

CNN-LSTM 딥러닝 기반 캠퍼스 전력 예측 모델 최적화 단계 제시

김예인, 이세은, 권용성*
한동대학교 기계제어공학부

Proposal of a Step-by-Step Optimized Campus Power Forecast Model using CNN-LSTM Deep Learning

Yein Kim, Seeun Lee, Youngsung Kwon*
Department of Mechanical Control Engineering, Handong Global University

요약 딥러닝을 사용한 예측 방법은 동일한 예측 모델과 파라미터를 사용한다 하더라도 데이터셋의 특성에 따라 결과가 일정하지 않다. 예를 들면, 데이터셋 A에 최적화된 예측 모델 X를 다른 특성을 가진 데이터셋 B에 적용하면 데이터셋 A와 같이 좋은 예측 결과를 기대하기 어렵다. 따라서 높은 정확도를 갖는 예측 모델을 구현하기 위해서는 데이터셋의 성격을 고려하여 예측 모델을 최적화하는 것이 필요하다. 본 논문에서는 하루 대학 캠퍼스 전력사용량을 1시간 단위로 예측하기 위해 데이터셋의 특성이 고려된 예측 모델이 도출되는 일련의 방법을 단계적으로 제시한다. 데이터 전처리 과정을 시작으로, 이상치 제거와 데이터셋 분류 과정 그리고 합성곱 신경망과 장기-단기 기억 신경망이 결합된 알고리즘(CNN-LSTM: Convolutional Neural Networks-Long Short-Term Memory Networks) 기반 하이퍼파라미터 튜닝 과정을 소개한다. 본 논문에서 제안하는 예측 모델은, 각 시간별 24개 포인트에서 2%의 평균 절대비율 오차(MAPE: Mean Absolute Percentage Error)를 보인다. 단순히 예측 알고리즘만을 적용한 모델과는 달리, 단계적 방법을 통해 최적화된 예측 모델을 사용하여 단일 전력 입력 변수만을 사용해서 높은 예측 정확도를 도출한다. 이 예측 모델은 모바일 에너지관리시스템(Energy Management System: EMS) 어플리케이션에 적용되어 관리자나 소비자에게 최적의 전력 사용 방안을 제시할 수 있으며 전력 사용 효율 개선에 크게 기여할 것으로 기대된다.

Abstract A forecasting method using deep learning does not have consistent results due to the differences in the characteristics of the dataset, even though they have the same forecasting models and parameters. For example, the forecasting model X optimized with dataset A would not produce the optimized result with another dataset B. The forecasting model with the characteristics of the dataset needs to be optimized to increase the accuracy of the forecasting model. Therefore, this paper proposes novel optimization steps for outlier removal, dataset classification, and a CNN-LSTM-based hyperparameter tuning process to forecast the daily power usage of a university campus based on the hourly interval. The proposing model produces high forecasting accuracy with a 2% of MAPE with a single power input variable. The proposing model can be used in EMS to suggest improved strategies to users and consequently to improve the power efficiency.

Keywords : Deep Learning, AI, CNN, LSTM, Forecasting Campus Power Consumption, Energy Management System, Building Energy Management System, Mobile, Campus, Optimization, AICBM

*Corresponding Author : Youngsung Kwon(Handong Global Univ.)

email: youngsung.kwon@handong.edu

Received June 29, 2020

Accepted October 5, 2020

Revised July 31, 2020

Published October 31, 2020

1. 서론

1.1 연구 배경 및 목표

국제에너지기구(IEA: International Energy Agency, 이하 IEA)의 2019년 보고서에 따르면, 온실가스의 주성분인 이산화탄소 배출량은 전 세계의 지속적인 에너지 수요증가로 인해 33.1 Gt으로 역대 최고치를 기록한 것으로 조사됐다[1]. 세계 각국은 2015 파리 협정의 온실가스 감축목표를 달성하기 위해 부단히 노력하고 있다. 이에 따라 신재생 에너지 보급 확대와 에너지 사용 효율 개선에 대한 중요성이 점차 부각되고 있으며, 세계 에너지 시장은 에너지 전환 시대로 접어들었다. IEA는 에너지 사용 효율 개선이 경제 성장을 촉진하고 온실 가스 배출을 줄일 수 있는 잠재력을 가지고 있음에도 불구하고, 막대한 에너지 소비로 인해 2018년 최저 수준을 기록했다고 발표했다[2]. 이는 지속적인 에너지의 사용 효율 개선이 이 시대가 당면한 필수적인 과제를 해결하기 위한 획기적인 솔루션이 될 수 있음을 의미한다.

2018년 국내에서는 이산화탄소 배출 감축의 대안으로 신재생에너지 확대 정책을 발표했다. 신재생에너지 공급량은 전년 대비 8.45% 증가하였으나, 1차 에너지 대비 신재생에너지 공급비중은 5.8%로 낮은 비중을 차지했다[3]. 신재생에너지 출력의 불확실성과 변동성은 전력수급의 불균형을 일으켜 전력수급 안정성에 부정적인 영향을 미친다. 우리나라는 철강 및 반도체 등 전력소비가 큰 제조업의 비중이 높으므로 안정적인 전력 수급과 전력 소비 효율 개선이 반드시 필요하다.

2018년 기준 국내 건물 에너지 소비는 최종에너지 소비 중 41.7% 비중을 나타냈다[4]. 특히 건물 부문에 있어서 대학 캠퍼스는 에너지 다소비 기관 중 하나이며, 이는 호텔, 병원과 더불어 가장 높은 에너지 소비량을 보여준다[5]. 따라서 대학 캠퍼스의 에너지 사용 효율 향상을 통한 전력 사용량 절감이 필요하다.

본 논문은 대학 건물 에너지 절감 및 효율화 방안 분석에 사용될 예측값을 도출하기 위해, 데이터의 특성을 고려하여 캠퍼스 전력 사용량 예측 모델을 최적화하는 과정을 제안한다. 예측 모델 최적화 과정은 이상치 제거, 데이터셋 분류, 하이퍼파라미터 튜닝의 세 가지 단계로 이루어진다.

주거 및 상업용 건물 에너지 소비 예측에 대한 연구는 이미 활발하게 진행되고 있지만, 대학 캠퍼스를 대상으로 전력 사용량을 예측하는 연구는 미비하다. 따라서 본 논문에서는 대학 캠퍼스를 대상으로 전력 사용량을 예측하

였으며, 전력사용량 단일 입력 변수 사용만으로도 MAPE 2%의 높은 예측 정확도를 나타냈다.

본 논문의 2장에서는 앞서 소개한 과정을 거쳐 모델이 최적화되는 과정을 기술하며, 3장에서는 결론을 내리며, 향후 연구 계획에 대해 소개한다.

1.2 기대효과

본 논문의 궁극적인 목표는 에너지관리시스템 구축하여 에너지 소비 효율을 향상시키는 것이다. 제안된 최적화 모델로부터 예측된 전력 사용량 데이터는 실시간 모니터링 데이터와 함께 소비전력 패턴 분석 및 최적 제어 등의 에너지 관리 솔루션을 제공하기 위한 기반 정보가 될 것이다.

캠퍼스 전력 사용량을 실시간으로 모니터링 가능한 모바일 어플리케이션이 구축된 상태이며, 이는 Fig. 1. (a)와 같다. Fig. 1. (b)는 실제 구현한 모니터링 어플리케이션의 화면이다.

본 논문에서 제안한 예측모델을 모바일 에너지 관리 시스템 어플리케이션에 탑재하여 딥러닝 기반의 에너지 관리 시스템 구축에 한 걸음 더 나아가고자 한다. 이후 IoT 하드웨어를 접목하여 에너지 사용을 직접적으로 제어함으로써 낭비되는 전력을 절감할 것이다. 모바일 어플리케이션 및 IoT 하드웨어를 접목시키는 과정은 추후 연구로 진행할 예정이다. 국내 건물 에너지 소비는 국가 전체 에너지 소비 중 상당한 비중을 차지하고 있으므로 딥러닝 기반의 에너지 관리 시스템 구축과 이로부터 파급될 효율적인 에너지 사용 및 관리는 국가차원의 에너지 절감에 크게 기여할 것으로 기대된다.

2. 모델 최적화

2.1 데이터 취득 및 변환

본 논문은 한동대학교의 하루 전력 사용량을 1시간 단위로 예측하기 위해 기 구축된 서버와 데이터베이스로부터 1년치 전력사용량 데이터(2019.01.01 - 2019.11.25.)를 사용했다. 계측 장비로부터 매 1초씩 실시간으로 측정된 전력 사용량 데이터를 1시간 단위의 데이터로 변환하여 예측모델의 데이터셋으로 사용했다.

테스트 데이터로는 예측 대상일(24시간) 이전의 3일 전력 사용량을 사용하고 학습 데이터와 검증 데이터로는 테스트 데이터 이전의 1년치 캠퍼스 전력 사용량을 사용했다.

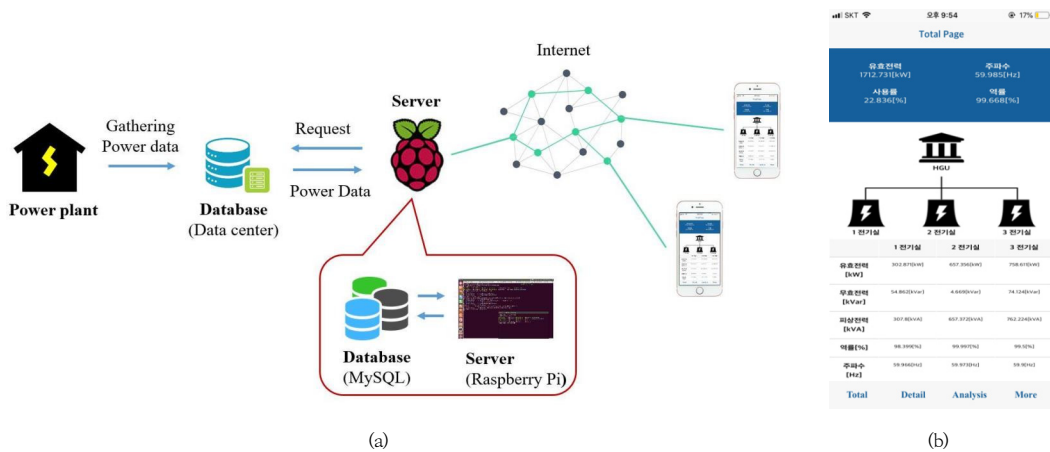


Fig. 1. The developed mobile application environment
 (a) Architecture of developed power monitoring mobile application, (b) Power monitoring mobile application

2.2 평가

2.2.1 학습 평가

훈련셋(training dataset)을 가지고 예측 모델을 학습 시키는 과정에서는 손실 함수를 통해 훈련 오차를 계산하고, 이 훈련 오차가 최소가 되는 방향으로 가중치와 편향이 수정된다. 따라서 훈련 오차는 예측 모델의 현재 상태를 나타내는 중요한 지표이다. 일반적인 훈련 오차 함수로 평균 제곱 오차(MSE: Mean Squared Error, 이하 MSE)를 사용하며 Eq. (1)과 같이 계산한다.

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

Where, n denotes the number of data in the dataset, y_i denotes the predicted value, and t_i denotes Actual observation.

2.2.2 검증 평가

훈련 과정을 마친 후, 검증셋(validation dataset)에 도 위의 과정을 동일하게 반복한다. 새로운 샘플에 대한 오류 비율을 일반화 오차(generalization error)라고 하며, 검증셋에서 예측 모델을 평가함으로써 이 오차에 대한 추정값을 얻는다. 이 값은 새로운 데이터에 대해 예측 모델이 얼마나 잘 동작하는지 알려준다. 일반화 오차를 정확하게 구하고 훈련 오차와 비교하는 것은 매우 중요한 과정이다. 훈련 오차가 낮지만, 일반화 오차가 높다면 이는 예측 모델이 훈련 데이터에 과대적합(over fitting) 되었다는 것을 의미한다[6].

본 논문에서 사용한 데이터셋은 교내 전력 사용량의 1

년치 데이터로써 데이터의 개수가 많은 편이 아니다. 검증셋이 너무 작으면 모델이 정확하게 평가되지 않으며, 최적이지 않은 모델을 잘못 선택할 가능성이 있다[7]. 이에 대한 대안으로 본 논문에서는 교차 검증을 수행했다.

2.2.3 예측 결과 평가

평균 제곱근 오차(RMSE: Root Mean Square Error, 이하 RMSE)는 모델이 예측한 값과 실제값 차이를 나타낼 때 사용되는 척도이다. 예측 정밀도를 표현하는데 적합한 RMSE는 Eq. (2)와 같이 계산된다.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - t_i)^2} \quad (2)$$

Where, n denotes the number of data in the dataset, y_i denotes the predicted value, and t_i denotes Actual observation.

2.3 예측 알고리즘

최근 시계열 예측에 사용되어 뛰어난 예측 성능으로 주목을 받고 있는 알고리즘인 CNN-LSTM은 합성곱층(convolution layer)에서 합성곱 연산을 하는 필터가 시퀀스 위를 슬라이딩하여 인접한 데이터에 대한 공간적 특성을 추출한다[8]. 이어서 시간 정보 파악에 최적화된 알고리즘인 LSTM을 지나며 시간적 특성을 반영해 예측하는 것이 주요 특징이다.

본 논문에서 제안하는 CNN-LSTM의 하이퍼파라미터는 Table 1과 같다. 합성곱층과 맥스 풀링층으로 CNN

을 구성했고, CNN의 출력 형태인 2차원 배열을 LSTM에 넣기 위해 1차원으로 바꿔주는 플랫튼 레이어를 사용했다. 또한 시계열 예측에 적합한 LSTM 레이어에서 제안된 모델에 적합한 64개의 전력 사용량값을 예측 후, 마지막 전결합 레이어(fully connected layer)에서 오차가 가장 작은 값 하나를 선택하도록 설계했다. Fig. 2는 제안하는 CNN-LSTM의 전체적인 구조를 나타낸다.

Table 1. Hyper parameters of the proposed CNN-LSTM model.

Type of layer	Node	Kernel size	Stride
Convolution	32	(2,1)	1
Max Pooling	-	(2,1)	1
Flatten	-	-	-
LSTM	64	-	-
FC	1	-	-

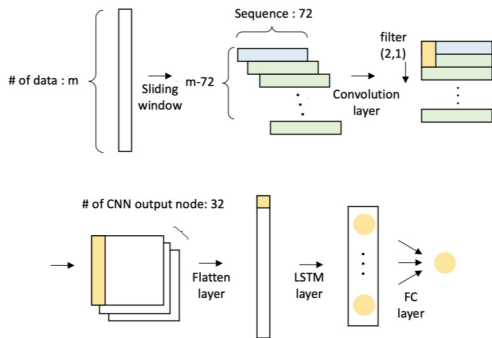


Fig. 2. Proposed CNN-LSTM structure

2.4 데이터 전처리

이상치(outlier)는 특정 범위 내에서 많이 벗어난 아주 큰 값 또는 작은 값을 말한다. 본 논문에서는 제안한 예측 모델의 예측 정확도를 높이기 위해 다음의 두 가지 기준으로 이상치를 고려했다. 통계적으로 사분위 범위(IQR: Inter Quartile Range, 이하 IQR)의 1.5배를 넘어가는 데이터를 통계적 이상치로 간주했고, 특정 상황에서 예외로 간주될 수 있는 데이터를 조건부 이상치로 고려했다.

Fig. 3는 1년치 캠퍼스 전력 사용량을 시각화 한 것이다. Fig. 3(a)는 이상치를 제거하지 않은 데이터셋, Fig. 3(b)는 통계적 이상치를 제거한 데이터셋이다. Fig. 3(c)는 Fig. 3(b)에서 추가적으로 조건부 이상치를 제거한 데

이터셋이다. 조건부 이상치에는 설날, 추석 같은 고유 명절 등 특정 상황을 고려했으며, 이는 각 기간동안 캠퍼스 건물을 폐관하여 정상적인 사용량 거동을 보이지 않았기 때문이다.

Table 2에서는 제안한 예측 모델과 기존의 시계열 예측에 사용되는 대표적인 모델과의 예측 결과를 비교했다. 또한 데이터셋의 이상치가 예측 결과에 미치는 영향을 살펴보기 위해 세 개의 그룹(이상치 존재, 통계적 이상치 제거, 통계적&조건부 이상치 제거)로 나누어 결과를 비교했다. RMSE값을 살펴보면, 모든 그룹 1, 2, 3에서 CNN-LSTM 알고리즘의 예측 정확도가 가장 높다는 것을 알 수 있다. Fig. 4는 이를 시각화한 것이다. 다음으로 이상치 그룹별 RMSE 값을 살펴보면, 이상치를 두 가지 방법으로 모두 제거한 집단 3이 가장 예측 정확도가 높은 것을 알 수 있다. Fig. 5는 이를 시각화한 것이다.




Fig. 3. 1-year dataset outlier removal process
(a) 1-year raw dataset (b) 1-year dataset with outlier removed
(c) 1-year dataset with outlier and traditional holidays removed

Table 2. Results according to the algorithm and outlier removal group

Group	1	
	MSE	RMSE
CNN-LSTM	4311.8337	65.664555
FCNNs	20907.929	144.59574
CNN	8273.2515	14534.428
LSTM	90.957416	120.55881

Group	2	
	MSE	RMSE
CNN-LSTM	3982.6549	63.108279
FCNNs	11253.257	106.08137
CNN	7627.1167	87.333365
LSTM	8300.5187	91.107182

Group	3	
	MSE	RMSE
CNN-LSTM	2684.6524	51.813632
FCNNs	12040.630	109.72981
CNN	11753.532	14534.428
LSTM	7353.1990	85.750796




Fig. 4. Comparison of the Results by Algorithm




Fig. 5. Comparison of the Results by Removing Outlier

2.5 데이터셋 분류

이후 과정에서는 앞서 수행한 이상치 제거를 거쳐 통계적 및 조건부 이상치를 제거한 데이터셋을 사용했다. 캠퍼스의 전력 사용량은 학기중과 방학, 주중과 주말의 패턴이 다르게 나타난다. 이러한 변동이 예측 결과에 어떻게 영향을 주는지 관찰하기 위해 데이터셋 분류를 진

행했다.

본 논문에서는 데이터셋 분류에 다음과 같은 2가지 기준을 사용했다. Table 4의 Class 1은 학기 중과 방학의 차이를 고려하기 위해 3개의 그룹(1년치 데이터셋, 1&2 학기 데이터셋, 그리고 2학기 데이터셋)으로 분류했다. 또한 Class 2는 주중과 주말의 차이를 고려하기 위해 2개의 그룹(주중과 주말을 포함한 데이터셋, 주중만 포함한 데이터셋)으로 구성했다. 그 결과 Class 1의 분류에서는 데이터의 절대량이 가장 많은 1-year 집단이 가장 좋은 결과를 보였다. Class 2의 분류에서는 주중과 주말을 포함한 데이터셋보다 주중만을 포함한 데이터셋이 예측 정확도가 높은 결과를 나타냈다.

Table 3. Results from dataset classification

Class 1	1-year	
Class 2	All day	Weekdays
MSE	2684.65242	1950.45803
RMSE	51.8136316	44.1639902

Class 1	1 st and 2 nd Semester	
Class 2	All day	Weekdays
MSE	4508.18921	6911.93851
RMSE	67.1430503	83.1380689

Class 1	2 nd Semester	
Class 2	All day	Weekdays
MSE	23323.5601	10749.4691
RMSE	152.720529	103.679646

2.6 하이퍼파라미터 튜닝

하이퍼파라미터 튜닝은 검증셋에서 모델의 성능을 평가하여 최적의 학습 방법을 찾기 위해 하이퍼파라미터를 조정하는 것을 말한다. Table 3에서 예측 정확도가 가장 높은 데이터셋은 이상치를 모두 제거한 1년 주중 데이터셋이다. Table 4는 하이퍼파라미터 튜닝에 의해 결정된 하이퍼파라미터이다. 하이퍼파라미터 튜닝을 통해 RMSE 값은 Table 3의 44에서 Table 4의 35까지 감소한다. 에포크(epoch)는 클수록 결과가 좋아지는 경향이 있지만 너무 크게 하면 과적합을 발생시킬 수 있으며 학습 속도가 매우 느려지게 된다. 따라서 에포크는 적정 값인 50으로 고정하고 실험적으로 합성곱 층의 유닛 수와 층의 수, 필터 크기, 풀링 크기와 배치 크기를 선택했다. Table 5는 한 가지 변수만 변화시키고 나머지 변수는 Table 4의 값을 사용하여 도출한 결과이다. 예를 들어

합성곱 층의 유닛 수를 결정할 때에는 합성곱 층은 3겹으로, 필터는 (2,1)로, 풀링은 (2,1)로, 배치는 12로 테스트했다.

Table 4. Hyper parameter of optimized model

Class	1 year weekdays
Convolution units	32
Convolutional layer	3
Filter size	(2,1)
Pool size	(2,1)
Batch size	12
MSE	1256.6182
RMSE	35.4488

Table 5. Results of the hyper parameter optimization

Conv. units	32	64
MSE	1256.6182	1444.49326
RMSE	35.4488	38.0064897

Conv. layer	1	2	3	4
MSE	3106.47	1939.2	1256.6	4578.1
RMSE	55.7357	44.037	35.449	67.662

Filter size	(2,1)	(4,1)	(6,1)
MSE	1256.6182	1942.84586	2349.186
RMSE	35.448811	44.0777253	48.46841

Pool size	X	(2,1)	(4,1)
MSE	3912.7775	1256.6182	24184.57
RMSE	62.552198	35.448811	155.5139

Batch size	6	12	24
MSE	2570.9556	1256.6182	2534.645
RMSE	50.704592	35.448811	50.34526

Table 6는 캠퍼스의 전력 사용량 예측 모델 최적화 결과를 정리한 것이다. 결과적으로 시계열 데이터의 공간적 정보와 시간적 정보를 동시에 추출할 수 있는 CNN-LSTM 알고리즘이 가장 높은 예측 정확도를 보였다. 다음으로 2가지 이상치를 제거하였을 때 가장 정확도 높은 예측을 할 수 있었고, 마지막으로 데이터의 절대량을 극단적으로 줄이지 않는 선에서 데이터셋을 분류할 때 가장 높은 예측 정확도를 확보할 수 있었다. 이러한 일련의 데이터 전처리 과정을 거친 후 마지막으로 하이퍼파라미터 튜닝을 통해 최적화 결과를 도출했다. RMSE는 단순히 오차의 크기를 비교하는 지표이며, MAPE는 오차의 비율로 모델을 비교할 수 있는 지표이다. 본 논문에서는 최적화된 모델을 도출하는 과정에서 직관적으로 오차를 비교하기 위해 RMSE를 사용했지만, 다른 데이터셋을 사용하는 모델과의 상대적인 성능 비교를 위해서는 오차를 MAPE와 같은 상대적인 지표로 나타냈다.

Fig. 6는 대학 캠퍼스의 하루 전력 사용량을 시간별로 예측한 결과를 나타낸다. 빨간색 선은 CNN-LSTM 예측 모델을 사용한 예측 결과이고, 검은색 선은 실제 대학 캠퍼스 전력 사용량을 나타낸다. Fig. 6의 결과와 같이 본 논문에서 제안한 단계별 최적화 기법을 사용할 경우 하루 동안의 전력 사용량 변화에 대해 작은 오차로 추종하는 것을 확인할 수 있다.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - t_i}{y_i} \right| \times 100\% \quad (3)$$

Where, n denotes the number of data in the dataset, y_i denotes the predicted value, and t_i denotes Actual observation.




Fig. 6. Results of CNN-LSTM Optimization

Table 6. Results of optimized model

Algorithm	
CNN-LSTM	
Classification	
1-year Weekdays	
Architecture	
Convolution units	32
Convolutional layer	1
Filter size	(2,1)
Pool size	(2,1)
Batch size	12
Results	
MSE	1256.6182
RMSE	35.448811
MAPE	2.13 %

3. 결론

본 논문은 CNN-LSTM 모델을 사용하여 대학 캠퍼스의 하루 전력 사용량을 1시간 단위로 보다 정확하게 예측하기 위해 모델을 최적화하는 과정을 단계적으로 제시했다. 제시한 단계를 실제적으로 모델에 적용함으로써 적절한 알고리즘 선택, 이상치 제거, 데이터셋 분류, 하이퍼 파라미터 튜닝이 제안한 모델의 예측 결과에 미치는 영향을 단계적으로 검증했다. 일련의 최적화 과정을 거쳐 제안된 CNN-LSTM 기반 예측 모델은 MAPE 2%의 훌륭한 예측 정확도와 뛰어난 성능을 보였다.

본 논문에서 제안한 최적화 예측 모델은 추후 사용자의 에너지 사용 패턴 분석 및 제어 솔루션을 제공하는 모바일 에너지관리시스템 어플리케이션의 기반으로 유용하게 사용될 것이다. 이를 통해 에너지 사용 효율 개선에 크게 기여할 것으로 기대된다.

References

[1] IEA. Global Energy and CO2 Status Report [Internet]. IEA, c2019 [cited 2019 March 26], Available From: <https://www.iea.org/reports/global-energy-co2-status-report-2019> (accessed May. 25, 2020)

[2] IEA. Energy and Efficiency [Internet]. IEA, c2019 [cited 2019 Nov. 26], Available From: <https://www.iea.org/reports/energy-efficiency-2019> (accessed May. 25, 2020)

[3] C. S. Kim, New & Renewable Energy Supply Statistics, Technical Report, Korea Energy Agency, Korea, pp.15-18.

[4] Y. S. Moon, Monthly Energy Statistics, Technical Report, Korea Energy Economics Institute, Korea, pp.17-20.

[5] G. H. Park, Research on Energy Efficiency Improvement Plan of University Campus Building, Korea Energy Economics Institute, Korea, pp.7-10.

[6] A. Geron, Hands-On Machine Learning with Scikit-Learn, Keras & TensorFlow, p.952, Hanbit Publishing Network, 2020, pp.62-63.

[7] T. Y. Kim, Python Deep Learning Keras with Blocks, p.304, DIGITAL BOOKS, 2017, pp.41.

[8] T. Y. Kim, "Predicting residential energy consumption using CNN-LSTM neural networks", Energy, ELSEVIER, South Korea, Volume 182, pp.72-81, September 2019. DOI: <https://doi.org/10.1016/j.energy.2019.05.230>

김 예 인(Yein Kim)

[준회원]



• 2016년 3월 ~ 현재 : 한동대학교 기계제어공학부

<관심분야>

AI, 전력전자, 전력계통 등.

이 세 은(Seeun Lee)

[준회원]



• 2016년 3월 ~ 현재 : 한동대학교 기계제어공학부

<관심분야>

AI, 전력전자, 전력계통 등.

권 용 성(Youngsung Kwon)

[정회원]



- 2012년 8월 : University of Texas at Austin (공학석사)
- 2015년 8월 : University of Texas at Austin (공학박사)
- 2015년 10월 ~ 2018년 8월 : LG 전자 VC사업본부 선임연구원
- 2018년 9월 ~ 현재 : 한동대학교 기계제어공학부 조교수.

〈관심분야〉

전력변환, 전력계통 등.