

# 수업 일정을 고려한 대학건물의 부하 예측

홍민영, 이대성, 손성용\*

가천대학교

[ghdalsdud000@gachon.ac.kr](mailto:ghdalsdud000@gachon.ac.kr), [leeds96@gachon.ac.kr](mailto:leeds96@gachon.ac.kr), [xtra@gachon.ac.kr](mailto:xtra@gachon.ac.kr)

## Load forecasting of university building considering lecture schedules

Min-Young Hong, Dae-Sung Lee, Sung-Yong Son\*

Gachon University

### 요약

건물은 재실자, 건물 이용 일정 등의 요인에 의해 요일별로 상이한 부하 패턴이 나타나므로 부하 예측에 어려움이 존재한다. 본 연구에서는 대학건물 부하 예측의 성능 향상을 위하여 시간별 수업 수와 수업 인원을 고려한 예측모델을 제시하였다. 각 변수들의 조합으로 구성된 3개의 XGBoost 기반 부하 예측모델을 개발하고 각 모델의 예측 오차를 비교하였다.

### I. 서론

건물 부하 예측에는 일반적으로 기상요소가 이용되나, 다양한 예측요소를 추가하여 예측하였을 때 성능이 향상되는 결과를 보였다[1]. 건물의 부하는 기온, 일사량과 같은 환경적 요소 외에도 재실 상태와 건물 내 일정 등과 같은 내부 요인에 영향을 받으며[2], 대학건물의 부하와 수업 수 요인은 양의 상관 관계가 있음이 확인된 바 있다[3]. 따라서 본 논문에서는 대학건물 부하 예측의 정확도를 높이고자 시간별 수업 수, 수업 인원 데이터를 입력 특성으로 갖는 모델을 개발하고 비교하였다. 해당 연구는 경기도 성남시에 위치한 가천대학교 본관 건물 1개 층을 대상으로 수행되었다.

### II. 모델 구성

#### 2.1 부하 예측모델

본 논문에서는 부하, 수업 수, 수업 인원을 부하 예측모델의 입력변수로 사용하였다. 강의 일정 요인이 부하 예측의 성능에 영향을 주는지 확인하기 위해 총 3개의 모델을 개발하여 예측 성능을 비교하였다. 모델 성능을 비교하기 위해서 주로 사용되는  $R^2$ , MSE(Mean Squared Error), RMSE(Root Mean Squared Error), MAE(Mean Absolute Error) 4가지 지표를 사용하여 3개 모델의 성능을 비교하였다.

모든 예측모델은 기본적으로 과거 부하 데이터를 입력변수로 고려하였으며 Model 2는 과거 부하와 수업 수를 입력변수로 사용하였다. 마지막으로 Model 3은 과거 부하, 수업 수 및 수업 인원을 입력변수로 구성하였으며, 구성도는 그림 1과 같다.

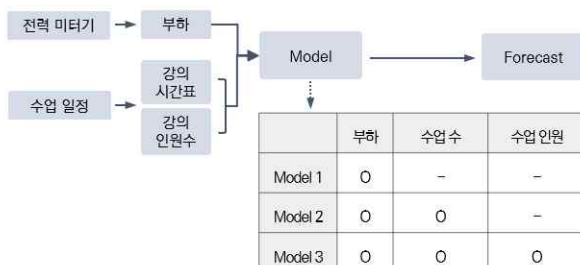


그림 1. 대학건물 부하 예측 구성도

#### 2.2 XGBoost 모델

XGBoost는 그라디언트 부스팅(Gradient Boosting) 프레임워크를 사용하는 트리(Tree) 기반의 앙상블 알고리즘이다. 부스팅(Boosting)이란 이전 분류 모델에서 얻은 정보를 이용하여 다음 분류 모델을 구성할 때 더 좋은 성능의 분류 모델을 생성하는 일련의 과정을 반복하여 최종적으로 더 높은 성능의 분류 모델을 생성하는 방식이다. 기존 부스팅 방식과 XGBoost의 큰 차이점은 파라미터로 지정한 최대 깊이(max\_depth)를 사용하여 모델 복잡도를 조절하고 노드의 과도한 분할을 제한하는 프루닝(Pruning)을 통해 과적합을 방지하는 특징이 존재한다.

### III. 사례연구

#### 3.1 데이터 수집 환경

사례연구를 위해 가천대학교 가천관 3층의 1학기 대면 수업 기간인 2022년 5월 12일에서 6월 13일까지의 부하 데이터를 수집하였다. 해당 층은 사회과학대 강의실과 교수실 용도로 사용되고 있다. 데이터는 15분 간격으로 수집되었으며, 추가 조사를 통하여 가천관 3층의 15분당 수업 수, 수업 인원 변수를 추가하였다. 수업은 동 시간대 최대 5개까지 진행되었으며, 수업 인원은 최소 25명에서 최대 275명이었다.

해당 데이터를 기반으로 예측 시점의 15분 이후의 부하 예측모델을 개발하였으며 6월 1일에서 11일 사이의 주말과 데이터 결측 기간을 제외한 5일간의 전력사용량을 예측하였다.

#### 3.2 모델 파라미터

표 1은 모델 구성 시 사용한 파라미터를 정리한 표이다. 학습기 수는 30개로 설정하여 30번의 반복 수행을 하도록 하였으며 빠른 학습속도를 위해 gpu\_hist 학습방식을 사용하였다. 트리에서 추가 분할을 결정하는 최소 손실 값 파라미터인 gamma를 0.01로 설정하였고 트리별 샘플링 비율은 1, 트리의 추가적인 분기의 최대 깊이를 결정하는 max\_depth를 5로 설정하여 과적합을 방지하였다. 학습률은 0.1로 설정하여 부스팅 시 각 이터레이션마다 0.1의 가중치가 곱해지도록 하였다. 손실 함수는 MAPE를 사용하였다.

표 1. 파라미터 설정

parameter	value
N_estimators	30
Learning_rate	0.1
gamma	0.01
Colsample_bytree	1
max_depth	5
eval_metric	MAPE
num_boost_round	20
tree_method	gpu_hist

### 3.3 부하 예측 결과

그림 2는 입력변수를 달리하여 구성한 3가지 모델의 예측 결과이다. 모델의 성능을 파악하기 위하여 실제 측정값과 예측값을 동일 그래프에 나타내었다. 파란색 실선이 모델을 통해 예측한 부하이며 회색 실선은 실제로 측정된 부하이다.




그림 2. 모델별 부하 예측 결과

모델 학습 시에 과거 부하 데이터만을 사용한 Model 1의 경우, 건물의 전반적인 일정이 시작되는 8시 이전의 부하는 실제보다 높게 예측되고 9시에서 20시 사이에는 낮게 예측되며 수업 관련 변수를 추가적으로 고려한 나머지 두 모델에 비해 낮은 성능을 보인다. 이에 비해 Model 2와 Model 3의 예측 결과를 확인하였을 때 공통적으로 높은 성능을 가지는 모습이 나타났다. 이를 통해 과거 부하 변수 외에 수업 관련 변수를 추가로 학습하였을 때 높은 성능을 갖는 예측모델을 생성할 수 있음이 확인되었으며, 과거 부하와 수업 수로 학습시킨 모델과 수업 인원을 추가적으로 학습시킨 모델 간의 유의미한 성능 차이는 나타나지 않았다. 표 2를 통해 3개 모델의 예측 성능 지표를 비교하였다.

표 2. 예측 성능 지표

성능 지표	Model 1	Model 2	Model 3
$R^2$	0.91	0.96	0.96
MAE	0.07	0.03	0.03
MSE	0.007	0.002	0.002
RMSE	0.08	0.05	0.05

과거 부하 변수만을 이용하여 예측을 진행한 Model 1의 경우  $R^2$  기준으로 0.91이 나오는 것을 확인할 수 있었다. Model 2와 Model 3의 경우에는 0.96가 나왔으며 이러한 결과는 수업 수와 수업 인원 등의 강의 일정을 고려한 예측모델의 성능이 5.5 % 개선되었음을 알 수 있었다.

또한  $R^2$  외에 MAE, MSE, RMSE를 통하여 성능을 비교하였을 때 강의 일정을 고려한 Model 2, Model 3 모델의 예측 오차는 각 0.03, 0.002, 0.05로 Model 1에 비해 0.04, 0.005, 0.03가 감소함을 확인할 수 있었다.

다만 Model 2와 Model 3의 성능 지표의 유의미한 차이가 없으므로 본 연구에서는 과거 부하와 수업 수를 입력변수로 사용한 Model 2가 가장 적절한 모델임을 알 수 있다.

## IV. 결론

본 연구에서는 강의 일정 요인이 예측 성능 향상에 기여하는 바를 확인하기 위해 과거 부하 변수에 추가적으로 수업 수와 수업 인원을 입력변수로 고려하여 예측모델을 개발하고 성능을 비교하였다. 해당 변수들을 고려하였을 때 예측 성능이 향상되는 것을 확인할 수 있었으나 Model 2와 Model 3간 예측 성능의 유의미한 차이가 나타나지 않았다.

해당 결과를 1년 이상의 기간동안 수집된 데이터에 적용하여 후속연구가 이루어질 수 있을 것으로 보인다.

## ACKNOWLEDGMENT

### 감사의 글

본 연구는 산업통상자원부(MOTIE)의 재원으로 한국에너지기술 평가원(KETEP)의 지원(No.20194310100060, No.20226210100100)을 받아 수행한 연구과제입니다.

## 참고 문헌

- [1] 박준호, 신동하, 김창복, 특수일 분리와 예측요소 확장을 이용한 전력수요 예측 딥 러닝 모델, Aug. 2017
- [2] Chaouki Ghenai et.al, Short-term building electrical load forecasting using adaptive neuro-fuzzy inference system (ANFIS), Journal of Building Engineering, pp. 3-4, July. 2022
- [3] 홍민영, 김미림, 박건준, 손성용, 시간표를 고려한 대학건물 전력부하 분석, 2022 추계 통신학회 학술대회, Oct. 2022