

건물 에너지 관리를 위한 시공간 예측 모델의 적용 가능성에 관한 연구

진현석¹, 김경백²

¹전남대학교 인공지능융합학과 석사과정

²전남대학교 인공지능융합학과 교수

ggyo003@jnu.ac.kr, kyungbaekkim@jnu.ac.kr

A Study on the Applicability of Spatiotemporal Prediction Model for Building Energy Management

Hyeonseok Jin, Kyungbaek Kim

Dept. of Artificial Intelligence Convergence, Chonnam National University

요 약

최근 에너지 소비량의 상승과 함께 효율적으로 에너지를 관리하는 것에 대한 중요성이 높아지고 있다. 이러한 관점에서 볼 때, 전 세계 에너지 소비량의 약 40%를 차지하는 건물 에너지의 수요와 공급을 예측하는 것은 매우 중요한 과제이며 딥러닝 모델을 기반으로 에너지 소비량을 예측하는 연구가 수행되고 있다. 그러나 기존 예측 모델은 여러 구역의 에너지 소비량을 예측하기 위해 필요한 시공간 상관 관계를 온전히 포착하기 어렵거나 에너지 사용량에 영향을 미치는 요인들을 활용하기 위해 복잡한 구조를 활용해야 한다는 한계가 있다. 본 논문에서는 이러한 한계를 극복하기 위해 데이터를 비디오 데이터 형식으로 변환하고 시공간 예측 모델을 사용하여 건물 에너지 예측을 수행하고, 비교 실험을 통해 적용 가능성에 대해 검토하고 가능성을 제시한다.

1. 서론

최근 에너지 소비량의 상승으로 인해 정부 및 지자체에서 관련 규정 및 정책을 신설하는 등 효율적으로 에너지를 관리하는 것에 대한 중요성이 높아지고 있다. 이러한 관점에서 볼 때, 전 세계 에너지 소비량의 약 40%를 차지하는 건물 에너지 [1]의 수요와 공급을 예측하고 이를 바탕으로 소비 전략을 수립하는 것은 매우 중요한 과제이며, 딥러닝 모델을 기반으로 에너지 소비량을 예측하는 연구가 수행되고 있다. 보다 정확한 건물 에너지 예측을 위해 시공간 상관관계를 포착하는 것은 매우 중요하나, 시계열 데이터만을 활용하는 기존 예측 모델은 정확한 예측을 위해 필요한 시공간 상관관계를 온전히 포착하기 어렵거나 [2] 온도, 습도 등 에너지 사용량에 영향을 미치는 요인들을 활용하기 위해 복잡한 구조의 아키텍처를 활용한다는 한계가 존재한다.

본 논문에서는 이러한 한계를 극복하기 위해 CU-BEMS 데이터 세트 [3]를 비디오 데이터 형식으로 변환하고, 시공간 예측 모델을 사용하여 건물 에너지 예측을 수행한다. 또한 기존 예측 모델과의 비교 실험을 통해 유효성을 확인하고, 적용 가능성에 대한 검토 및 향후 적용 가능성을 제시한다.

2. 관련 연구

시계열 데이터를 기반으로 건물 에너지 예측을 수행할 때 이전 시점의 정보와 현재 시점의 정보를 순차적으로 전달하며 학습을 진행하는 LSTM, GRU, Bi-LSTM과 같은 Recurrent Neural Network(RNN) 계열 딥러닝 모델이 주로 사용된다 [4]. RNN 계열 딥러닝 모델은 순차적인 특징으로 인해 시계열 특징을 잘 학습할 수 있지만, 병렬화가 어려워 온전히 학습하는데 시간이 오래 걸린다는 한계가 존재한다.

RNN과 더불어 보다 효율적인 예측을 수행하기 위해 Convolutional Neural Network(CNN)를 기반으로 Temporal Convolutional Network(TCN) [5]가 제안되었다. TCN은 병렬 처리가 용이하고 필터 크기나 간격을 늘리는 방식으로 유연한 확장이 가능하다는 장점이 있으며, 건물 에너지 예측 [6], 이상 탐지 [7] 등 다양한 분야에 활용되고 있다.

최근에는 건물 에너지 예측의 성능을 향상시키기 위해 Graph Convolutional Network(GCN)과 LSTM을 결합하여 여러 구역이 포함된 건물의 시공간 상관관계를 포착하는 연구가 제안되었다 [2]. 그러나 기존 건물 에너지 예측 연구들은 시계열 데이터를

기반으로 하여 시공간 상관관계를 포착하기 어렵거나, 다양한 요인을 반영하기 위해 복잡한 아키텍처를 활용한다는 한계가 존재한다.

3. 데이터 변환

본 논문에서 제안한 간단한 구조의 시공간 예측 모델의 유효성을 확인하고 적용 가능성에 대한 검토를 수행하기 위해, 시계열 데이터와 다양한 요인들을 Algorithm 1을 사용하여 하나의 비디오 형식 데이터로 변환하여 시공간 예측 모델의 입력으로 활용할 수 있도록 하였으며, 그림 1과 같이 시계열 기반 모델과의 비교를 위해 시공간 예측 모델의 출력에 Pooling 레이어를 추가하여 시계열 예측 값을 반환할 수 있도록 하였다.

Algorithm 1 Data Transform process

Input: time series data $x=\{x_1, \dots, x_t\} \in R^{B \times T \times N}$

Output: video format data $\hat{x}=\{\hat{x}_1, \dots, \hat{x}_t\} \in R^{B \times T \times H \times W \times C}$

Phase 1: Mapping

arr ← empty array

n ← number of zones

for i = 1 to n **do**

arr[i] ← insert ith zone's multivariate value

end for

Phase 2: Concatenate

result_arr ← empty array

for i = 1 to n **do**

if result_arr == empty **then**

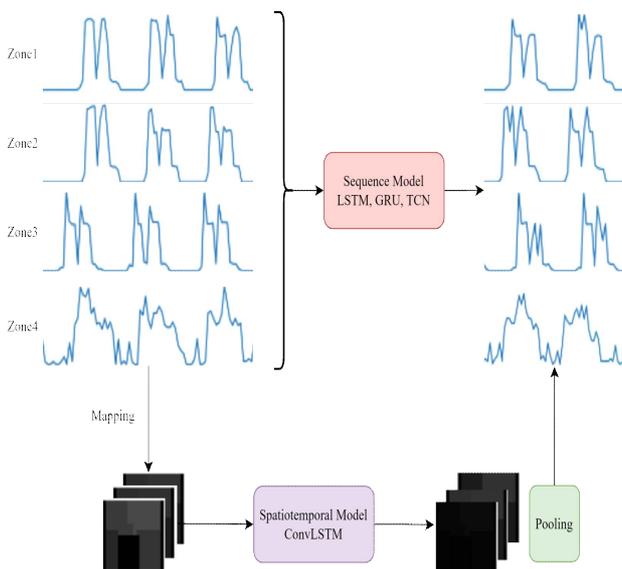
result_arr ← arr[i]

else

result_arr ← CONCAT(result_arr, arr[i])

arr ← insert ith zone's multivariate value

end for



(그림 1) 실험 프로세스

4. 실험

4.1 환경 설정

실험은 Windows10 WSL, Intel(R) Core(TM) i7-10700 CPU @ 2.90GHz, RTX 3070, Python 3.11.8 및 Tensorflow 및 Keras 2.14.0 환경에서 AdamW optimizer, 학습률 0.0005, Mean Squared Error(MSE) 손실함수를 사용하여 50회 학습을 진행하고 예측 성능을 비교하였다.

4.2 측정 지표

건물 에너지 예측 성능을 비교하기 위해 시공간 예측 모델인 ConvLSTM [8], 시계열 기반 예측 모델 LSTM, GRU, TCN, Bi-LSTM을 대상으로 수식 1, 수식 2를 사용하였다. 특정 시간대의 오차가 큰 경우를 반영하기 위해 오차에 제곱을 취하고 평균을 구하는 MSE와 직관적인 해석의 용이성을 위해 오차에 절댓값을 취하고 평균을 구하는 Mean Absolute Error(MAE)를 측정 지표로 사용하였다.

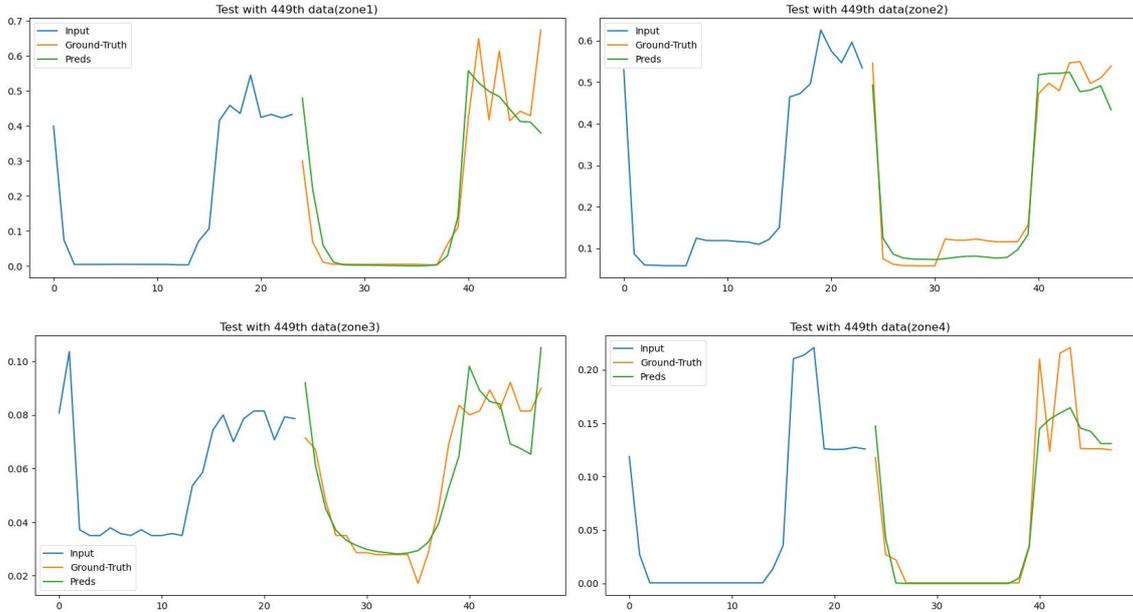
$$MSE = \frac{1}{n} \sum_{i=1}^n (y - \hat{y})^2 \quad (1)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y - \hat{y}| \quad (2)$$

4.3 데이터 세트

건물 에너지 예측 비교 실험을 위해 CU-BEMS 데이터 세트 [3]를 사용하였다. 4개의 공간이 포함된 2개층과 5개의 공간이 포함된 5개층에 대해 2018년 7월부터 2019년 12월 까지 분 단위로 전력 사용량 및 이에 영향을 미치는 온도, 습도 및 밝기 등의 다양한 요인 데이터가 측정되어 있으며, 실험에는 4개 공간을 포함하고 있는 2층 데이터를 활용하였다.

결측치의 영향을 최소화하고 모든 요인 데이터를 활용하기 위해, 결측치 비율이 가장 낮으면서도 공간별로 모든 요인 데이터를 포함하고 있는 2019년 동안의 2층 데이터를 활용하였다. 선형 보간을 사용하여 결측치를 대체하였으며, 연산 효율성 및 24시간 단위로 특징을 포착할 수 있도록 시간 단위로 리샘플링 및 24시간 단위로 슬라이딩 윈도우를 적용하고 값의 범위를 0에서 1사이로 조정하는 Min-Max 정규화가 적용되었다. 전처리 이후 5,425건의 데이터를 8:2 비율로 분할하여 학습 및 검증에, 1,105건의 데이터를 테스트에 사용하였다.



(그림 2) 시공간 예측 결과

4.4 실험 결과

테스트 데이터에 대한 비교 실험 결과는 표 1과 같다. 시공간 예측 모델인 ConvLSTM은 가장 낮은 MSE 및 MAE를 달성하였으며, 시계열 기반 예측 모델인 LSTM, GRU, TCN, Bi-LSTM 대비 약 10% 뛰어난 예측 성능을 보여 제안한 방법의 유효성을 확인할 수 있었다. 또한 그림 2와 같이 실제 데이터와 유사한 예측을 수행할 수 있음을 확인할 수 있었다.

<표 1> CU-BEMS 테스트 결과

models	MSE	MAE
LSTM	0.012	0.061
GRU	0.012	0.058
TCN	0.023	0.085
Bi-LSTM	0.011	0.059
ConvLSTM	0.010	0.057

5. 결론

본 논문에서는 건물 에너지 예측을 수행할 때, 간단한 방법으로 시공간 상관관계 포착이 가능한지 적용 가능성에 대한 검토를 수행하고자 시계열 데이터와 이에 영향을 미칠 수 있는 요인들을 하나의 비디오 형식 데이터로 변환하고 비교 실험을 수행하였다. 실험 결과, 시공간 예측 모델인 ConvLSTM은 기존 시계열 기반 예측 모델보다 뛰어난 예측 성능을 보였으며, 향후 구조를 확장하여 건물 에너지 예측을 보다 잘 수행할 수 있을 것으로 기대된다.

그러나 시공간 예측 모델은 보다 고차원의 데이터를 처리하기에 연산 비용이 높고, 학습에 시간이 오래 걸린다는 한계가 존재한다. 향후 연구에서는 이러한 한계를 극복하기 위해 시공간 예측 모델 구조를 고도화하여 효율성을 높이고, 보다 장기간의 데이터를 처리할 수 있도록 하여 예측 성능을 높이는 연구를 수행하고자 한다.

사사문구

이 논문은 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 지역지능화 혁신인재양성사업임(IITP-2024-RS-2022-00156287, 50%).

본 연구는 과학기술정보통신부 및 정보통신기획평가원의 인공지능융합혁신인재양성사업 연구 결과로 수행되었음(IITP-2023-RS-2023-00256629, 50%)

참고문헌

[1] Sülo, Idil, et al. "Energy efficient smart buildings: LSTM neural networks for time series prediction." 2019 International conference on deep learning and machine learning in emerging applications (Deep-ML). IEEE, 2019.

[2] Wang, Xiwen, et al. "Distributed LSTM-GCN-Based Spatial - Temporal Indoor Temperature Prediction in Multizone Buildings." IEEE Transactions on Industrial Informatics 20.1 (2023): 482-491.

- [3] Pipattanasomporn, Manisa, et al. "CU-BEMS, smart building electricity consumption and indoor environmental sensor datasets." *Scientific Data* 7.1 (2020): 241.
- [4] Wang, Xin, et al. "LSTM-based short-term load forecasting for building electricity consumption." *2019 IEEE 28th international symposium on industrial electronics (ISIE)*. IEEE, 2019.
- [5] Bai, Shaojie, J. Zico Kolter, and Vladlen Koltun. "An empirical evaluation of generic convolutional and recurrent networks for sequence modeling." *arXiv preprint arXiv:1803.01271* (2018).
- [6] Lara-Benítez, Pedro, et al. "Temporal convolutional networks applied to energy-related time series forecasting." *applied sciences* 10.7 (2020): 2322.
- [7] 진현석, and 김경백. "이상 전력 탐지를 위한 TCN-USAD." *스마트미디어저널* 13.7 (2024): 9-17.
- [8] Shi, Xingjian, et al. "Convolutional LSTM network: A machine learning approach for precipitation nowcasting." *Advances in neural information processing systems* 28 (2015).