

AMI 데이터를 활용한 딥러닝 기반의 에너지 사용량 예측 모델

김동하*, 이한준**

Deep-learning based Predictive Model For Energy Consumption using AMI Data

Dong-Ha Kim*, Hanjun Lee**

요약

국내 에너지 사용량은 매년 증가하고 있으며 그중 큰 비중을 차지하는 산업 부문에 대한 효율적인 관리가 요구된다. 이를 위해서는 더욱 정교한 사용량 예측이 필요하다. 이에 본 연구에서는 AMI(Advanced Metering Infrastructure, 지능형 전력 계량 인프라) 데이터와 기상정보를 수집하고 XGBoost, LightGBM, LSTM 등 딥러닝 알고리즘을 기반으로 산업 부문의 전력 사용량 예측 모델을 구축하였다. 추가적으로 군집화를 통하여 전력 사용 패턴별 유형을 구분하고 각 군집별로 예측 모델을 학습시켰다. 결과적으로 LSTM 기반의 모델이 가장 우수한 성능을 보였으며 군집화를 통하여 모델의 정확도가 향상되는 것을 확인할 수 있었다. 또한 SHAP를 활용한 변수 중요도 분석을 통하여 업종과 온도, 근무자 수가 전력 사용량에 영향이 큰 요인임을 확인하였다.

Abstract

The domestic energy consumption is increasing every year, and the industrial sector, which accounts for a large share of it, needs to be managed efficiently. This requires more sophisticated usage forecasting. In this study, we collected AMI (Advanced Metering Infrastructure) data and weather information and built a power usage prediction model for the industrial sector based on deep learning algorithms such as XGBoost, LightGBM, and LSTM. Additionally, we differentiated types of power usage patterns through clustering and trained prediction models for each cluster. As a result, the LSTM-based model exhibited the best performance, and it was observed that clustering improved the model's accuracy. Furthermore, through variable importance analysis with SHAP values, we confirmed that industry, temperature and number of employees are significant factors influencing energy consumption.

Keywords

AMI, deep learning, electricity consumption, LSTM

* 명지대학교 경영정보학과 학사과정
- ORCID: <https://orcid.org/0009-0003-4864-5836>
** 명지대학교 경영정보학과 교수(교신저자)
- ORCID: <https://orcid.org/0000-0002-9005-3661>

• Received: Jul. 27, 2023, Revised: Aug. 22, 2023, Accepted: Aug. 25, 2023
• Corresponding Author: Hanjun Lee
Dept. of Management Information Systems, Myongji University, Korea
Tel.: +82-2-300-0772, Email: hjlee1609@mju.ac.kr

1. 서 론

4차 산업혁명 시대의 핵심 자원이라 할 수 있는 빅데이터와 인공지능 기술은 다양한 분야의 사물 지능화를 선도하고 있다. 차세대 지능형 전력망 인프라인 스마트 그리드도 그 대표적인 사례 중 하나이다. 스마트 그리드는 공급자와 사용자 상호간 실시간 정보 공유를 가능하게 하는 전력망으로서 스마트 그리드 구성의 필수 요소인 AMI(Advanced Metering Infrastructure)를 기반으로 양방향 소통이 가능하며, 이를 통하여 전력량을 조절할 수 있다는 점이 핵심이다. 스마트 그리드에서는 지능형 전력 계량 인프라를 통하여 대규모 전력 사용량 데이터가 1분, 3분, 5분 단위로 축적된다. 이렇게 축적된 데이터는 에너지 효율 제고와 최적화 및 관리 솔루션 개발등을 포함하여 다양한 목적으로 활용이 가능하다[1].

한편 경제 발전과 산업의 대규모화로 인하여 전력 사용량이 급증하고 있다. 하지만 전력 시스템의 생산 용량은 해마다 한계치에 다다르고 있어 이에 대한 해법이 요구되고 있다[2]. 선행연구에서는 AMI 데이터를 기반으로 전력사용량을 예측한 바 있다[3]-[7]. 그런데 이러한 연구들은 주로 가정 부문의 데이터를 분석하였으며 아직까지 산업 부문을 대상으로 수행된 연구는 흔치 않다. 2022년 에너지 경제연구원에서 발간한 통계연보에 따르면 대한민국은 1인당 전력소비량이 상위권에 속하며, 가정 부문 전력소비는 OECD 평균 이하인데 반해 산업 부문 전력소비는 주요선진국을 상회한다. 이에 본 연구에서는 AMI 데이터와 함께 업종과 각 일자별 온도 및 습도 등 기상 정보를 활용하여 산업 부문의 전력 사용량을 예측하는 딥러닝 기반 모델을 제안하고자 한다.

본 연구의 구성은 다음과 같다. 2장에서는 본 연구와 관련된 선행연구 사례들을 소개하고, 3장에서는 본 연구의 접근방법에 대하여 설명한다. 4장에서는 연구 결과를 설명하며, 5장에서 결론과 함께 시사점을 제시하고자 한다.

II. 선행연구

2.1 AMI 데이터를 활용한 선행연구

스마트 그리드는 전력 효율성 극대화와 자유로운 미래 에너지 공급을 위하여 전력 인프라를 개선시킬 수 있는 수단이다[1]. 스마트 그리드를 통해 공급자와 소비자가 양방향 소통으로 전력량을 조절함으로써 에너지를 효율적으로 사용할 수 있다. 스마트 그리드 구현을 위하여 필수 전제조건이 바로 AMI이다[2]. AMI는 양방향 소통이 가능한 스마트 미터를 제공하고, Interval data, TOU(Time-Of-Use) data 등 기존 계량기와는 다른 새로운 데이터를 제공할 수 있으며 서비스의 연결과 해제가 가능하다[8]. AMI 시스템의 핵심 장치인 데이터 집중 장치(DCU, Data Concentration Unit)로부터 각 수용가별 정보를 수집하여 상위 시스템에 전송하면 분석 및 처리 과정을 거쳐 전력 사용 정보를 소비자에게 제공할 수 있다[2]. 스마트 그리드 환경내에서 AMI를 통해 실시간으로 전력 사용 데이터가 축적되며 이렇게 생성된 빅데이터를 활용한 다양한 연구들이 진행되었다[3]-[7].

[3]의 연구에서는 AMI 데이터와 K-Means 알고리즘을 활용하여 군집별 전력 사용 패턴에 관하여 분석하였다. [4]의 연구에서는 [3]과 동일한 데이터를 기반으로 전력 사용량을 예측하는 딥러닝 기반의 모델을 제시하였다. [5]의 연구에서는 K-Means 알고리즘을 통한 전력 소비 패턴별 군집화 후 신경망 알고리즘을 기반으로 소비자에게 개별 가전기기의 사용량 정보를 예측하였다. [6]의 연구에서는 동적타임워핑, 주기도와 같은 시계열 군집법과 함께 Seasonal ARIMA(Autoregressive Integrated Moving Average), TBATS(Trigonometric, Box-Cox transform, ARMA errors, Trend and Seasonal components) 모델, 신경망 모델을 기반으로 전력 사용량을 예측하였다. 이상의 선행연구에서는 스마트 그리드 환경하에서 발생하는 AMI 데이터와 머신러닝 및 딥러닝 모델 등을 통하여 전력 사용량을 예측하였다는 점과 가정 부문의 전력 사용을 분석하였다는 점에서 유사성을 갖는다.

한편, AMI 데이터를 기반으로 산업 부문 전력 사용을 분석한 선행연구는 아직까지 희소하다. [7]의 연구에서는 상업 시설들의 실시간 영업여부를 예측하는 모델을 제시하였으며 이를 위하여 준지도 학습법과 CNN(Convolutional Neural Network) 알고리즘을 활용하였다.

상기 연구에서는 AMI 데이터를 활용하여 산업 부문을 분석하였으나 실제 전력 사용량이 아니라 영업 여부를 예측하는 것에 초점을 두었다. 이에 본 연구에서는 AMI 데이터를 활용하여, 아직까지 관련 연구가 충분치 못한 산업 부문에서의 전력 사용량을 예측하는 모델을 제안하고자 한다.

2.2 딥러닝 기반의 전력 예측

본 연구에서는 XGBoost와 LightGBM, LSTM과 같은 딥러닝 계열의 모델들을 분석에 활용하고자 한다. 각 모델에 대한 설명은 다음과 같다.

먼저 XGBoost는 트리 기반의 부스팅 모델로서 GBM(Gradient Boosting Machine)모델에서 병렬처리, 하드웨어 최적화 등의 개념을 도입하여 최적화된 모델이다[9]. XGBoost의 경우 하나의 결정 트리를 학습할 때 모든 임계값을 기준으로 분할하는 것이 아니라 데이터셋을 수많은 서브 데이터로 분할한 뒤 서브 데이터 내에서 최적값을 찾는 모델이다. 기존의 일반적인 의사결정 나무나 랜덤 포레스트 보다 GBM 기법을 통하여 나무가 성장하기에 학습 정확도 및 희소한(Sparse) 데이터에도 과적합을 방지할 수 있는 점이 장점이다.

LightGBM의 경우 XGBoost의 단점을 보완하는 방식으로 개발된 모델로서 GOSS(Gradient-based One-Side Sampling)를 통하여 데이터의 일부만으로 빠르게 정보 이득을 계산할 수 있으며 EFB(Exclusive Feature Bundling)를 통하여 feature의 수를 줄일 수 있다[10]. LightGBM은 이와 같은 방법을 이용하여 XGBoost 대비 학습 소요 시간을 줄

이는 GBM 기반 모델이다.

LSTM(Long Short Term Memory)은 기존 Simple RNN의 Long Term Dependency를 해결하기 위하여 고안된 모델이다[11]. Cell-state를 통하여 이전 타임 스텝의 hidden state를 계속 전달하며 Forget gate를 통하여 이전 Cell state에서의 정보를 기억할지 결정한다. Input gate를 통하여 현재의 정보를 cell state로 더해주며 Output gate를 통하여 최종 output을 계산하는 모델이다. 전력 사용량 예측 분야 선행연구에서 LSTM을 사용하여 모델을 제안한 바 있다 [12][13]. 본 연구에서는 상기 모델을 각각 활용하여 예측 모델을 구축하고 가장 성능이 우수한 모델을 최종적으로 제시하고자 한다.

III. 연구 방법

3.1 연구 절차

본 연구의 개략적인 진행 절차는 그림 1에서 보는 바와 같다. 우선, 통신 빅데이터 플랫폼(<https://bdp.kt.co.kr/>)에서 제공하는 업종별 전력 사용량 정보를 통해 데이터를 구성한다. 그리고 데이터 전처리를 수행한 뒤 학습을 위하여 데이터를 분할한다. 그 후 세 종류의 딥러닝 모델을 통하여 학습을 진행하고, 성능을 평가한다. 선행연구 사례에서 군집화를 사용하여 모델의 성능을 높인 것처럼 본 연구에서도 군집화를 수행하고 각 군집별로 모델링 후 군집 전 구축한 모델과의 비교를 통하여 최종 모델을 제시한다.

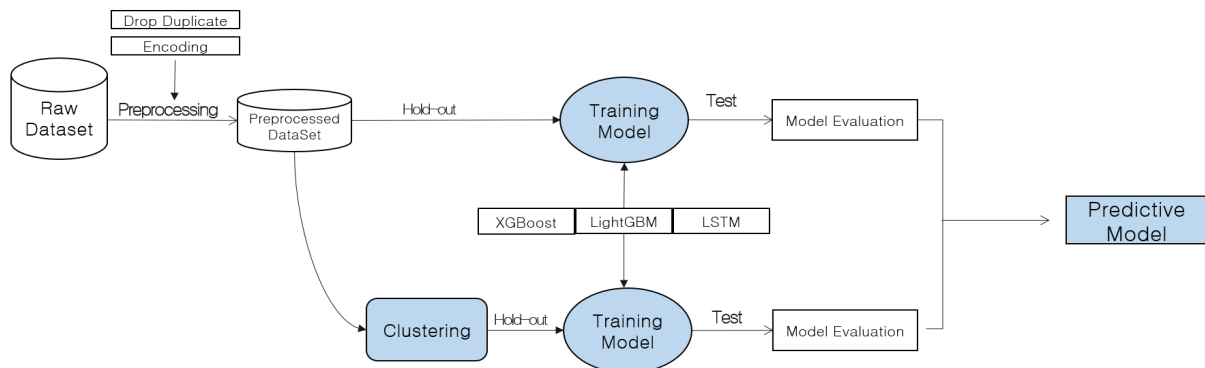


그림 1. 연구 흐름도

Fig. 1. Research procedure

3.2 데이터 수집과 데이터셋 구성

본 연구에서 학습에 활용한 데이터는 AMI 데이터로서 2018년부터 2021년까지의 AMI를 통해 측정된 전력 사용량 데이터이다. KT社에서 운영하는 통신 빅데이터 플랫폼에서 해당 데이터에 대한 접근이 가능하다. 본 연구에서는 특별·광역시 중 전력 공급률이 높은 인천광역시를 분석 대상으로 선정하였다. 데이터 내의 변수에는 측정일(Measurement date), 측정 시각(Measurement time), 업종명(Industry name), 업무 시간(Actual working hours), 상주 근무자 수(Number of resident workers) 등 업종 관련 정보와 함께 온도(Temperature value), 습도(Humidity value) 등 기상정보 및 종속변수인 전력 사용량(SG electricity usage value)을 포함한다. 업종 변수는 제조업(Manufacturing) 등 총 13가지 중 하나의 값을 가진다. 그중 제조업의 경우 전체 데이터의 약 45%를 차지하고 있으며 도매 및 소매업(Wholesale & Retail)의 경우 약 10%를 차지하고 있다. 추가적으로 측정일을 근거로 계절 변수를 생성하였고 온도와 습도 값을 활용해 불쾌지수(Discomfort index)라는 변수를 추가로 생성하여 분석에 활용하였다. 파생변수 생성 및 결측치와 중복제거 등 전처리를 완료한 데이터셋 예시는 그림 2에서 보는 바와 같다.

본 연구에서는 전력 사용량 예측을 위한 회귀모델을 제안한다. 이를 위해 앞서 준비한 데이터셋에서 먼저 중복 데이터와 결측치 제거, Label Encoding 등 전처리 작업을 수행하였다. 전체 데이터 세트는 총 833,450개이며, 학습용과 검증용 및 테스트용 데이터를 각각 6:2:2로 분할하여 모델 구축을 진행하였다.

Measurement date	Measurement time	Day of the week	Public holiday status	Industry name	Number of resident workers	Temperature value	Humidity value	Season	Actual working hours	Discomfort index	SG electricity usage value
20180401	0	Sunday	Y	Accommodation & Food	2	10.8	73.0	Spring	10.0	low	1.742
20180401	1	Sunday	Y	Accommodation & Food	2	11.4	73.0	Spring	10.0	low	1.381
20180401	2	Sunday	Y	Accommodation & Food	2	11.5	68.0	Spring	10.0	low	1.585
20180401	3	Sunday	Y	Accommodation & Food	2	11.9	65.0	Spring	10.0	low	1.687
20180401	4	Sunday	Y	Accommodation & Food	2	12.1	64.0	Spring	10.0	low	1.209

그림 2. 데이터셋 예시

Fig. 2. Dataset samples

3.3 예측 모델 구축

본 연구에서는 XGBoost, LightGBM 및 LSTM을 사용하여 모델을 훈련하였으며 모델별로 하이퍼파라미터 튜닝을 하였다. 먼저 XGBoost와 LightGBM은 HyperOpt 라이브러리를 활용하였는데 XGBoost의 max_depth는 9, n_estimators는 876, subsample은 0.99, learning_rate는 0.017로 설정하였고 LightGBM의 max_depth는 10, n_estimators는 874, subsample은 0.68, learning_rate는 0.26으로 설정하였다. LSTM은 총 9개의 레이어로 모델을 구축하였으며, 총 파라미터의 개수는 2,868,737개이다. LSTM층에는 BiLSTM을 적용하여 예측의 정확도를 향상시켰으며 각 LSTM층별 LayerNormalization을 적용하여 모델의 안정성을 향상시켰다. 각 밀집층 사이에는 Dropout을 적용하여 과적합을 방지하였으며 초기 학습률은 $1e-3$ 이고 Adam 옵티마이저를 사용하여 학습하였다. 학습률 스케줄러의 경우 Reduce On Plateau 스케줄러를 통하여 학습의 정확도를 높였다.

IV. 연구 결과

4.1 성능 평가

모델 성능에 대한 평가지표는 오차의 절대값의 평균인 MAE(Mean Absolute Error), 오차의 제곱의 평균의 제곱근인 RMSE(Root Mean Square Error), 그리고 MAE의 백분율인 MAPE(Mean Average Percent Error)를 사용하였다.

세 지표 모두 0에 가까울수록 모형의 성능이 좋은 것으로 해석할 수 있다. 본 논문에서 구축한 세 가지 모형의 성능은 각각 표 1에서 보는 바와 같다. 모형 간의 차이가 크지는 않았으나 세 지표 기준 LSTM 기반의 예측 모형이 타모형 대비 오차가 적었다. 백분율을 기반으로 하기 때문에 해석하기 용이한 MAPE 값을 근거로 할 때 본 논문에서 제안한 LSTM 모형의 예측값과 실제 전력사용량이 16% 정도 차이난다고 볼 수 있다.

표 1. 모델 간 성능 비교

Table 1. Performance comparison among the models

Model	MAE	RMSE	MAPE
XGB	1.2002	2.5876	17.18
LGBM	1.2384	2.6590	18.16
LSTM	1.1140	2.5651	16.24

4.2 특성 중요도

본 연구에서는 가장 우수한 성능을 보인 LSTM 모형에서 변수들의 중요도를 비교분석하기 위하여 SHAP(SHapley Additive exPlanation)을 활용하였다. SHAP은 개별 예측값에 대한 각 변수들의 영향력을 Shapley Value를 통하여 나타내는 방법으로서 모형의 해석과 설명에 활용된다[14]. SHAP 분석 결과는 그림 3에서 보는 바와 같다. X축은 Shapley Value 값으로서 절대값이 클수록, 다시 말해 특정 변수의 Shapley Value 분포 범위가 넓을수록 목표변수에 대한 영향력이 크다는 것으로 해석할 수 있다. 그리고 색상은 빨간 색에 가까울수록 해당 변수의 값이 크고 파란 색에 가까울수록 작은 것을 의미하는데 특정변수의 색상 구분이 선명할수록 예측에 유용한 변수라 볼 수 있다. 그림 3에 따르면 온도(Temperature value)와 습도(Humidity value) 등 기상 조건, 그리고 상주 근무자수(Number of resident workers)가 전력 사용량에 영향력이 큰 중요 변수들로 나타났다. 특히 상주 근무자 수의 경우 값이 높을수록 전력 사용량에 영향을 많이 미치는 것을 확인할 수 있다. 온도의 경우 값이 높을수록 전력 사용량이 많은 것을 확인할 수 있으며 습도는 값이 낮을수록 전력사용량에 영향을 많이 미치는 것을 확인할 수 있다.

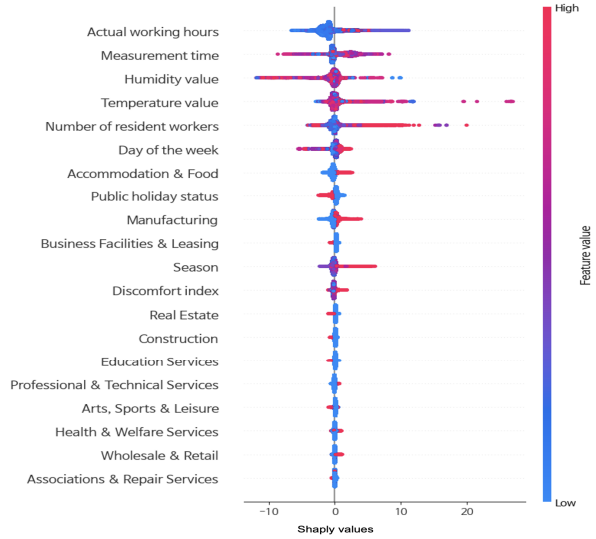


그림 3. 변수들의 SHAP value
Fig. 3. SHAP value of the features

업종과 관련된 변수들을 살펴보면 숙박 및 음식점업(Accommodation & food)과 제조업(Manufacturing)이 전력 사용량에 가장 큰 영향을 미치는 것을 확인할 수 있었다. 반면 그 외 업종의 경우 전력사용량에 대한 영향은 상대적으로 적은 것을 확인하였다.

4.3 군집화 결과

선행연구들의 사례를 참고하여 본 연구에서도 군집화를 수행하였다. K-Means 알고리즘을 활용하여 종속변수인 전력 사용량을 제외한 독립변수들로 군집을 구성하였다. 군집의 적정수는 실루엣 계수값으로 판단하였다. 군집 결과에 대하여 t-SNE를 통해 차원축소한 결과를 시각화하면 그림 4와 같다.




그림 4. 데이터 군집 시각화
Fig. 4. Data cluster visualization

4.4 군집화 후 모델 평가

군집화 후 모델의 성능 변화를 측정하였다. 각 군집별로 MAE, RMSE, MAPE 값을 구한 결과는 표 2에서 보는 바와 같다. 군집화 후 모델의 성능이 대체로 개선된 것을 확인할 수 있으며 세 가지 평가 지표를 근거로 모든 군집군에서 LSTM기반 예측 모델의 오차가 가장 적은 것으로 나타났다. 특히 0번과 1번 군집보다 2번 군집에서 모든 모델의 오차가 대폭 감소한 것을 확인할 수 있었다. 이에 각 군집에 포함된 데이터를 살펴본 결과 2번 군집에 포함된 업종은 모두 보건업 및 사회복지 서비스업으로 한정되어 있었다. 이 업종들은 전반적으로 전력 사용량이 적어 다른 군집에 비해 특히 성능 개선의 폭이 큰 것에 영향을 끼친 것으로 판단된다.

표 2. 군집화 후 모델 간 성능 비교

Table 2. Performance comparison among the clustered models

Cluster	Model	MAE	RMSE	MAPE
0	XGB	1.0263	2.2560	18.22
	LGBM	1.0515	2.3144	18.97
	LSTM	0.9709	2.3052	16.87
1	XGB	1.4105	2.9482	16.17
	LGBM	1.4587	3.0226	16.85
	LSTM	1.3429	2.9885	14.84
2	XGB	0.1319	0.1745	0.9421
	LGBM	0.1352	0.1726	0.9515
	LSTM	0.1173	0.1524	0.7851

V. 결론 및 시사점

에너지 사용량에 대한 정확도 높은 예측은 에너지의 효율적 관리를 위해 매우 중요한 과제이다. 이에 본 연구에서는 AMI 데이터 및 일별 기상정보 등을 활용하여 딥러닝 기반의 전력 사용량 예측 모델을 제안하였다. 그리고 SHAP 분석을 통하여 전력 사용량 예측에 영향을 미치는 중요 변수를 식별하였다. 이를 통하여 기상조건이나 상주 근무자수 등의 변수 뿐 아니라 제조업이나 및 숙박 및 음식 점업과 같은 업종의 구분이 전력량 예측 모델 구축 시 모델의 성능에 영향을 미치는 유의미한 변수임

을 확인하였다. 또한, 군집화를 통하여 전력 사용자들의 유형에 따른 예측 모델을 구축함으로써 모델의 성능을 제고시킬 수 있었다. 본 연구에서는 그동안 가정 부문 대비 관련 연구가 부족했던 산업 부문의 전력사용과 관련하여 실데이터와 최신 딥러닝 모델에 기반하여 정확도 높은 예측 모델을 제안하였다는 점에서 의미를 갖는다.

아울러 본 연구의 제한점은 다음과 같다. 현재 제공되는 데이터가 인천 외 강원도, 부산 등의 특정 지역에 한정되어 있다. 본 연구에서는 전력 자급율이 가장 높은 인천을 분석의 대상으로 선택하였으나 향후 전국을 대상으로하는 데이터가 확보된다면 보다 일반화가 용이한 분석 결과를 얻을 수 있을 것으로 보여진다. 또한 데이터 수집 과정에서 결측치와 중복 및 누락 데이터를 다수 발견하였다. 원천 데이터의 품질은 분석 결과의 신뢰성에 직결되므로 데이터 수집 단계에서부터 데이터에 오류가 없도록 관리할 필요가 있다.

References

- [1] S. M. Jeong and H. Lee, "A Consideration on the value evaluation of AMI data as big data", KIEE Summer Conference, pp. 45-46, Jul. 2014.
- [2] J. M. Ko, J. J. Song, Y. I. Kim, N. J. Jung, and S. K. Kim, "A development of demand response operation system and real-time pricing based on smart grid", The transactions of the Korean Institute of Electrical Engineers, Vol. 59, pp. 1964-1970, Nov. 2010.
- [3] N. Yoo, E. Lee, B. J. Chung, and D. S. Kim, "Analysis of apartment AMI data and analysis of apartment AMI data and power consumption using K-Means algorithm", Summer Annual Conference of IEIE, pp. 506-508, Nov. 2019.
- [4] N. Yoo, E. Lee, B. J. Chung, and D. S. Kim, "Analysis of apartment power consumption and forecast of power consumption based on deep learning", Journal of IKEEE, Vol. 23, pp. 258-265, Dec. 2019. <https://doi.org/10.7471/ikeee.2019.23.4.1373>.

- [5] J. M. Kim, J. B. Jeon, and C. H. Lim, "Classification of home appliance electricity consumption using AMI data", KIEE Summer Conference, pp. 35-36, Nov. 2020.
- [6] J. Y. Lee, and S. Kim, "Time series clustering for AMI data in household smart grid", The Korean Journal of Applied Statistics, pp. 791-804, Dec. 2020.
- [7] I. Choi, M. Jang, and M. Choi, "Development of operations prediction system using AMI data and machine learning", KIEE Summer Conference, pp. 1662-1663, Jul. 2020.
- [8] D. G. Hart, "Using AMI to realize the smart grid", In 2008 IEEE Power and Energy Society General Meeting-Conversion and Delivery of Electrical Energy in the 21st Century, Pittsburgh, PA, USA, Vol. 10, Jul. 2008. <https://doi.org/10.1109/pes.2008.4596961>.
- [9] J. E. Engelen and H. H. Hoos, "A survey on semi-supervised learning", Machine learning, Vol. 109, No. 2, pp. 373-440, Nov. 2019. <https://doi.org/10.1007/s10994-019-05855-6>.
- [10] G. Ke, Q. Meng, T. Finley, T. Wang, W. Chen, W. Ma, Q. Ye, and T. Y. Liu, "LightGBM: a highly efficient gradient boosting decision tree", Advances in Neural Information Processing Systems, Vol. 30, pp. 3146-3154, Dec. 2017.
- [11] S. Hochreiter and J. Schmidhuber, "Long short term memory", Neural Computation, Vol. 9, No. 8, pp. 1735-1780, Nov. 1997. <https://doi.org/10.1162/neco.1997.9.8.1735>.
- [12] J. H. Lee, J. S. Kim, Y. H. Ahn, and W. S. Cho, "Daily forecasting of energy demand using SARIMA and LSTM method of support decision making on V2G", Journal of Korean Data and Information Science Society, Vol. 30, No. 4, pp. 779-795, Jul. 2019. <https://doi.org/10.7465/jkdi.2019.30.4.779>.
- [13] Y. J. Nam and H. H. Jo, "Prediction of weekly load using stacked bidirectional LSTM and stacked

unidirectional LSTM", The Journal of Korean Institute of Information Technology, Vol. 18, No. 9, pp. 9-17, Sep. 2020. <https://doi.org/10.14801/jkiit.2020.18.9.9>.

- [14] S. Lundberg and S.-I. Lee, "A Unified Approach to Interpreting Model Predictions", Advances in Neural Information Processing Systems, Vol. 30, pp. 4766-4775, Dec. 2017.

저자소개

김 동 하 (Dong-Ha Kim)



2018년 2월 ~ 현재 : 명지대학교
경영정보학과 학사과정
관심분야 : 머신러닝, 딥러닝,
자연어처리, 추천시스템

이 한 준 (Hanjun Lee)



2001년 2월 : 서울대학교
컴퓨터공학과(공학사)
2004년 2월 : 서울대학교
컴퓨터공학과(공학석사)
2016년 8월 : 고려대학교 경영학과
MIS 전공(경영학박사)
2007년 7월 ~ 2018년 2월 :
한국국방연구원 선임연구원
2018년 3월 ~ 2020년 2월 : 한남대학교 조교수
2020년 3월 ~ 현재 : 명지대학교 부교수
관심분야 : 머신러닝, 자연어 처리, 정보시스템, 정보화
정책