

태양광 발전량 예측 인공지능 DNN-RNN 모델 비교분석

홍정조¹, 오용선^{2*}

¹목원대학교 정보통신융합공학부 박사과정, ²목원대학교 정보통신융합공학부 교수

Comparative Analysis of Solar Power Generation Prediction AI Model DNN-RNN

Jeong-Jo Hong¹, Yong-Sun Oh^{2*}

¹Ph.D. Student, Division of Information and Communication Convergence Engineering, Mokwon University

²Professor, Division of Information and Communication Convergence Engineering, Mokwon University

요약 지구 온난화의 주범인 온실가스 감축을 위해 UN은 1992년 기후변화협약을 체결하였다. 우리나라도 온실가스 감축을 위해 재생에너지 보급 확대 정책을 펼치고 있다. 태양에너지를 이용한 재생에너지 개발의 확대는 풍력과 태양광 발전의 확대로 이어졌다. 기상 상황에 영향을 많이 받는 재생에너지 개발의 확대는 전력계통의 수요공급관리에 어려움이 발생하고 있다. 이러한 문제를 해결하기 위해 전력중개시장을 도입하게 되었다. 따라서 전력중개시장 참여를 위해서는 발전량 예측이 필요하다. 본 논문에서는 자체 개발한 예측 시스템을 활용하여 연축태양광발전소에 대하여 분석하였다. 현장 일사량(모델 1)과 기상청 일사량(모델 2)을 적용한 결과 모델 2가 3% 정도 높은 것을 확인하였다. 또한, DNN과 RNN 모델을 비교 분석한 결과 DNN 모델이 예측 정확도가 1.72% 정도 향상되는 것을 확인하였다.

주제어 : 발전량 예측, 태양광 발전, 인공지능 모델, Data 품질관리, 일사량

Abstract In order to reduce greenhouse gases, the main culprit of global warming, the United Nations signed the Climate Change Convention in 1992. Korea is also pursuing a policy to expand the supply of renewable energy to reduce greenhouse gas emissions. The expansion of renewable energy development using solar power led to the expansion of wind power and solar power generation. The expansion of renewable energy development, which is greatly affected by weather conditions, is creating difficulties in managing the supply and demand of the power system. To solve this problem, the power brokerage market was introduced. Therefore, in order to participate in the power brokerage market, it is necessary to predict the amount of power generation. In this paper, the prediction system was used to analyze the Yonchuk solar power plant. As a result of applying solar insolation from on-site (Model 1) and the Korea Meteorological Administration (Model 2), it was confirmed that accuracy of Model 2 was 3% higher. As a result of comparative analysis of the DNN and RNN models, it was confirmed that the prediction accuracy of the DNN model improved by 1.72%.

Key Words : Power generation forecast, Solar power, AI model, Data quality management, Insolation

1. 서론

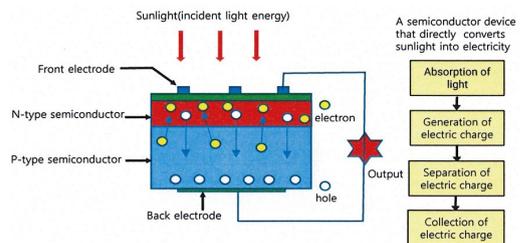
산업혁명 시기인 18~19세기에 제한 없이 사용된 화석연료로 인해 다량의 온실가스 배출이 지구의 평균온도를 약 1℃ 상승시켰다. 지구 온난화로 인한 가뭄, 폭염, 태풍, 해수면 상승 등의 자연재해로 인한 인적·물적 피해에 직면함에 따라 UN은 1992년 전 세계 196개 국가를 대상으로 온실가스 감축을 위한 기후변화협약을 체결하게 되었다[1]. 따라서 기후 변화에 영향을 많이 미치는 온실가스의 감축을 위해 태양에너지를 활용한 재생에너지의 보급 확대는 전 지구적인 의무가 되었다. 우리나라도 1997년 12월 신재생에너지관련 법을 제정하여 보급을 촉진한 결과 태양광의 경우 설비용량이 2014년 1.8GW에서 2021년 말 기준 19GW로 10.6배 증가하였다[2]. 또한, 기후변화대응을 위한 정부의 2050년 탄소제로 전략목표 달성을 위해 기상 영향이 큰 재생에너지 개발 확대가 필수적이며, 정부는 「제5차 신·재생에너지 기술개발 및 이용·보급 기본계획」에 의거 2034년 신재생에너지 발전비중 목표를 22.2%, 설비용량은 80.8GW로 확대할 목표를 정하고 보급에 박차를 가하고 있다 [3,4]. 이와같이 기후 영향이 큰 재생에너지의 보급 확대는 불규칙적인 전기에너지 생산으로 인해 우리나라 전력계통 운영의 수요공급관리에 많은 어려움이 발생하고 있다. 정부는 이러한 문제점을 해결하기 위해 재생에너지 발전량 예측제도를 2021.10월 「소규모전력중개거래시장」을 도입하게 되었다[5]. 본 논문에서는 기후 영향을 많이 받는 태양광 발전량 예측을 위해 발전소 인근 지역의 기상자료와 실측 일사량 및 발전량 data를 기반으로 발전량 예측을 위해 개발한 「재생에너지 발전량 예측 시스템」에 인공지능(AI) 모형 DNN(Deep Neural Network) 및 RNN(Recurrent Neural Network)에 학습시켜 태양광 발전량을 예측함으로써 기상 조건에 따른 발전량 예측의 인공지능(AI) 모형을 비교 분석하고자 한다.

2. 관련연구

2.1 태양광 발전 기술

태양광 발전시스템은 태양으로부터 빛에너지를 받아 직접 전기에너지로 변환하는 발전방식이다. 태양광을 직접 전기에너지로 변환하는 반도체 소자는 광을 흡수하면 전자가 생성하고, 다시 전자가 분리되어 전하를 수집하는 특성을 가지며, Fig. 1과 같이 태양의 빛(입사광에너

지)이 반도체 전면전극 표면에 비추어지면 광전효과에 의해 전극간에 전자는 N형 반도체 방향으로 정공은 P형 반도체 쪽으로 이동하게 되어 전류가 발생하고 전류가 흐르게 되므로 전기가 생성하게 된다. 광전효과는 1887년 독일의 물리학자 하인리히 루돌프 헤르츠가 발견했으며, 보통 금속 표면에 빛을 쬐었을 때 금속의 표면에서 전자가 튀어나오는 현상을 말한다[6]. 이러한 원리에 의해 광을 흡수하는 반도체 소자에 태양 빛을 받으면 전기가 생산된다. 여기서 태양광발전소에 설치되어 있는 태양광 모듈을 통해 생산되는 발전량의 산정은 해당 시간대별 일사량에 대한 태양전지 모듈의 출력으로 산정한다 [7,8].



[Fig. 1] Overview of solar power generation

2.2 태양광 발전 시스템의 발전량 산정

태양광 발전량 산정은 태양전지의 모듈 특성, 기상요소가 고려된 일사량의 시간대별 크기에 식(1)과 같이 태양광 설비용량, 일 평균 수평면 전 일사량, 온도보정계수, 수평면일사량 대비 경사면 일사량에 의거 태양광 모듈의 출력으로 산정된다. 여기에 일정 기간(365일)을 곱하면 연간발전량이 산정된다[9].

$$P = P_{PV} \times G \times \gamma \times \alpha \times h \quad (1)$$

여기서 P = 기상요소를 고려한 발전량[kWh]

P_{PV} = 태양광 설비용량[kW]

G = 일 평균 수평면 전 일사량[kWh/m²/h]

γ = 온도보정계수×기본보정계수

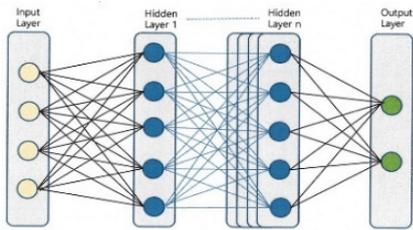
α = 수평면일사량 대비 경사면 일사량[%]

3. 태양광 발전량 예측

3.1 발전량 예측 모델

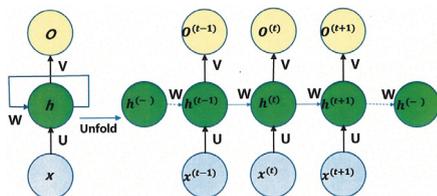
기후 변화에 영향을 미치는 온실가스 감축과 화석연료 고갈로 인한 전 지구적인 문제를 해결하기 위해 태양에너지를 이용한 태양광 발전 시스템의 설치가 날로 증가

하고 있다[10]. 태양광 발전 시스템의 증가는 전력계통 운용에 어려움을 가중시키고 있어 하루 전(D-1일) 시간 대별로 발전량이 어느 정도 되는지를 예측하는 것은 매우 중요한 과제가 되었다. 재생에너지 발전량 예측 시스템 중 여기서는 기상 영향이 많은 태양광 발전량에 대하여 예측하는 모형에 대하여 분석하였다. 태양광 발전량을 예측하는 모형에는 회귀분석 예측 모델, 인공지능(AI, Artificial Intelligence) 모델 등 다양하게 연구되고 있다[11]. 본 논문에서는 인공지능(AI, Artificial Intelligence) 모형중 데이터의 양이 많아지면 성능이 좋아지는 장점이 있는 DNN(Deep Neural Network, 심층신경망)과 반복적이고 순차적인 데이터 학습에 특화된 순환신경망인 RNN(Recurrent Neural Network)을 활용하여 예측하였다. DNN은 Fig. 2와 같이 입력층과 출력층 사이에 여러개의 은닉층들로 이루어진 인공 신경망이다. 심층신경망은 복잡한 비선형 관계를 모델링 할 수 있어 사물 식별 모형을 위한 심층신경망 구조에서의 예를 들면 각 객체가 이미지 기본요소들의 계층적 구성을 표현될 수 있어 사물 식별 능력을 보다 향상시킬 수 있다. 이러한 특징을 태양광 예측에 적용하면 단순하게 통계적 기법의 회귀식보다 더 효율적인 예측이 가능하다[12,13].



[Fig. 2] DNN model

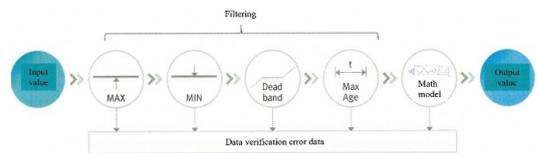
RNN은 Fig. 3과 같이 내부의 순환구조가 들어있는 특징으로 기존의 지속적이고 반복적이며, 순차적인 데이터 학습의 한계를 해결한 알고리즘으로 알려져 있다 [14,15].



[Fig. 3] RNN model

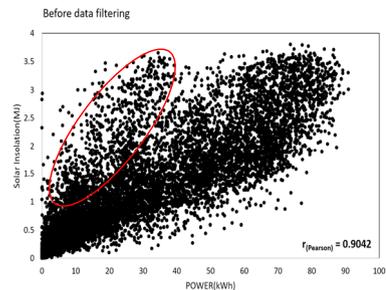
3.2 데이터 품질관리 프로세스

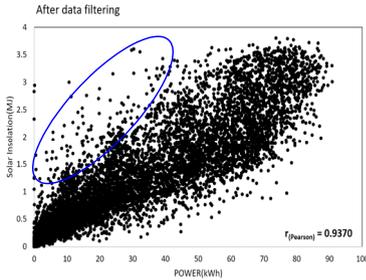
발전량 예측에 있어 무엇보다 중요한 것은 태양광 발전소의 과거 운영자료, 즉, 발전량, 온도, 일사량, 강우량 풍속 등의 운영자료가 DB에 저장되어있는 데이터의 품질이 좋지 않으면 데이터에 의한 발전량 예측은 부정확한 결과를 출력할 수밖에 없어 이로 인하여 예측의 정확도가 떨어지게 된다. 따라서 data 품질관리 방법으로 Fig. 4와 같이 MIN, MAX, Deadband, MaxAge의 필터링 기법을 활용하여 일사량, 발전량 등의 data를 필터링 검증을 하고, 수확모형(or 인공지능 모형)에 의하여 최종 검증하여 인공지능 학습 전에 최종 수정하여 적용하였다.



[Fig. 4] Data quality control processor

아래 Fig. 5는 DB에 저장되어있는 발전소 전력량과 일사량과의 상관관계를 나타내고 있으며, 품질관리 전에는 적색 실선부와 같이 중심점에서 많이 벗어난 자료들이 다수 분포되어있는 것을 알 수 있으며, 품질관리 후에는 청색 실선과 같이 중심선을 벗어난 자료들이 많이 제거된 것을 알 수 있다. 즉, 품질관리 전후 피어슨 값을 비교해본 결과 품질관리 전에는 피어슨 상관계수 $r_{(pearson)} = 0.9042$ 에서 품질관리 후에는 $r_{(pearson)} = 0.9370$ 으로 품질관리 전과 비교해 0.0328 정도 개선되었음을 알 수 있다.

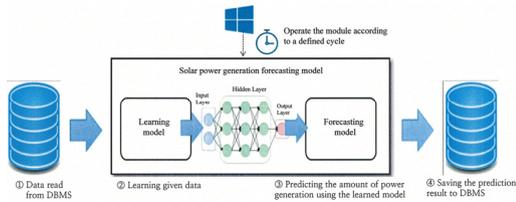




[Fig. 5] Comparison of solar radiation data before and after quality control (Yonchuk power plant)

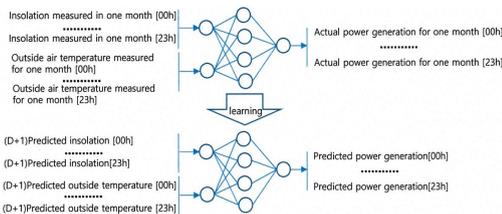
3.3 발전량 예측 프로세스

Fig. 6에서와같이 태양광 발전량 예측 프로세스는 사전에 정의된 시점에 ① DB에 저장되어있는 예측에 필요한 자료, 즉 예측 일사량, 발전실적 및 구름량 데이터를 읽어오는 단계 ② 주어진 데이터를 사전에 학습하는 단계 ③ 사전에 학습된 DNN, RNN 예측 모델을 통해 태양광 발전량을 1시간 단위로 예측하는 단계, ④ 마지막 단계로 예측 결과를 DB에 저장하고 활용하는 프로세스로 태양광 발전량을 예측하였다.



[Fig. 6] Solar power generation forecasting process

예측 모형은 Fig. 7에서와같이 연속발전소의 운영실적 자료인 예측일 기준 한 달 이전의 실측 일사량 및 외기온도, 실측 발전량 자료를 시간 단위로 분류하여 모형에 학습시킨 다음 D+1의 시간 단위 발전량을 예측하였다.



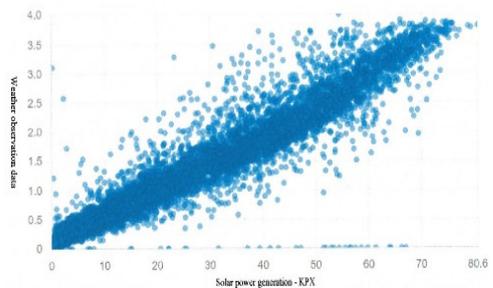
[Fig. 7] AI model applied to prediction of development

4. 발전량 예측 결과 검증

발전량 예측 시스템은 자체 개발한 “발전량 예측 및 전력증거거래시스템”을 활용하여 분석하였으며, 예측 모델은 Tensorflow 프로그램으로 DNN, RNN 기반으로 구축하였다. 발전량 예측 시스템의 구성은 데이터 연계 모듈, 데이터베이스 관리 시스템, 데이터 품질관리 모듈, 발전량 예측 모형, 입찰 및 정산 모듈, 관리/운영자 시스템으로 이루어져 있다. 이 시스템을 활용하여 비교하고자 하는 발전소의 실측 일사량과 기상청 관측장비를 통해 확보한 일사량을 모델에 학습시켜 예측 정확도를 비교하고, 인공지능 DNN 모델과 RNN 모델에 대하여도 예측 정확도를 비교하였다.

4.1 실측 및 기상청 관측장비 일사량 적용

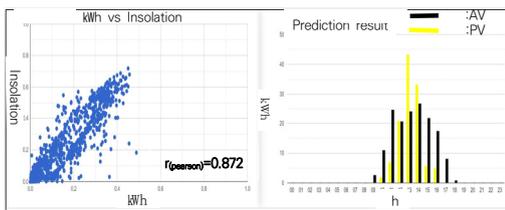
태양광 발전량 인공지능(AI, Artificial Intelligence) 예측 모델의 검증 대상 발전소는 학습데이터 이외의 외부요인으로 인한 간섭영향을 최소화할 수 있는 외기온도가 가장 일정하게 유지되는 것으로 파악된 대전의 연속태양광발전소에 대하여 현장에 설치된 일사량 계측값(모델 1)과 기상청 종관기상관측장비(ASOS, Automated Synoptic Observing System)의 일사량(모델 2)을 적용하여 비교 검증하였다. 여기서 종관기상관측장비는 기온, 습도, 강수량 등 날씨나 대기 현상과 관련된 자연현상들을 관측하도록 기상청에서 설치하여 운영하고 있는 장비를 일컫는다. Fig. 8은 대전의 연속태양광발전소에서 2019년~2020년 실측된 발전량과 일사량 자료로 일정하게 유지된 상관계수 관계를 보여 주고 있다.



[Fig. 8] Yonchuk power generation-insolation data ('19~'20)

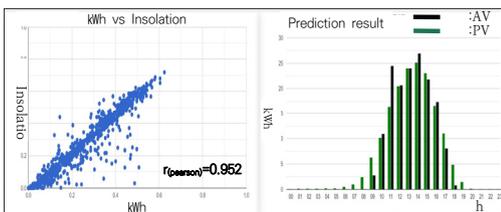
학습데이터는 2019년~2020년의 발전소별 시간당 발전량 및 일사량 계측값에 대하여 데이터 품질관리 후 25%를 DNN 학습을 위한 검증 데이터로 사용하였다.

Fig. 9, 10과 같이 학습데이터의 발전량 실적과 일사량 상관계수는 모델 1은 0.872, 모델 2는 0.952로 나타났다. 여기서 실제 AI 모델의 평가는 학습데이터와 완전히 분리된 한국기상과학원에서 제공하는 구름 따위의 영향이 없을 때 일사에 직각인 면에 입사하는 태양 복사와 구름 따위로 가려져 입사하는 태양 복사의 합인 전천일사량(SWDN, Downward short wave radiation)의 예보 중 2021년 4월 한 달(30일) 데이터를 활용하여 검증한 결과 모델 1은 검증 기간에 대해 예측값 대비 실제 발전소의 발전량 예측 정확도는 평균 89.0%로 나타났다.



[Fig. 9] Power generation prediction result of model 1

일사량 학습데이터를 발전소로부터 5.5km 거리에 설치된 기상청 관측소의 종관기상관측장비(ASOS, Automated Synoptic Observing System)의 자료를 학습시킨 모델 2의 경우 발전량 예측 정확도는 평균 92%를 나타내었다. 모델 1과 모델2를 비교한 결과 현장 일사량 계측값을 학습시킨 것보다 기상청 관측소의 일사량 데이터를 학습시킨 모델 2가 3% 정도 정확하게 예측함을 확인하였다.



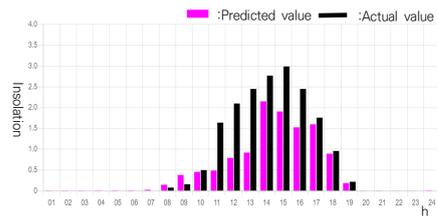
[Fig. 10] Power generation prediction result of model 2

4.2 DNN-RNN 예측 결과 비교

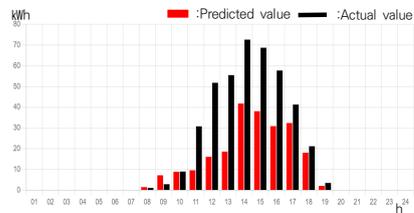
인공지능(AI) 모델 비교는 Fig. 8의 시간당 발전량과 기상청 종관기상관측장비(ASOS, Automated Synoptic Observing System)의 일사량을 데이터 품질관리 후 25%를 학습을 위해 검증 데이터로 사용하였으며, 일사량 상관계수 0.952로 높게 나타났다. AI 모델은 동일한 학습데이터에 대하여 DNN과 RNN 두가지 방법에 대하여 비교하였다. 실제 AI 모델의 평가에서 DNN 모델은

학습데이터와 완전히 분리된 한국기상과학원에서 제공하는 전천일사량(SWDN, Downward short wave radiation) 예보 중 2021년 4월 한 달분을 활용하였고, RNN 모델은 예보 시점의 최근 7일 전부터의 과거 자료와 일사량 예보자료를 연속으로 입력하였으며, 두 모델을 활용하여 예보 시점으로부터 익일(D+1) 매 시각 24시간분의 발전량을 예측하도록 구성하였다.

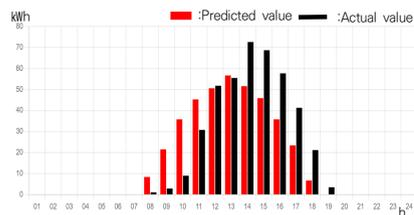
두 모델을 비교한 결과 DNN 모델은 검증 기간에 대해 실제 발전량 대비 예측의 정확도는 평균 89.21%였으며, 이에 비해 RNN 모델은 동일 기간에 대해 정확도가 87.49%를 나타내 1.72%의 차이를 확인하였다.



[Fig. 11] Insolation in rain



[Fig. 12] DNN model prediction results



[Fig. 13] RNN model prediction results

또한, RNN 모델에서는 맑은 날 분량의 과거 자료에서 나타나는 연속성을 과도하게 학습하여 Fig. 11, 12, 13과같이 시간대별로 일사량의 변화가 크게 나타나는 우천 시간대 등에는 익일(D+1)의 일사량 예측을 충분히 반영하지 못하는 경우가 발생함을 확인하였다.

5. 결론

인공지능 학습을 통한 발전량 예측은 기상요소의 데이터 품질이 결정적인 역할을 하는 것을 알 수 있었다. 실제 운영되고 있는 태양광발전소의 구내에 설치된 계측데이터의 품질이 확보되지 않으면 발전소로부터 이격되어 있는 기상청의 종관기상관측장비(ASOS, Automated Synoptic Observing System)의 관측데이터로 학습한 경우보다 예측 정확도가 낮게 나타났으며, 이를 통해 운영되고 있는 태양광발전소 외부의 관측소를 활용하여 발전량 예측이 가능함을 알 수 있었다.

또한, 일사량은 일반적으로 시계열 데이터로 분류하나, 기상 여건에 따라 단기간 내 현저한 변동을 나타낼 수 있어 태양광 발전량 예측을 위해서는 시각 정보가 완전히 배제된 DNN 모델이 RNN 모델보다 급격한 기상변화에 좀 더 정확한 예측이 가능할 수 있음을 확인하였다. 향후 발전소별 계측데이터 외 기상 데이터 활용과 국내 장기간 기후 변화와 D+1일의 급격한 기상변화를 적정 가중치로 반영 가능한 인공지능 모델을 선정하기 위한 추가 연구가 필요할 것으로 사료 된다.

REFERENCES

- [1] C. K. Lee, "In the era of carbon neutrality beyond greenhouse gas reduction, renewable energy is the answer", *K-Sure Insight*, 2021. <https://www.ksure.or.kr>.
- [2] D. H. Lee and K. H. Kim, "Deep Learning Based Prediction Method of Long-term Photovoltaic Power Generation Using Meteorological and Seasonal Information", *The Journal of Society for e-Business Studies*, Vol.24, No.1, pp.1-16, 2019. <https://doi.org/10.7838/jsebs.2019.24.1.001>
- [3] Renewable Energy Policy Division, "5th Renewable Energy Basic Plan (2020-2034)", 2020. <http://www.motie.go.kr>.
- [4] Y. T. Lee, D. H. Kim, W. S. Sin, C. K. Kim, H. G. Kim, S. W. Han, "A Comparison of Machine Learning Models in Photovoltaic Power Generation Forecasting", *Journal of the Korean Institute of Industrial Engineers*, Vol.47, No.5, pp.444-458, 2021. <https://doi.org/10.7232/JKIIIE.2021.47.5.444>.
- [5] S. H. Lee, "Domestic virtual power plant system and status", *Korea Development Bank Monthly Report*, Vol.767, No.10, pp.25-47, 2019.
- [6] Encyclopedia of Daum, "Photoelectric effect", <m.search.daum.net>
- [7] J. J. Song, Y. S. Jeong & S. H. Lee, "Analysis of prediction model for solar power generation", *Journal of Digital Convergence*, Vol.12, No.3, pp.243-248, 2014. <https://dx.doi.org/10.14400/JDC.2014.12.3.243>
- [8] J. powers and M. M. Ali, "Application of neural networks in aluminum corrosion", *Journal of the Korean Data & Information Science Society*, Vol.1, pp.157-172.
- [9] S. M. Lee, H. S. Jo, H. H. Lee, G. B. Lee, B. R. Oh & O. K. Kwon, "An Annual Photovoltaic Generation Estimation Considering Meteorological Elements", *KIEE Summer Conference 2018*, pp.875-876, 2018.
- [10] H. Lee, "Analysis of time series models for consumer price index", *Journal of the Korean Data & Information Science Society*, Vol.23, No.3, pp.535-542, 2012. <https://doi.org/10.7465/jkdi.2012.23.3.535>
- [11] H. S. Jeong, "Power Generation Prediction Model Considering Environmental Characteristics of the Floating Photovoltaic System", pp.37-39, 2021.
- [12] Etsys Ltd, "Power generation forecasting and system building service for small-scale power brokerage transactions", pp.9-10, 2021.
- [13] Y. M. Seo, B. J. Lee, Y. Y. Choi, "Machine Learning Model-based Photovoltaic Power Generation Forecasting Using Meteorological Data", *Journal of the Korean Society of Environmental Technology*, Vol.18, No.3, pp.242-251, 2017.
- [14] Y. S. Kim, S. H. Lee, H. W. Kim, "Prediction Method of Photovoltaic Power Generation Based on LSTM Using Weather Information", *Journal of the Korean Institute of Communications and Information Sciences*, Vol.44, No.12, pp.2231-2238, 2019. <https://doi.org/10.7840/kics.2019.44.12.2231>
- [15] J. Y. Seo, "Deep Learning with TensorFlow", pp.265-282, 2021.

홍 정 조(Jeong-Jo Hong)

[정회원]



- 1989년 2월 : 영남대학교 공과대학 전기공학과(공학사)
- 2008년 2월 : 충남대학교 대학원 전기공학과(공학석사)
- 1989년 1월 ~ 2021년 12월 : K-water 근무
- 2020년 3월 ~ 현재 : 목원대학교 정보통신융합공학부 IT공학과(박사과정), 한국컨텐츠학회 정회원.

<관심분야>

신재생에너지, 발전량 예측, 전력거래, 인공지능

오 용 선(Yong-Sun Oh)

[정회원]



- 1983년 2월 : 연세대학교 공과대학 전자공학과(공학사)
- 1985년 2월 : 연세대학교 대학원 전자공학과(공학석사)
- 1992년 2월 : 연세대학교 대학원 전자공학과(공학박사)
- 1984년 3월 ~ 1986년 7월 : 삼성 전자(주) 시스템개발실 연구원
- 1987년 1월 ~ 1988년 2월 : 3J TECH. INC. 선임연구원
- 1998년 9월 ~ 1999년 8월 : 한국해양대학교 객원교수
- 1988년 3월 ~ 현재 : 목원대 정보통신융합공학부 교수, 한국해양정보통신학회, 한국통신학회, 대한전자공학회 IEEE 정회원.

〈관심분야〉

디지털 커뮤니케이션 시스템, 정보이론, 멀티미디어 콘텐츠