cho (2019)은 실시간 일사량을 예측하는 ANN 모델을 개발하였다. 입력 데이터로 건구온도, 상대습도, 해당 월, 일, 시간 그리고 태양천정각을 활용하였으며 개발된 ANN 모델의 예측 정확도는 Coefficient of Variation of Root Mean Squared Error (Cv(RMSE)) 19% 그리고 Normalized Mean Bias Error (NMBE) 5%를 보였다[23].

Table 1. Purpose of the ANN related publications

Purposes	Number of Publications
Prediction	144
Optimal control	40
Performance assessment	17
Optimal design	10
Building retrofitting	5
Building materials	2
Monitoring	2
Demand response	1
Development of algorithm	1
Detection	1

Table 2. Example of the Information of Publications related to ANN in the Field of Building Energy

Title	Author (Year)	Content	Reference
An ANN-based fast building energy consumption prediction method for complex architectural form at the early design stage	Li et al. (2019)	Heating, cooling, lighting energy consumption prediction	[21]
A zone-level, building energy optimization combining an artificial neural network, a genetic algorithm	Reynolds et al. (2018)	Building energy optimization	[22]
Prediction of hourly solar radiation using temperature and humidity for real-time building energy simulation	Gaballa and Cho (2019)	Prediction of solar radiation	[23]
Artificial neural network models using thermal sensations and occupants' behavior for predicting thermal comfort	Deng and Chen (2019)	Predicting thermal comfort	[24]
Fault and sensor error diagnostic strategies for a vapor compression refrigeration system by using fuzzy inference systems and artificial neural network	Kocyigit et al. (2015)	Fault detection & diagnostic strategies for a vapor compression refrigeration system	[25]

Deng and Chen (2018)은 재실자의 한서감 (Thermal Sensations) 과 행동 데이터를 활용하여 실제 환경에서의 열적 쾌적도를 평가하기 위한 ANN 모델을 개발하였다. 열 곳의 사무용 건물과 열 곳의 주택 및 아파트에서 실내온도, 상대습도, 착의량, 활동량, 한서감 그리고 재실자의 행동 데이터를 수집하였다. 실내온도와 상대습도의 관계와 재실자의 한서감과 활동량의 관계를 파악하기 위한 두 개의 ANN 모델을 개발하였다[24].

Kocyigit (2015)는 증기 압축 냉동시스템에서의 고장 진단 (Fault Diagnostic)을 위한 ANN 모델을 개발하였다. 입력 데이터로 증발 압력, 응축 압력, 과열기, 과냉기, 그리고 압축기의 표면온도를 활용하였으며, 8개의 고장 시나리오에 대해 학습하였다. 학습된 모델은 8개의 고장 시나리오에 성공적으로 진단한 것으로 나타났다[25].

타 알고리즘보다 건물에너지 분야에서 일찍 사용되었고 현재도 활발하게 연구되고 있다. 건물에너지 분야에서 ANN 선행연구는 대부분 예측을 위한 것이다. 예측물은 Cv(RMSE)와 NMBE 기준에는 충족하나 타 알고리즘과 비교시 상대적으로 예측률이 낮은 것으로 나타나며 이는 아래에서 자세히 서술하였다.

3.3. 건물에너지 분야에서의 합성곱 신경망 선행연구

Fig. 6.은 건물에너지 분야에서의 연도별 CNN 관련 논문 편수를 나타낸다. 논문 제목, Abstract, 그리고 키워드에 CNN, Building, 그리고 Energy를 포함한 논문이 2015년까지 존재하지 않았다. 2016년도를 시작으로 건물에너지 분야에 CNN 관련 논문이 출판되기 시작하여 2020년 12편의 논문이 출판되었다.

Table 3.은 건물에너지 분야에서 2000년부터 2020년까지 CNN 이 사용된 목적을 나타낸다.




Fig. 6. Number of CNN Related Publications in the Field of Building Energy

예측 분야에서는 건물 에너지 사용량, 부하, 기기발열, 인체발열 예측을 위해 CNN을 활용하였다. 모니터링 분야에서는 건물 열환경 및 재실자 모니터링 등을 위해 CNN을 활용하였다. 감지 분야는 시스템 이상감지와 재실자 감지를 위해 CNN을 활용하였으며, 최적제어 분야에서는 예측된 재실자에 근거한 최적의 에어컨 제어에 활용하였다. 또한 실내 공기질 실측 데이터 중 누락된 데이터를 해결하기 위해 CNN이 활용되기도 하였다.

Table 4.는 건물 에너지 분야에 CNN이 활용된 논문 중 일부를 보여준다.

Huang and Hao (2020)은 에너지 효율적인 공조 시스템을 구현하기 위해 재실자를 인지하는 CNN 모델을 개발하였다. 개발된 모델은 감시 카메라를 통해 재실자의 수, 카메라와 재실자의 거리 및 각도를 감지하며 98%의 높은 정확도를 나타냈다[26].

Benitez et al. (2020)은 실제 실내 공기질 데이터에서 누락된 데이터가 있는 경우 누락된 데이터를 추정하는 방법을 제안하였다. 실내 공기질 데이터를 20%, 50%, 그리고 80% 제거하여 누락된 데이터를 만든 후 분석을 진행하였다. 주성분 분석 (Principle Component Analysis; PCA), 입력층이 동일한 네트워크인 오토인코더 (Autoencoders; AE) 등과 비교했을 때 CNN을 활용하였을 때 정확도가 높음을 확인했다[27].

Streltsov et al. (2020)은 주거건물의 에너지 사용량을 예측하기 위하여 위성이나 항공사진 등을 사용하였다. 이를 위해 CNN을 활용하여 위성이나 항공사진에서 건물을 자동으로 인지하고 건물 유형별로 분류를 진행하였다. 미국 Florida 주의 Gainesville와 미국 California 주의 San Diego에서 평가하였고 각각 84%, 88% 정확도로 건물을 식별하였으며, 주거건물 식별 정확도는 99%를 보였다. 이를 활용하여 건물의 크기를 추정하고 Random forest regressions을 활용하여 에너지 사용량을 예측하였다[28].

CNN이 활용된 논문 편수는 적지만 다른 알고리즘과는 다른 방식으로 문제를 접근한다. 과거 데이터를 활용하여 예측을 하는 다른 알고리즘 기술과는 달리 카메라나 위성사진 등 그래픽을 분석하여 예측을 하는 연구가 활발히 진행되고 있다.

Table 3. Purpose of the CNN related publications

Purposes	Number of Publications
Prediction	6
Monitoring	3
Detection	2
Optimal control	1
Tackle the missing value	1

Table 4. Example of the Information of Publications related to CNN in the Field of Building Energy

Title	Author (Year)	Content	Reference
Development of CNN-based visual recognition air conditioner for smart buildings	Huang and Hao (2020)	Optimal control of A/C based on the predicted occupancy	[26]
Imputing missing indoor air quality data via variational convolutional autoencoders: Implications for ventilation management of subway metro systems	Benitez et al. (2020)	Tackle the missing value problem in indoor air quality data	[27]
Estimating residential building energy consumption using overhead imagery	Streltsov et al. (2020)	Buildings are detected and classified by type	[28]

3.4. 건물에너지 분야에서의 순환신경망 선행연구

Fig. 7.은 건물에너지 분야에서의 연도별 RNN 관련 논문 편수를 나타낸다. 2017년전까지는 RNN을 건물에너지에 활용한 논문이 매우 적었다. 2018년도를 기점으로 RNN이 건물에너지 분야에 활용되기 시작하여 2020년 10편의 논문이 출판되었다.

Table 5.는 건물에너지 분야에서 RNN이 사용된 목적을 나타낸다.

다른 알고리즘과 같이 예측 분야에서 가장 많은 논문이 출판되었다. 건물에너지, 전기 에너지, 난방 사용량, 부하, 가스, 전기, 그리고 재실자 예측을 위해서 RNN이 사용되었으며, HVAC 에너지 사용량 및 태양광 발전량 예측에서도 RNN이 활용되었다.

감지 부분에서는 주거건물의 에너지 사용량을 확인하고 이상감지를 판단하는 곳에 RNN이 활용되었으며 모니터링 분야에서는 에너지 모니터링하는 연구에 RNN이 활용되었다. 또한 축열조 최적 용량 산정을 위해 RNN을 활용하기도 하였다.

Table 6.은 건물 에너지 분야에 RNN이 활용된 논문 중 일부를 보여준다.

Weng and Mourshed (2019)은 RNN을 활용해 시간별 실내 작용온도 예측 모델을 개발하였다. 활용된 입력 값으로는 시간, 일, 월 데이터와 외기온도, 확산일사량, 산란일사량, 풍량, 상대습도 그리고 창면적비 데이터를 활용하였다. 예측된 데이터의 70%는 1° C 이내, 23%는 2° C 이내의 오차를 보였다[29].

Javed et al. (2014)은 난방기 동안 쾌적한 실내환경을 유지하기 위해 RNN 알고리즘을 활용한 난방 공조제어 모델을 개발하였다.

Table 5. Purpose of the RNN related publications

Purposes	Number of Publications
Prediction	22
Detection	1
Monitoring	1
Optimal system sizing	1




Fig. 7. Number of RNN Related Publications in the Field of Building Energy

Table 6. Example of the Information of Publications related to RNN in the Field of Building Energy

Title	Author (Year)	Content	Reference
RNN-based forecasting of indoor temperature in a naturally ventilated residential building	Weng and Mourshed (2019)	Indoor temperature forecasting	[29]
Comparison of the robustness of RNN, MPC and ANN controller for residential heating system.	Javed et al. (2014)	Optimal control of heating system	[30]
Load demand forecasting of residential buildings using a deep learning model	Wen et al. (2020)	RNN model with Gated Recurrent Unit is proposed to forecast the load demand of residential buildings	[31]
Deep learning techniques for energy forecasting and condition monitoring in the manufacturing sector	Mawson and Hughes (2020)	Energy forecasting and condition monitoring	[32]

개발된 RNN 기반 제어는 외기온도와 일사량의 영향을 고려하여 최적의 설정온도를 도출하였다. 또한, 재실자가 없는 경우 최저 설정 온도로 변경하여 에너지 절감에도 고려하였으며 RNN 모델 기반 제어는 ANN 모델 기반 제어 대비 최대 약 19%의 에너지 절감 가능성을 나타냈다[30].

Wen et al. (2020)은 미국 Texas 주의 Austin에 위치한 주거건물의 시간별 부하 데이터를 사용하여 RNN 모델의 정확도를 입증하였다. 또한 과거의 데이터를 활용하여 누락된 데이터를 채우는 기능도 탑재하고 있다[31].

Mawson and Hughes (2020)은 생산 일정, 기후 조건, 시설 건물의 열적 특성, 건물 동작 및 사용을 기반으로 제조 시설 에너지 소비 및 작업장 조건을 예측하기 위해 Feed forward neural network 및 RNN의 사용을 제안하고 비교하였다. Feed forward 모델의 경우 건물 에너지, 실내 공기 온도 및 습도의 정확도가 각각 92%, 99%, 그리고 64%이다. RNN 모델은 Feed forward 모델과 동일한 변수를 활용했을 때 건물에너지는 96%, 실내 공기는 99%, 그리고 실내 습도의 정확도는 57%를 보였다[32].

3.5. 건물에너지 분야에서의 장단기메모리 선행연구

Fig. 8.은 건물에너지 분야에서의 연도별 LSTM 관련 논문 편수를 나타낸다. 건물에너지 분야에서 LSTM 관련 논문은 2018년까지 전무하다. 위에서 설명하였듯이 본 논문에서 수집한 선행연구들은 논문제목, Abstract, 그리고 키워드에 LSTM, Building, 그리고 Energy를 포함한 논문을 수집하였기 때문에 실제로는 2018년 전에도 LSTM이 건물에너지 분야에 사용되어 있을 수 있다. 하지만 본 논문에서 활용한 수집 방법으로 논문을 수집하였을 때 2019년부터 LSTM이 건물에너지 분야에 사용되기 시작했으며 2020년 19편의 논문이 출판되었다.

Table 7.은 건물에너지 분야에서 LSTM이 사용된 목적을 나타낸다. LSTM 또한 건물 에너지 분야에서 대부분 예측을 위해 활용되고 있다.

예측 분야에서는 건물에너지, 부하, 전기사용량, HVAC 에너지 사용량 예측 뿐 만 아니라 내부발열, Plug load, 재실자, 그리고 PV 발전량 예측에도 활용되고 있다. 최적제어의 경우 Air handling unit 최적 제어를 위해 LSTM을 활용하였으며, 실측 건물 에너지 데이터의 누락된 데이터로 인한 문제를 해결하는 용도로도 활용되었다.

Table 8.은 건물 에너지 분야에 LSTM이 활용된 논문 중 일부를 보여준다.




Fig. 8. Number of LSTM Related Publications in the Field of Building Energy

Table 7. Purpose of the LSTM related publications

Purposes	Number of Publications
Prediction	22
Optimal control	1
Tackle the missing value	1

Mtibaa et al. (2020)은 멀티존 공조 시스템에서의 정확한 실내 공기 온도 예측을 위해 LSTM 모델을 활용하였다. 입력 데이터로 시간 및 일 데이터, 공급온도, 난방 요구량, 외기온도 등을 활용하였으며 2시간 후의 데이터를 예측하였다. 변풍량 및 정풍량 공조 시스템에 적용하여 성능 평가한 결과, 기존 ANN의 오차율보다 50% 절감 가능한 것으로 나타났다[33].

Qolomany et al. (2017)은 건물 안의 재실자 수를 예측하는 방안으로 LSTM 모델과 자기회귀 누적 이동평균 (Autoregressive Integrated Moving Average; ARIMA) 모델을 구축하여 재실자 수의 예측 정확도를 비교하였다. 비교 결과, LSTM 모델이 ARIMA 모델보다 높은 예측률을 보였다[34].

Xu et al. (2019)은 실내 온도를 예측하는 LSTM 예측 모델을 개발하였다. 분석 결과, 5분 간격 예측의 경우 LSTM 모델이 ANN 모델보다 약 8% 높은 예측 정확도를 보였다. 30분 간격 예측의 경우, 두 모델 간 예측 정확도 차이는 3%로 다소 감소하였는데 그 이유는 예측 간격이 커짐에 따른 학습데이터의 양의 감소에 의한 것으로 판단하였다[35].

Abdel-Nasser and Mahmoud (2019)은 주요 신재생 에너지 중 하나인 태양광 발전의 스마트 그리드 안에서 안정적인 수급을 위해 LSTM을 활용한 태양광 발전량 예측 모델을 개발하였다. 일사량은 패턴이 일정하지 않다는 점에서 기존 ANN 모델은 낮은 예측률을

Table 8. Example of the Information of Publications related to LSTM in the Field of Building Energy

Title	Author (Year)	Content	Reference
LSTM-based indoor air temperature prediction framework for HVAC systems in smart buildings.	Mtibaa et al. (2020)	Indoor air temperature prediction	[33]
Role of deep LSTM neural networks and Wi-Fi networks in support of occupancy prediction in smart buildings.	Qolomany et al. (2017)	Occupancy prediction	[34]
Improving prediction performance for indoor temperature in public buildings based on a novel deep learning method.	Xu et al. (2019)	Indoor air temperature prediction	[35]
Accurate photovoltaic power forecasting models using deep LSTM-RNN	Abdel-Nasser and Mahmoud (2019)	Photovoltaic power forecasting	[36]
Short-term energy use prediction of solar-assisted water heating system: Application case of combined attention-based LSTM and time-series decomposition	Heidari and Khovalyg (2020)	Energy prediction of solar-assisted water heating system	[37]
Predicting residential energy consumption using CNN-LSTM neural networks.	Kim and Cho (2019)	Energy consumption prediction	[38]

보인 반면, LSTM 모델은 한 시간 앞의 태양광 발전량을 높은 정확도로 예측하였다[36].

Heidari and Khovalyg (2020)은 신재생 에너지를 활용하는 온수 시스템의 최적 운영을 위한 온수 에너지 사용량을 예측하기 위해 LSTM 모델을 활용하였다. LSTM 모델이 ANN 모델보다 약 25% 높은 예측 정확도를 보였다[37].

Kim and Cho (2019)은 안정적인 전력 공급을 목표로 정확한 에너지 소비량 예측을 위해 LSTM과 CNN을 결합한 주거용 건물의 에너지 소비량 예측 모델을 개발하였다. CNN은 에너지 소비에 영향을 미치는 변수들의 특징을 추출할 수 있으며, LSTM은 시계열 데이터의 불규칙한 경향이 있는 정보를 파악할 수 있다. 해당 연구에서는 두 모델의 특징들을 결합한 CNN-LSTM 모델을 개발하여 이전에는 예측하기 어려웠던 전기 에너지 소비량을 거의 완벽하게 예측하였다. 특히, 분, 시, 일, 주 단위의 데이터에서도 높은 예측 정확도를 나타냈다[38].

RNN 및 LSTM 관련 연구는 에너지 소비량 예측, 실내온도 예측, 예측 제어 등 시계열 데이터를 활용한 연구들이 활발히 진행되는 것으로 확인되었다. 특히, 알고리즘의 특징에 적합하게 시계열 데이터를 다루는 주제에 집중되어 있다. 예측률 측면에서 보면 LSTM은 기존 ANN 모델과 대비하여 예측 정확도가 크게 향상되는 것으로 나타났다[33,35,36,37].

4. 결론

본 연구의 목표는 인공지능 기술의 구조적 특성 파악과 선행연구 분석을 통하여 수요 공급 매칭 등 건물 에너지 분야에서 활용가능성이 높다고 판단되는 인공지능 알고리즘 기술을 소개하는 것에 있다. 본 연구에서는 ANN, CNN, RNN, 그리고 LSTM의 구조와 건물에너지 분야에서의 각 알고리즘 기술의 연구 동향을 파악하였다. 본 연구를 통하여 에너지 공급 및 수요 예측, 더 나아가 스마트 시티에 적용 가능한 인공지능 알고리즘 중 최적의 인공지능 알고리즘을 선정하기 위한 기초적인 데이터로 활용 가능하다.

ANN의 경우 가장 많은 연구가 진행되었으며 예측, 제어, 고장진단 등 다방면으로 건물에너지 분야에서 활용되었지만 지속적으로

제공되는 시계열 데이터의 분석에서 한계를 보였다.

CNN의 경우 한 개의 이미지를 하나로 인식하는 ANN과 달리 여러 데이터로 인식하여 데이터의 부분특성을 파악하는데 장점이 있지만 처리 시간이 길다는 단점이 존재한다. 건물에너지 분야에서는 2016년부터 활용되었으며, 예측과 건물 모니터링에 주로 활용되었다. 또한 CNN이 독자적으로 활용되기 보다는 LSTM 등 다른 알고리즘과의 결합을 통해 사용되었다.

RNN의 경우 과거의 데이터가 현재 데이터를 예측하는데 영향을 주기 때문에 데이터의 패턴을 활용한다. 따라서 시간적 상관관계를 가지고 있는 시계열 데이터 처리에 적합한 구조를 가지고 있다. 하지만 RNN은 많은 학습데이터를 처리할 때 오차가 갱신되지 않는 경사 소실 문제가 발생하여 오랜 과거의 시계열 데이터가 반영되지 않는 한계점을 가지고 있다. 건물에너지 분야에서는 다른 알고리즘과 동일하게 예측을 위해 주로 사용되고 있다.

LSTM의 경우 RNN의 경사소실 문제를 해결하기 위하여 개발되었다. LSTM 또한 건물에너지 분야에서 예측을 위해 주로 사용되고 있다. 다른 알고리즘과의 예측률을 비교하였을 때 ANN, CNN 보다 높은 예측률을 보이는 것을 확인할 수 있다.

에너지 수요와 공급 매칭을 위해 외부 환경 데이터, 건물 데이터가 필요하다. 외부 환경 데이터와 건물 내부 데이터 모두 시계열 데이터로 시계열 데이터에 특화되고 건물에너지 분야에서 타 알고리즘에 비하여 높은 예측률을 보이는 LSTM 모델이 에너지 수요와 공급 매칭을 위해 적합한 알고리즘이라고 판단된다.

추후 연구에서는 본 논문에서 언급한 알고리즘 기술을 구현하여 건물부하, 태양광 시스템 발전량을 예측하여 예측률을 상호 비교할 예정이다.

Acknowledgement

본 연구는 산업통상자원부(MOTIE)와 한국에너지기술평가원(KETEP)의 지원을 받아 수행한 연구 과제입니다(No. 2019 271010015B).

Reference

- [1] International Energy Agency, CO₂ emissions from fuel combustion. 2019.
- [2] E. Terrenoire et al., The contribution of carbon dioxide emissions from the aviation sector to future climate change. *Environmental research letters*. 2019. Vol. 14. No. 8. 084019.
- [3] UN. World Urbanization Prospects: The 2018 Revision. 2019.
- [4] 조수연, 이승복, 건물데이터를 통한 건물에너지 절감 가능성에 대한 연구. *설비공학회 논문집*, 제29권 제11호, 2017, pp.580-591. // (S.Y. Cho, S.B. Leigh, A Study of the Possibility of Building Energy Saving through the Building Data: A Case Study of Macro to Micro Building Energy Analysis. *Korean Journal of Air-Conditioning and Refrigeration Engineering*, 29(11), 2017, pp.580-591.)
- [5] H. Luo et al., A short-term energy prediction system based on edge computing for smart city. *Future Generation Computer Systems*, Vol. 101, 2019, pp.444-457.
- [6] J. Bedi, D. Toshniwal, Deep learning framework to forecast electricity demand. *Applied energy*, Vol. 238, 2019, pp.1312-1326.
- [7] 한전 KDN, 인공지능 기술과 에너지 산업 혁신. 2020. // (Korea Electric Power Corporation Knowledge, Data & Network. *Artificial Intelligence Technology and Energy Industry Innovation*. 2020.)
- [8] 정보통신기술진흥센터, 4차 산업혁명을 선도하는 주요 기술대상 - 기술수준평가 및 기술수준 향상방안-. 2018. // (Institute of Information and Communications Technology Planning and Evaluation, In the era of the Fourth Industrial Revolution, the current state of artificial intelligence in Korea. 2018.)
- [9] A.L. Samuel, Some Studies in Machine Learning Using the Game of Checkers. *IBM Journal of Research and Development*, Vol. 44, 1959, pp.206-226.
- [10] T.S. Dutta, What Is The Difference Between AI, ML And Deep Learning? 2019. Available online: https://techviral.net/difference-between-ai-ml-deep-learning/#What_Is_The_Difference_Between_AI_ML_And_Deep_Learning
- [11] 강인성, 문진우, 박진철, 최근 건축분야의 인공지능 기계학습 연구동향. *대한건축학회 논문집*, 제33권 제4호, 2017, pp.63-68. // (I.S. Kang, J.W. Moon, J.C. Park, Recent Research Trends of Artificial Intelligent Machine Learning in Architectural Field - Review of Domestic and International Journal Papers -, *Journal of the Architectural Institute of Korea*, 33(4), 2017, pp.63-68.)
- [12] B. Seo et al., ANN-based thermal load prediction approach for advanced controls in building energy systems. In *ARCC Conference Repository*. Toronto. Canada. May. 2019.
- [13] S. Bouktif et al., Multi-sequence LSTM-RNN deep learning and metaheuristics for electric load forecasting. *Energies*. 13(2), 2020, p.391.
- [14] K. O'Shea, R. Nash, An introduction to convolutional neural networks. *CoRR*, abs/1511.08458. 2015.
- [15] C. Olah, Understanding LSTM Networks. 2015. Available online: <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>
- [16] M. Venkatchalam, Recurrent Neural Networks. 2019. Available online: <https://towardsdatascience.com/recurrent-neural-networks-d4642c9bc7ce>
- [17] L.J. Lee, A study on fundamental and application of CNN and RNN. *Broadcasting and media magazine*, 22(1), 2017, pp.87-95.
- [18] A. Mittal, Understanding RNN and LSTM. 2019. Available online: <https://towardsdatascience.com/understanding-rnn-and-lstm-f7cdff6dfc14e>
- [19] N. Somu et al., A Hybrid Model for Building Energy Consumption Forecasting Using Long Short Term Memory Networks. *Applied Energy*, Vol. 261, 2020, p.114131.
- [20] S. Hochreiter and K. Ramamritha, Long Short Term Memory. *Neural Computation*, Vol. 9. No. 8. 1997, pp.1735-1780.
- [21] Z. Li et al., An ANN-based fast building energy consumption prediction method for complex architectural form at the early design stage. In *Building Simulation*, Vol. 12. No. 4. 2019, pp.665-681.
- [22] J. Reynolds et al., A zone-level, building energy optimization combining an artificial neural network, a genetic algorithm, and model predictive control. *Energy*, Vol. 151. 2018, pp.729-739.
- [23] H. Gaballa, S. Cho, Prediction of hourly solar radiation using temperature and humidity for real-time building energy simulation. In *Journal of Physics: Conference Series*, 1343(1), 2019, p.012049.
- [24] Z. Deng, Q. Chen, Artificial neural network models using thermal sensations and occupants' behavior for predicting thermal comfort. *Energy and Buildings*, Vol. 174. 2018, pp.587-602.
- [25] N. Kocyigit, Fault and sensor error diagnostic strategies for a vapor compression refrigeration system by using fuzzy inference systems and artificial neural network. *International Journal of Refrigeration*, Vol. 50, 2015, pp.69-79.
- [26] Q. Huang K. Hao, Development of CNN-based visual recognition air conditioner for smart buildings. *Journal of Information Technology in Construction (ITcon)*, 25(21), 2020, pp.361-373.
- [27] J. Loy-Benitez, S. Heo, C. Yoo, Imputing missing indoor air quality data via variational convolutional autoencoders: Implications for ventilation management of subway metro systems. *Building and Environment*, Vol. 182, 2020, p.107135.
- [28] A. Streltsov et al., Estimating residential building energy consumption using overhead imagery. *Applied Energy*, Vol. 280, 2020, p.116018.
- [29] K. Weng, M. Mourshed, RNN-based forecasting of indoor temperature in a naturally ventilated residential building. *Building Simulation 2019. IBPSA*. 2019.
- [30] A. Javed et al., Comparison of the robustness of RNN, MPC and ANN controller for residential heating system. In *2014 IEEE Fourth International Conference on Big Data and Cloud Computing*. 2014. pp.604-611.
- [31] L. Wen, K. Zhou, S. Yang, Load demand forecasting of residential buildings using a deep learning model. *Electric Power Systems Research*, Vol. 179, 2020, p.106073
- [32] V.J. Mawson, B.R. Hughes, Deep learning techniques for energy forecasting and condition monitoring in the manufacturing sector. *Energy and Buildings*, Vol. 217, 2020, p.109966.
- [33] F. Mitebaa et al., LSTM-based indoor air temperature prediction framework for HVAC systems in smart buildings. *Neural Computing and Applications*. 2020. pp.1-17.
- [34] B. Qolomany et al., Role of deep LSTM neural networks and Wi-Fi networks in support of occupancy prediction in smart buildings. In *2017 IEEE 19th International Conference on High Performance Computing and Communications; IEEE 15th International Conference on Smart City; IEEE 3rd International Conference on Data Science and Systems*. Bangkok. Thailand. December. 2017. pp.50-57.
- [35] C. Xu et al., Improving prediction performance for indoor temperature in public buildings based on a novel deep learning method. *Building and Environment*, Vol. 148, 2019, pp.128-135.
- [36] M. Abdel-Nasser, K. Mahmoud, Accurate photovoltaic power forecasting models using deep LSTM-RNN. *Neural Computing and Applications*, 31(7), 2019, pp.2727-2740.
- [37] A. Heidari, D. Khovalyg, Short-term energy use prediction of solar-assisted water heating system: Application case of combined attention-based LSTM and time-series decomposition. *Solar Energy*, Vol. 207, 2020, pp.626-639.
- [38] T.Y. Kim, S.B. Cho, Predicting residential energy consumption using CNN-LSTM neural networks. *Energy*, Vol. 182, 2019, pp.72-81.