

도시화율 및 산업 구성 차이에 따른 딥러닝 기반 전력 수요 변동 예측 및 전력망 운영

김가영 · 이상훈[†]

이화여자대학교 엘텍공과대학 기후·에너지시스템공학전공

Deep Learning Based Electricity Demand Prediction and Power Grid Operation according to Urbanization Rate and Industrial Differences

KAYOUNG KIM, SANGHUN LEE[†]

Department of Climate and Energy Systems Engineering, Ewha Womans University, 52 Ewhayeodae-gil, Seodaemun-gu, Seoul 03760, Korea

[†]Corresponding author :
sanghun@ewha.ac.kr

Received 30 August, 2022
Revised 29 September, 2022
Accepted 15 October, 2022

Abstract >> Recently, technologies for efficient power grid operation have become important due to climate change. For this reason, predicting power demand using deep learning is being considered, and it is necessary to understand the influence of characteristics of each region, industrial structure, and climate. This study analyzed the power demand of New Jersey in US, with a high urbanization rate and a large service industry, and West Virginia in US, a low urbanization rate and a large coal, energy, and chemical industries. Using recurrent neural network algorithm, the power demand from January 2020 to August 2022 was learned, and the daily and weekly power demand was predicted. In addition, the power grid operation based on the power demand forecast was discussed. Unlike previous studies that have focused on the deep learning algorithm itself, this study analyzes the regional power demand characteristics and deep learning algorithm application, and power grid operation strategy.

Key words : Artificial Intelligence(인공지능), Deep learning(딥러닝), Power grid(전력망), Urbanization(도시화)

1. 서론

기후변화가 심각해짐^{1,2)}에 따라 COP21 등 기후위기를 극복하기 위한 전 세계적 노력이 이루어지고 있다³⁾. 특히 기존의 화석연료를 신재생 및 수소 에너

지로 대체하여 온실가스 배출을 저감하기 위한 노력들^{4,6)}이 대표적이다. 하지만, 특히 신재생 에너지는 발전량 제어가 어려우며 전력 생산 시의 변동성이 크다는 이슈가 있다^{7,8)}. 이러한 신재생 에너지의 발전 특성은 결국 전력망을 안정적으로 운영하는 데 어려

움을 야기한다. 특히 전력망의 운영이 일반적으로 하루 전 계획에 따라 이루어지게 된다⁹⁾는 것을 고려할 때 신재생 에너지의 비율이 증가함에 따라 전력망의 불안정성이 크게 증가할 수 있다.

이러한 문제를 해결하기 위해서는 전력 수요량에 대한 정확한 예측을 수행함으로써 전력망의 안정성을 높이는 방법을 고려할 수 있다. 기존에는 일일의 전력 수요량 예측에 어려움이 있었으나 최근 인공지능이 부상하면서 이를 활용해 전력 수요량을 예측하는 연구가 이어지고 있는 중이다^{10,11)}. 전력 수요량은 일반적으로 시계열 데이터로서 딥러닝을 통해 예측이 가능하다¹²⁾. 이러한 예측기술을 기반으로 스마트 그리드, 실시간 전력시장 등 전력망을 효율적으로 운영할 수 있는 다양한 전략들이 제안되고 있다^{13,14)}.

하지만 보다 정확한 전력 수요량 예측을 위해서는 다양한 지역의 특성을 고려한 연구가 필수적이다. 특히 스마트 그리드에 활용되는 데이터의 형태는 앞으로 더욱 다양해질 것인데, 전력 수요량과 같은 정형 데이터(structured data) 뿐만 아니라 비정형적 특징 또한 내재된, 지역 경제 관련 데이터 또한 중요한 분석 대상이 된다¹⁵⁾. 따라서 예측 대상 지역의 경제 구조에 영향을 미치는 요소를 파악한 뒤 예측을 수행하여야 지능적인 전력망 운영이 가능할 것이다. 하지만 기존에는 단순히 다양한 인공지능 알고리즘을 적용하는 수준의 연구만이 진행되어 왔었다.

본 연구에서는 지역의 도시화율에 따른 전력 수요량 변동 특성을 분석하고, 딥러닝 기법 중 하나인 순환 신경망(recurrent neural network, RNN)을 활용하여 각 지역에서의 전력 수요량을 예측하였다. 이를 위해 미국 내 도시화율이 높은 지역에 속하는 뉴저지와 낮은 지역에 속하는 웨스트 버지니아 지역을

의 전력 수요량 특성을 분석하였으며, 그 수요량 변동을 예측을 수행하였다.

2. 모델링

본 연구에서는 뉴저지와 웨스트 버지니아 주의 2020년 1월 1일부터 약 31개월간 PJM 전력 소비 데이터를 이용하였다¹⁶⁾. 먼저 두 지역의 전력 사용량 특성을 확인하기 위하여 시간별 전력 소비량 데이터를 일별로 재조정하였다. 그 후 파이썬의 matplotlib 라이브러리로 새롭게 가공된 시계열 데이터를 시각화하였다. 다음으로, 전력 수요 예측 모델에는 대표적인 딥러닝 라이브러리인 Keras에서 제공하는 SimpleRNN이 사용되었다. 뉴저지, 웨스트 버지니아 각각에 대하여 일주일, 하루 단위의 전력 수요량을 예측하였으며 기계 학습에 사용된 시계열 데이터의 상세한 기간은 Table 1과 같다.

RNN은 인공 신경망의 한 종류로 뉴런의 출력이 다시 순환되어 학습되기 때문에 시계열 데이터 처리에 유용하다. RNN에 입력되는 하이퍼 파라미터는 Table 2에 기술된 값으로 설정하였으며 신경망의 형태는 Fig. 1과 같다.

입력되는 데이터 세트 전체는 신경망에 100번 학습되도록 하였으며 한 번의 연산에 들어가는 데이터의 크기는 128로 설정하였다. 반면 신경망이 과적합 상태에 이르게 되면 훈련 데이터를 통한 학습이 과도하게 잘 이루어져 오히려 검증 데이터에 대한 성능은 떨어지게 되는데, 이를 방지하기 위하여 드롭아웃

Table 1. Datasets used for deep learning

	Train data	Test data
Weekly predictions	2020.01.01.~ 2022.08.03	2022.08.04.~ 2022.08.10
Daily prediction	2020.01.01.~ 2022.08.09	2022.08.10

Table 2. Hyperparameters of SimpleRNN

Hyperparameter	Value
Number of neurons	40
Optimizer	Adam
Activation function	tanh
Dropout rate	0.15
Loss function	Mean squared error (MSE)
Epoch	100
Batch size	128

웃을 통해 임의의 뉴런이 학습 시에 배제되도록 하였다.

예측 모델의 정확도를 평가하기 위하여 MSE와 MAE를 계산하였다. 두 척도 모두 실제값과 RNN 모델이 예측한 값 사이의 오차를 나타내며 0에 가까울 수록 정확한 예측이 이루어졌다는 것을 의미한다.

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i^{actual} - y_i^{predicted})^2$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i^{actual} - y_i^{predicted}|$$

3. 연구 결과 및 고찰

3.1 전력 수요량 특성 분석

본 연구에서 선정한 뉴저지와 웨스트 버지니아는

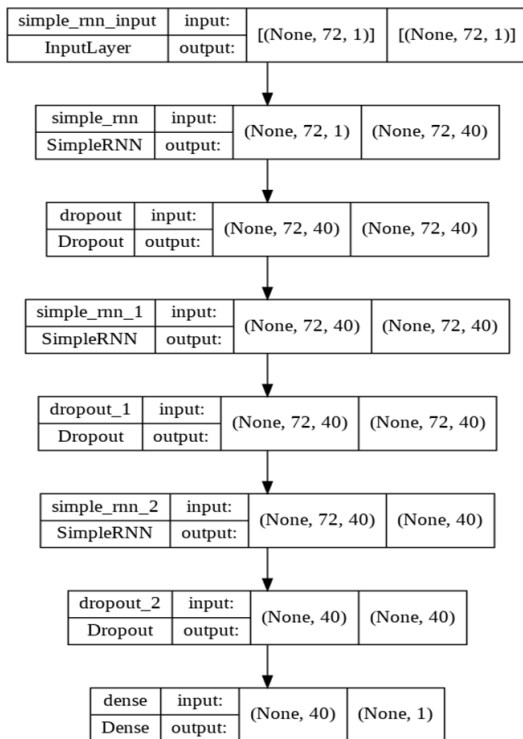


Fig. 1. Visualization of SimpleRNN model

도시화 정도에서 큰 차이를 보인다. 2010년을 기준으로 두 지역의 도시화율은 뉴저지 94.7%, 웨스트 버지니아 48.7%로 약 1.9배의 차이가 난다¹⁷⁾. 뉴저지의 경우, 대표적인 주거지역으로서 의료, 교육, 소매, 서비스 등의 산업에 기초하고 있다. 반면에 웨스트 버지니아는 석탄을 포함한 광물자원 및 에너지, 화학 관련 산업이 대부분을 차지하고 있다.

Fig. 2는 각각 뉴저지와 웨스트 버지니아의 2020년 1월부터의 전력 수요 변동을 나타낸다. 주목할 만한 점은 뉴저지의 경우 여름철에 최저 전력 수요와 비교하여 약 2.5-2.8배 이상의 많은 전력 수요가 발생한 반면에, 웨스트 버지니아의 경우 여름과 겨울철에 높은 전력 수요가 나타나지만 최저 전력 수요와 비교하여 1.6-1.8 수준으로 뉴저지에 비해서는 낮은 전력 수요 변동성이 발생하였다는 점이다.

이러한 차이가 발생한 원인은 도시화율과 주요 산업의 차이에서 기인하였을 가능성이 있다. 전술한 바와 같이 뉴저지의 경우는 높은 도시화율을 가지는 도심 지역이므로 서비스 분야 산업이 주를 이룬다. 이로 인하여 주거 및 상업 지역에서 여름철에 냉방 등에 의해 전력 수요가 크게 증가했을 가능성이 있다. 반면 웨스트 버지니아의 경우 도시화율이 낮으며 석탄 기반의 산업이 경제의 대부분을 차지하고 있는데, 일반적으로 석탄 등 광물자원 산업 등은 계절에 따라 전력 수요를 크게 변동하게 만들지 않는다. 때문에 여름과 겨울에 난방 및 냉방 등으로 인해 전력 수요가 증가하더라도 그 정도는 크지 않았던 것으로 추정된다. 추가적으로, 뉴저지와 웨스트 버지니아의 연중 평균 온도는 통계적으로 유사한 수준으로 변화하기 때문에 두 지역의 기온 차이에 의한 것은 아닌 것으로 판단된다.

3.2 딥러닝 기반 전력 수요 예측 결과

Fig. 3은 뉴저지와 웨스트 버지니아의 전력 수요 예측 결과에 대한 손실 함수를 나타낸다. 손실 함수란 RNN 모델이 최적화하는 대상이기 때문에 손실이 작아질수록 모델이 정답을 잘 맞히는 것이라 해석할

수 있다. 그 결과 두 지역 모두에 대하여 100회의 epoch가 진행됨에 따라 훈련 손실뿐만 아니라 검증 손실 또한 작은 값으로 수렴함을 관찰할 수 있었다.

Fig. 4는 뉴저지와 웨스트 버지니아 각각에 대한 1주일 치 전력 수요 예측의 결과이다. 두 연구 결과의 100회 epoch를 기준으로 정략적인 오차값은 Table 3과 같으며 두 지역 모두에서 유사한 수준의 예측 정확도를 보이고 있다.

또한 Fig. 5는 각각 뉴저지와 웨스트 버지니아의 일일 전력 수요 예측 결과를 확대하여 나타낸다. 이에 대한 정략적인 오차값은 Table 4와 같다. 이때 뉴저지가 웨스트 버지니아에 비해 더 큰 변동성을 가지는 것을 확인할 수 있었는데, 전력 수요 정규화 값

을 기준으로 하루 동안 뉴저지는 최대 0.23-0.95의 변동성을, 웨스트 버지니아는 0.28-0.88의 변동성을 나타내었다. 그럼에도 앞선 일주일간 예측과 마찬가지로 낮은 오차값을 가졌으며 두 경우 모두에 대하여 높은 정확도를 보임을 알 수 있었다.

이러한 변동성은 앞서 언급한 바와 같이 산업 구조의 차이에서 기인한 것으로 추정된다. 도시화율이 높아 주거 및 상업 지역이 많은 비율을 차지하는 뉴저지의 경우, 낮 시간에 많은 전력 수요가 발생하고 야간에는 수요가 감소하게 된다. 하지만 석탄 산업이 발달한 웨스트 버지니아에서는 야간에도 관련 공업 지대에서 일정량의 전력 수요가 발생할 것이기 때문이다.




Fig. 2. Electricity demand curve for Jan 2020-Jul 2022: (a) New Jersey and (b) West Virginia

3.3 도시화율 및 산업 구성에 따른 전력망 수요 예측 전략

앞선 전력 수요 특성 분석 및 예측 과정을 통해 도시화율과 산업 구성이 다른 뉴저지와 웨스트 버지니아에서 어떤 차이점이 관찰되는지 확인할 수 있었다. 더불어 두 지역 모두에서 지난 2년 이상의 전력 수요 데이터를 기반으로 딥러닝을 통해 하루 및 일주일간의 전력 수요를 예측하는 것이 가능함을 확인하였는데 이는 딥러닝을 활용한 전력 수요 예측 기술이 실제 전력망의 운영에 활용될 수 있는 가능성을 보인 것이기도 하다.

또한 각 지역의 전력 수요 특성이 다르며 특히 도시화율이 높고 주요 산업 구성이 서비스 산업에 해당하는 경우, 도시화율이 낮고 주요 산업 구성이 석탄 산업을 포함한 광물자원, 에너지, 화학 산업 분야에 치중된 곳에 비해 전력 수요의 계절간, 주간, 일간 변동성이 더 큰 것을 확인할 수 있었다. 따라서 하이

퍼 파라미터 최적화, epoch 횟수의 증가, 최신 알고리즘의 도입 등을 통해 더욱 정확한 예측을 하기 위한 노력이 필요하다.

본 연구는 기존에 딥러닝 알고리즘 자체에만 집중하여 전력망의 수요를 예측하여 왔던 기존의 연구 방식에서 벗어나 각 지역별 특성을 고려하여 전력 수요 패턴을 파악하고, 딥러닝을 활용한 전력 수요의 정확한 예측 가능성을 평가하였다. 이를 기반으로 하루 전 시장을 통한 전력망 안정성 향상 운영 전략의 가능성을 보여주었다는 데 그 의미가 있다.

그러나 본 연구에는 여러 한계점이 존재한다. 우선 실제 전력 수요 예측을 기반으로 전력망을 효율적으로 운영하기 위해서는 하루 단위의 예측뿐만 아니라 시간 단위의 예측 또한 수행되어야 한다. 일반적으로 하루 전 계획 및 시장을 통해 전력망을 효율적으로 운영하는 전략이 많이 제시되고 있으나 신재생 에너지의 비율이 증가함에 따라 변동성 제어가 중요해졌다. 이에 한 시간 단위의 전력 거래 시장이

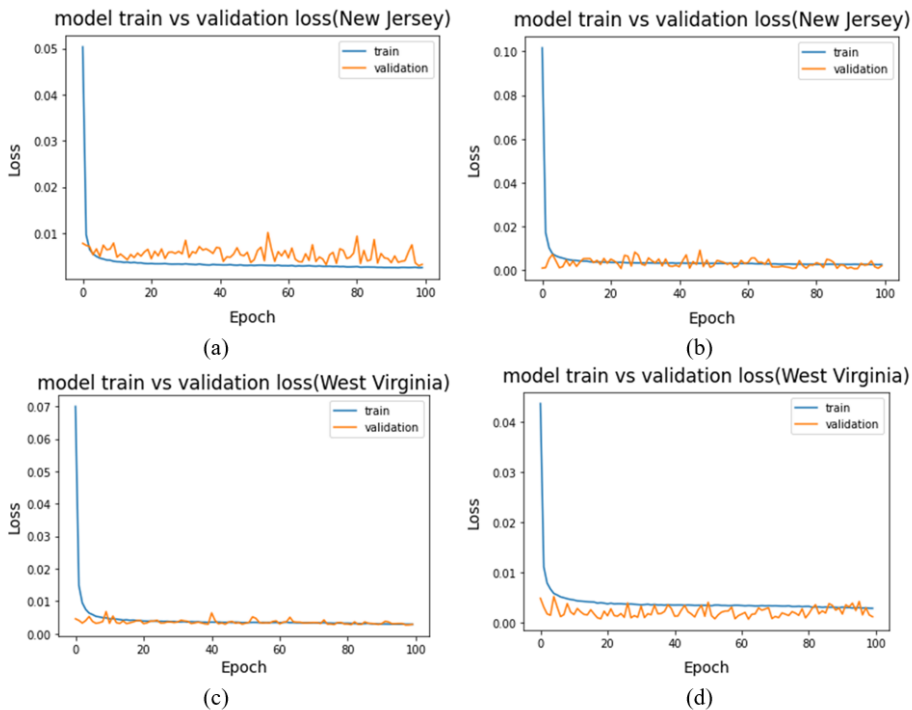


Fig. 3. Model train vs validation loss with increasing epoch: (a) weekly and (b) daily prediction for New Jersey, and (c) weekly and (d) daily prediction for West Virginia

나 전력 사업자를 실시간으로 시장에 참여시키는 방안도 검토되고 있는 바 더 짧은 시간 단위의 정확한 전력 수요 예측 연구가 이루어져야 할 것이다. 더불어 지역의 전반적인 전력 사용의 흐름이나 양상을 거시적으로 파악하기 위해서는 연간 전력 소비량 예측 등 비교적 장기적 시간에 걸친 예측 또한 필요할 것이다.

또한 본 연구에서는 딥러닝에서 널리 활용되어 왔던 RNN 알고리즘을 활용하였다. 하지만 시계열 데이터의 예측에 활용되는 인공지능 알고리즘에는 FNN, DFNN, TCN, ERNN, LSTM, GRU, seq2seq, ARIMA 등 다양한 종류가 있다¹⁸⁾. 따라서 향후 연구에서는 각 지역의 전력 수요 특성에 보다 적합한 알고리즘을 선정하여 이를 분석 및 평가할 필요성이 있을 것이다.

4. 결론

본 연구에서는 도시화율과 산업 구성이 크게 다른

미국 뉴저지와 웨스트 버지니아의 전력 수요 변동 특성을 분석하였으며, RNN 알고리즘을 적용하여 하루 및 일주일간의 전력 수요를 성공적으로 예측하였다. 또한, 도출된 예측 결과를 기반으로 전력 수요 예측 기반 전력망 운영 전략을 논의하였다. 그 결과 도시화율이 높고 서비스 관련 산업이 주를 이루는 뉴저지가 도시화율이 낮고 석탄, 에너지, 화학 산업이 주를 이루는 웨스트 버지니아에 비해 높은 계절간(2.5-2.8배 vs. 1.6-1.8배), 일간(최대 정규화값 범위 0.23-95 vs. 0.28-0.88) 전력 변동성을 나타냄을 확인하였다. 그럼에도 두 지역 모두에서 RNN을 통해 일주일 및 하루간의 전력 수요 예측이 가능하며 MAE와 MSE 값 또한 낮아 예측 모델이 높은 수준의 정확도를 가진다는 것을 알 수 있었다. 향후 딥러닝의 예측에 기반하여 전력망을 운영하기 위해서는 특히 변동성이 큰 지역에 대하여 하이퍼 파라미터 최적화, epoch 횟수의 증가, 최신 알고리즘의 도입 등 더욱 정확한 예측을 위한 방법들이 수반되어야 할 것이며 추가적으로 다양한 알고리즘의 정확도를 비교함으로써

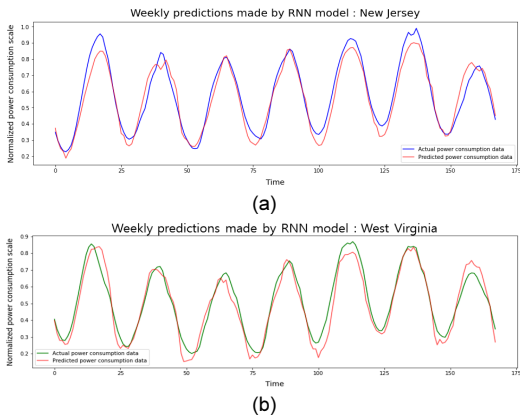


Fig. 4. Weekly electricity demand prediction: (a) New Jersey and (b) West Virginia

Table 3. Quantitative evaluation of the RNN model weekly forecasting results

Region	MSE	MAE
New Jersey	0.003	0.047
West Virginia	0.003	0.043

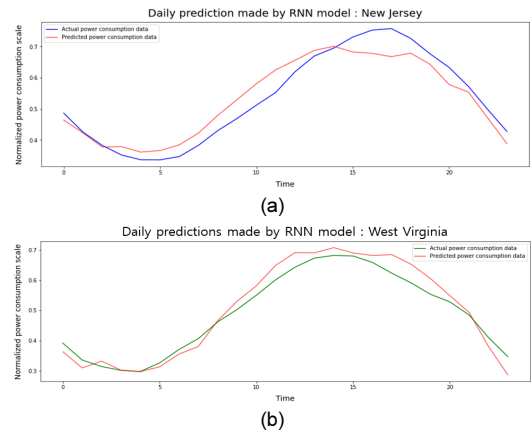


Fig. 5. Daily electricity demand prediction: (a) New Jersey and (b) West Virginia

Table 4. Quantitative evaluation of the RNN model daily forecasting results

Region	MSE	MAE
New Jersey	0.002	0.039
West Virginia	0.001	0.044

써 보다 효율적인 전력망 체계를 구축할 수 있을 것이다.

후 기

이 연구는 2022학년도 이화여자대학교 교내연구비 지원에 의한 연구입니다. 이 논문은 정부(기상청)의 재원으로 한국기상산업기술원의 기상기후데이터 융합분석 특성화대학원 사업의 지원을 받아 수행되었습니다.

References

1. L. Berrang-Ford, R. Biesbroek, J. D. Ford, A. Lesnikowski, A. Tanabe, F. M. Wang, C. Chen, A. Hsu, J. J. Hellmann, P. Pringle, M. Grecequet, J. C. Amado, S. Huq, S. Lwasa, and S. J. Heymann, "Tracking global climate change adaptation among governments", *Nat. Clim. Change*, Vol. 9, No. 6, 2019, pp. 440-449, doi: <https://doi.org/10.1038/s41558-019-0490-0>.
2. J. W. Ahn, "The significance of long-term perception on renewable energy and climate change", *Trans Korean Hydrogen New Energy Soc*, Vol. 29, No. 1, 2018, pp. 117-123, doi: <https://doi.org/10.7316/KHNES.2018.29.1.117>.
3. A. Robbins, "How to understand the results of the climate change summit: Conference of Parties21 (COP21) Paris 2015", *Journal of Public Health Policy*, Vol. 37, No. 2, 2016, pp. 129-132, doi: <https://doi.org/10.1057/jphp.2015.47>.
4. R. Gross, M. Leach, and A. Bauen, "Progress in renewable energy", *Environ. Int.*, Vol. 29, No. 1, 2003, pp. 105-122, doi: [https://doi.org/10.1016/S0160-4120\(02\)00130-7](https://doi.org/10.1016/S0160-4120(02)00130-7).
5. H. Lee and S. Lee, "Economic analysis on hydrogen pipeline infrastructure establishment scenarios: case study of South Korea", *Energies*, Vol. 15, No. 18, 2022, pp. 6824, doi: <https://doi.org/10.3390/en15186824>.
6. Y. H. Jang, S. Lee, H. Y. Shin, and J. Bae, "Development and evaluation of a 3-cell stack of metal-based solid oxide fuel cells fabricated via a sinter-joining method for auxiliary power unit applications", *Int. J. Hydrogen Energy*, Vol. 43, No. 33, 2018, pp. 16215-16229, doi: <https://doi.org/10.1016/j.ijhydene.2018.06.141>.
7. S. Lee, T. Kim, G. Han, S. Kang, Y. S. Yoo, S. Y. Jeon, and J. Bae, "Comparative energetic studies on liquid organic hydrogen carrier: a net energy analysis", *Renewable Sustainable Energy Rev.*, Vol. 150, 2021, pp. 111447, doi: <https://doi.org/10.1016/j.rser.2021.111447>.
8. S. Ali and C. M. Jang, "Field testing and performance evaluation of 1.5 kW Darrieus wind turbine", *Trans Korean Hydrogen New Energy Soc*, Vol. 30, No. 6, 2019, pp. 608-613, doi: <https://doi.org/10.7316/KHNES.2019.30.6.608>.
9. J. Kong and J. Jung, "Development of incentive model for photovoltaic generators to participate in a day-ahead electricity market in South Korea", 2019 IEEE Innovative Smart Grid Technologies-Asia (ISGT Asia), 2019, pp. 2898-2902, doi: <https://doi.org/10.1109/ISGT-Asia.2019.8881082>.
10. M. Q. Raza and A. Khosravi, "A review on artificial intelligence based load demand forecasting techniques for smart grid and buildings", *Renewable Sustainable Energy Rev.*, Vol. 50, No. 2015, pp. 1352-1372, doi: <https://doi.org/10.1016/j.rser.2015.04.065>.
11. G. Han, S. Lee, J. Lee, K. Lee, and J. Bae, "Deep-learning-and reinforcement-learning-based profitable strategy of a grid-level energy storage system for the smart grid", *J. Energy Storage*, Vol. 41, No. 2021, pp. 102868, doi: <https://doi.org/10.1016/j.est.2021.102868>.
12. E. Choi, S. Cho, and D. K. Kim, "Power demand forecasting using long short-term memory (LSTM) deep-learning model for monitoring energy sustainability", *Sustainability*, Vol. 12, No. 3, 2020, pp. 1109, doi: <https://doi.org/10.3390/su12031109>.
13. A. L. Klingler and L. Teichtmann, "Impacts of a forecast-based operation strategy for grid-connected PV storage systems on profitability and the energy system", *Sol. Energy*, Vol. 158, 2017, pp. 861-868, doi: <https://doi.org/10.1016/j.solener.2017.10.052>.
14. C. Wan, J. Zhao, Y. Song, Z. Xu, J. Lin, and Z. Hu, "Photovoltaic and solar power forecasting for smart grid energy management", *CSEE J. Power and Energy Syst.*, Vol. 1, No. 4, 2015, pp. 38-46, doi: <https://doi.org/10.17775/CS EEJPES.2015.00046>.
15. Y. Zhang, T. Huang, and E. F. Bompard, "Big data analytics in smart grids: a review", *Energy Inf.*, Vol. 1, No. 1, 2018, pp. 1-24, doi: <https://doi.org/10.1186/s42162-018-0007-5>.
16. PJM, "Data Miner 2", PJM. Retrieved from <http://data-miner2.pjm.com/list>.
17. U. Bureau, "CPH-2-1, United States summary", 2012. Retrieved from <https://www.census.gov>.
18. A. Gasparin, S. Lukovic, and C. Alippi, "Deep learning for time series forecasting: the electric load case", *CAAI Trans. Intell. Technol.*, Vol. 7, No. 1, 2022, pp. 1-25, doi: <https://doi.org/10.1049/cit2.12060>.