
저자 (Authors)	유호성, 이용래, 김문겸 Ho-Sung Ryu, Yong-Rae Lee, Mun-Kyeom Kim
출처 (Source)	전기학회논문지 69(6) , 2020.6, 783-791(9 pages) The transactions of The Korean Institute of Electrical Engineers 69(6) , 2020.6, 783-791(9 pages)
발행처 (Publisher)	대한전기학회 The Korean Institute of Electrical Engineers
URL	http://www.dbpia.co.kr/journal/articleDetail?nodeId=NODE09349852
APA Style	유호성, 이용래, 김문겸 (2020). Local level 전력네트워크의 리스크 평가를 위한 LSTM을 활용한 재생에너지 발전량 예측 모델 개발. 전기학회논문지, 69(6), 783-791
이용정보 (Accessed)	중앙대학교 165.***.103.27 2020/07/09 15:15 (KST)

저작권 안내

DBpia에서 제공되는 모든 저작물의 저작권은 원저작자에게 있으며, 누리미디어는 각 저작물의 내용을 보증하거나 책임을 지지 않습니다. 그리고 DBpia에서 제공되는 저작물은 DBpia와 구독계약을 체결한 기관소속 이용자 혹은 해당 저작물의 개별 구매자가 비영리적으로만 이용할 수 있습니다. 그러므로 이에 위반하여 DBpia에서 제공되는 저작물을 복제, 전송 등의 방법으로 무단 이용하는 경우 관련 법령에 따라 민, 형사상의 책임을 질 수 있습니다.

Copyright Information

Copyright of all literary works provided by DBpia belongs to the copyright holder(s) and Nurimedia does not guarantee contents of the literary work or assume responsibility for the same. In addition, the literary works provided by DBpia may only be used by the users affiliated to the institutions which executed a subscription agreement with DBpia or the individual purchasers of the literary work(s) for non-commercial purposes. Therefore, any person who illegally uses the literary works provided by DBpia by means of reproduction or transmission shall assume civil and criminal responsibility according to applicable laws and regulations.

Predicting Renewable Energy Generation Using LSTM for Risk Assessment of Local Level Power Networks

Local level 전력네트워크의 리스크 평가를 위한 LSTM을 활용한 재생에너지 발전량 예측 모델 개발

Ho-Sung Ryu · Yong-Rae Lee · Mun-Kyeom Kim

유호성* · 이용래* · 김문겸†

Abstract

Low uncertainty is essential when operating the power system in a stable state. Recently, the uncertainty in the power systems has increased due to the growth of renewable energy. This paper proposes a method to reduce the uncertainty of the power systems including renewable energy by using Long Short-term Memory (LSTM) algorithm. Through repeated simulation, the optimal LSTM model of each renewable unit is created. probabilistic scenario is created by monte-carlo simulation and k-means clustering algorithm, and then we assess risk for each scenario through a test system created with reference to the actual system. To validate the superiority of the proposed method, the risk assessment are conducted through local level test system. The results demonstrate that the optimal LSTM model reduces the risk index compared to other predicted models.

Key Words

Long Short-Term Memory, Uncertainty Modeling, Renewable Power Forecasting, Local Level Network, Severity Risk Index

1. 서론

2015년 파리협정 이후 세계적으로 온실가스 저감을 위해 노력하고 있다. 특히 전력 분야는 세계 탄소배출량의 약 1/3 비중을 차지하고 있으며 이를 줄이기 위해 대대적인 발전믹스 변화를 계획하고 있다 [1]. 대한민국 역시 온실가스 저감을 위해 노력 중이며 최근 재생에너지 3020 이행계획 발표로 2030년까지 재생에너지를 전체 전력의 20%까지 확대하는 것을 목표로 하고 있다. 그중 신규설비의 97%를 변동성 재생에너지인 태양광과 풍력으로 공급할 예정이며 이에 따라 2030년에는 변동성 에너지가 차지하는 비율이 13.5%에 이를 것으로 전망되고 있다 [2]. 재생에너지는 기존 대규모 집중형 전원과 달리 소규모 전력 소비 부근에 분산하여 배치가 가능하므로 소규모 계통운영에 강한 이점이 있다. 특히 대한민국은 대도시의 에너지 자급률이 매우 저조하다. 서울의 경우 자급률이 2%에 불과하며 이는 대규모 발전설비 운영에 따른 환경, 안정상의 부담은 지방이 부담하고, 그에 따른 혜택은 대도시가 향유하는 불균형을 야기하게 된다. 분산전원의 장점을 살려 이러한 불균형을 해소한다면 장거리 송전에 의한 전력손실 및 송전 선로 설치비용 감소뿐만 아니라 지역 간의 갈등 완화에 기여할 수도 있다 [3].

하지만 일부 전문가들은 재생에너지의 보급 확대가 기존 전력시스템의 안정성을 떨어뜨릴 것이라는 우려를 제기하며 부정적인 입장이다 [4]. 실제로 미국에서는 재생에너지가 계통의 안정성에 부정적인 영향을 미칠 수 있다는 이유로 태양광 발전의 계통연계를 지연시킨 사례가 있다. 현재 대한민국은 변동성 재생에너지가 전체 전력 보급에 차지하는 비중이 적어 계통에 미치는 영향이 크지 않지만, 앞으로 환경에 대한 관심과 그에 따른 신재생에너지 보급 증가를 고려할 때 변동성 재생에너지가 계통에 어떠한 영향을 주는지 파악하고 이를 대비하기 위한 방안에 대한 연구는 필수적인 것이다.

태양광과 풍력 발전의 공통적인 특징은 기후요소에 영향을 많이 받는다는 것이다. 태양광 발전은 일사량과 기온, 풍력 발전의 경우 바람세기의 영향을 많이 받는다. 따라서 재생에너지의 변동성을 줄이기 위해서는 우선적으로 기후요소에 대한 정확한 예측이 필수적이다. 신재생에너지의 예측 효율을 높이기 위한 방법에 대한 연구는 활발히 진행 중이며 인공지능망 기술을 활용한 연구가 많은 비중을 차지하고 있다. 참고논문 [5]에서는 인공지능망을 활용하여 여름철 전력수요를 예측을 진행하였다. [6]은 심층신경망(Deep Neural Network, DNN)를 활용하여 태양광발전량 예측모델을 구성하였다. [7]은 머신러

† Corresponding Author : Dept. of Energy System Engineering, Chung-Ang University, Korea.
E-mail: mkim@cau.ac.kr
<https://orcid.org/0000-0002-0901-7816>

* Dept. of Energy System Engineering, Chung-Ang University, Korea.
<https://orcid.org/0000-0002-2046-6399>

Received : May 6, 2020 Revised : May 20, 2020 Accepted : May 25, 2020

Copyright © The Korean Institute of Electrical Engineers

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/4.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

닝기술을 활용하여 스마트 홈의 태양광 발전 예측 모델 생성을 다루고 있다. [8]은 요일 특성을 2차 함수로 변환하여 회귀 분석에 반영한 모델을 이용해 예측을 하는 방법을 제안한다. 한국 전력 거래소는 과거 전력 수요 패턴을 분석하여 기온과 전력 수요 상관관계를 분석하는 KSLF(KPX Short-term Load Forecaster)를 사용하고 있으며 전국적으로 수요를 예측하기 때문에 각 도시별 기온이 아닌 도시들의 평균 기온을 수요 예측에 활용하고 있다 [9]. 해외의 경우 PJM은 신경 회로망을 변형한 전력 패턴 모델을 활용하여 단기 전력 수요 예측에 활용하고 있으며, CAISO는 ARIMA 모델과 신경 회로망을 사용한 ALFS(Automated Load Forecasting System)을 활용하고 있다 [10]. 이처럼 여러 신경망을 통한 연구는 활발히 진행 중이며 해외의 여러 전력계통운영자들은 이미 실제로 인공지능망을 활용하여 예측기법으로 활용하고 있다.

본 논문에서는 기존 인공지능망 연구 중 가장 높은 평가를 받는 LSTM (Long Short-term Memory) 기술을 활용하여 반복된 시뮬레이션을 통해 각 신재생에너지의 발전량을 예측하는데 적합한 모델을 만들고 이를 활용하여 신재생에너지를 포함한 Local level 전력네트워크의 리스크 평가 방안을 제시한다. 실제 데이터를 활용하기 위해 2019년 기후데이터를 통해 LSTM 모델을 만들고 서울특별시 강서구의 계통을 바탕으로 모의계통을 만들어 리스크 평가를 진행한다.

본 논문은 2장에서 재생에너지의 불확실성 모델링, 3장에서 LSTM을 통한 기후요소 예측방법 제시, 4장에서는 확률적 리스크 평가를 진행하였고, 5장에서 사례연구를 통해, 6장 결론에서 연구의 필요성에 관해 설명한다.

2. 재생에너지의 불확실성 모델링

본 논문에서는 Local level 전력네트워크를 구성하는 요소들의 불확실성을 고려하기 위해 각 요소별 불확실성 모델링을 진행한다. 불확실성을 갖는 모델은 태양광 발전, 풍력 발전, 그리고 부하이며 각 모델의 특징에 따라 다른 확률분포를 적용하고자 한다 [11].

2.1 태양광 발전 모델링

태양광 발전의 출력은 태양의 일사량에 밀접한 영향을 받는다. 따라서 예측한 일사량에 따라 확률적으로 모델링 된다. 실제 일사량을 확률분포로 나타내면 베타 확률분포와 비슷하게 나타나며, 따라서 본 논문에서는 일사량을 베타 확률분포로 모델링한다.

$$PDF_{\beta}(si) = \frac{\Gamma(\alpha+\beta)}{\Gamma(\alpha)\Gamma(\beta)} \cdot si^{\alpha-1} \cdot (1-si)^{\beta-1} \quad (1)$$

$$\alpha = \frac{\mu_{si} \times \beta}{1 - \mu_{si}}, \quad \beta = (1 - \mu_{si}) \left(\frac{\mu_{si} \times (1 - \mu_{si})}{\sigma_{si}^2} - 1 \right) \quad (2)$$

여기서, Γ 는 감마 함수, si 는 예측 일사량, μ_{si} 는 실제 일사량

자료의 평균, σ_{si} 는 실제 일사량 자료의 표준편차 그리고 α 와 β 는 모양 결정 모수를 나타내며 각각의 식은 식(2)에 나타내었다.

태양광 발전의 출력은 일사량에 비례하며 태양광 패널의 물리적 특성에 따라 다르다. 태양광 출력에 대한 식은 다음과 같이 나타낸다.

$$P_{pv}(si) = \eta_{pv} \cdot A_{pv} \cdot si \quad (3)$$

여기서 η_{pv} 는 PV 패널의 효율, A_{pv} 는 PV 패널의 면적을 나타낸다.

2.2 풍력 발전 모델링

풍력 발전의 출력은 바람세기에 영향을 받으며 터빈을 동작시킬 수 있는 최소 바람세기와 터빈의 기계적 고장을 야기하는 것을 막기 위한 최대 바람세기를 터빈 특성에 따라 정해놓는다. 바람세기를 확률적으로 모델링 하는데 와이블 확률분포를 활용하였으며 아래와 같이 나타낸다.

$$PDF_w(v) = \left(\frac{k}{c} \right) \left(\frac{v}{c} \right)^{k-1} \exp \left[- \left(\frac{v}{c} \right)^k \right] \quad (4)$$

여기서, k 와 c 는 와이블 확률분포의 특성값, v 는 바람세기 예측값을 나타낸다.

바람세기에 따른 풍력터빈의 출력은 다음과 같다.

$$P_w(v) = \begin{cases} 0 & v_{wind} < v_{ci} \\ P_r \frac{(v_{wind} - v_{ci})}{(v_r - v_{ci})} & v_{ci} \leq v_{wind} < v_r \\ P_r & v_r \leq v_{wind} < v_{co} \\ 0 & v_{co} \leq v_{wind} \end{cases} \quad (5)$$

여기서, v_{ci} 는 최소 바람세기, v_r 는 정격 바람세기, v_{co} 는 최대 바람세기, P_r 는 터빈의 정격 출력을 의미한다.

2.3 부하 모델링

부하 역시 여러 예측 기법에 따라 예측할 수 있지만, 부하 소비자의 행동 변화에 따라 불확실성이 발생한다. 과거의 실제 값과 예측값의 편차에 따라 이러한 불확실성은 정규분포로 나타낼 수 있으며 식은 다음과 같다.

$$PDF_n(load) = \frac{1}{\sqrt{2\pi} \times \sigma_l} \exp \left(- \frac{(P_{load} - \mu_l)^2}{2\sigma_l^2} \right) \quad (6)$$

여기서, P_{load} 는 과거 실제 부하 값, μ_l 는 과거 부하 예측값, σ_l 는 예측값의 표준편차를 의미한다.

3. 장단기 기억을 고려한 신경망 (LSTM)

인공지능망이란 사람의 신경세포에서 얻은 통계적 학습 알고

리즘으로 예측 분석이 적용되는 다양한 산업 분야에서 활용되고 있다 [12]. 예측값이 결과값에 얼마만큼 영향을 미치는지에 따라 연결 강도가 다르게 설정되며 이를 통해 다른 예측 기법에 비해 비선형적이거나 왜곡된 입력에 대해서 특별한 전처리 없이 비교적 정확한 결과를 낼 수 있다는 장점이 있다. 하지만 인공신경망은 학습용 데이터의 양이 충분하지 않을 경우 정확한 모델링이 어려우며 필요 이상으로 많은 입력데이터가 사용될 시 수렴 속도가 늦어지거나 오히려 결과가 발산해버리는 상황이 발생할 수 있다. 인공신경망의 종류에는 다양한 종류가 있으며 대표적으로 심층신경망, 합성곱신경망(Convolutional Neural Network, CNN), 순환신경망(Recurrent Neural Network, RNN)등이 있다. 이 중에서 순환신경망은 연속적인 신호의 상관관계를 고려하여 미래를 예측하는데 영향을 미치며 이러한 특징으로 인해 시계열 자료를 분석하는데 대표적이다. 특히 순환신경망의 한 종류인 LSTM은 메모리의 가중을 달리하여 단기(short-term) 메모리와 장기(long-term) 메모리로 구분한다. 이를 통해 기존의 순환신경망의 기울기 소실 문제를 해결하여 대규모 신경망에서 더 효율적인 결과값을 산출한다. LSTM은 순환신경망에 은닉 스테이트(hidden state)에 셀 스테이트(cell state)를 추가한 구조이며 그림 1과 같은 차이가 있으며 그림에 보이는 LSTM의 은닉 스테이트 진행 과정은 다음과 같다 [13].




그림 1 RNN과 LSTM의 구조비교

Fig. 1 Structural comparison of RNN and LSTM

2.2 LSTM 모델링

LSTM 기법의 첫 번째 과정은 과거의 정보를 제거하는 과정으로 망각 게이트(forget gate)라고 한다. 망각 게이트는 시그모이드 함수를 사용하여 망각 정도에 따라 0부터 1 사이의 값을 출력하며 0은 과거의 데이터의 정보를 유지할 필요가 없다는 의미이며 1은 모든 정보를 유지해야 한다는 의미이다. 망각 게이트의 출력 값은 다음과 같다.

$$F_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (7)$$

여기서, F_t 는 망각 게이트 값, σ 는 시그모이드 활성화 함수, W_f 그리고 b_f 는 각각 곱 가중치와 합 가중치, x_t 는 입력 게이트 입력 값, h_{t-1} 는 이전 노드에서 넘어온 정보를 의미한다.

그다음 단계는 셀 스테이트에 저장할 새로운 정보를 결정하

는 단계이다. 두 가지 절차를 통해 이뤄지는데 먼저, 이전 노드에서 넘어온 정보가 두 번째 시그모이드 함수로 구성된 레이어를 통해서 입력 값으로 출력되고 그다음 하이퍼볼릭 탄젠트함수를 통해 새로운 후보 갱신 값을 출력한다.

$$I_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (8)$$

$$U_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (9)$$

여기서 I_t 는 입력 게이트 값, U_t 는 새로운 후보 갱신 값을 의미한다.

그 후 계산한 망각 게이트의 값과 이전 셀의 셀 스테이트 값을 곱한다. 그리고 입력 게이트 값과 새로운 후보 갱신 값을 곱하여 이를 더해 셀 스테이트를 업데이트한다.

$$C_t = F_t \cdot C_{t-1} + I_t \cdot U_t \quad (10)$$

여기서 C_t 는 t 셀의 셀 스테이트 값이다.

마지막으로 출력 게이트에서 마지막 시그모이드 함수로 구성된 레이어를 통해 셀 상태 정보를 다음 시점으로 전파하기 위한 정도를 결정한다. 그 후, 하이퍼볼릭 탄젠트함수를 통해 위에서 구한 셀 스테이트 값을 곱하여 나온 값을 출력 값과 곱하여 다음 노드에 전달하게 되며 식은 아래와 같다.

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (11)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (12)$$

여기서 o_t 는 출력 게이트 값, h_t 는 이번 노드의 정보이며 다음 노드에 전달하게 된다.

이 과정을 설정한 노드의 개수만큼 반복하게 된다.

3.2 LSTM을 통한 기후요소 예측

불확실성을 확률적으로 나타낼 때 각 요소의 예측값이 변수로 들어가는 만큼 예측값을 정확하게 예측하는 것이 불확실성 모델링하는데 중요하다. 따라서 본 논문에서는 예측값의 정확도를 높이기 위해 인공신경망 중 시계열 특성이 있는 자료 분석에 활용하는 LSTM을 이용한다. LSTM은 은닉 스테이트 수, 세대(epoch) 수, 학습률(learning rate), 모멘텀 값 (momentum value)의 설정값을 설정해야 한다. 여기서 은닉 스테이트 수는 LSTM 모델에 스테이트의 수가 몇 개인지, 세대 수는 LSTM의 기계학습 횟수, 학습률은 에러에 따른 다음 자료의 학습하는 정도, 그리고 모멘텀은 이전 결과에 따른 추세의 정도를 의미하며, 각 설정값은 어떠한 모델을 예측하느냐에 따라 최적값이 달라진다. 각 설정값의 최적값은 반복된 시뮬레이션을 통해 오차를 비교하며 설정해야 한다. 본 연구에서는 일사량과 바람세기를 예측하는데 최적의 LSTM 모델을 만들기 위해 최적화 과정을 진행하였고 그 과정은 다음과 같다.

1. 입력 데이터 가져오기 : 기후예측을 위해 필요한 과거 기후 데이터를 가져온다.
2. 데이터 분류하기 : 가져온 데이터 중 LSTM 모델을 만드는데 사용할 데이터와 사용하지 않을 데이터로 구분한다.
3. 데이터 표준화하기 : 데이터가 시간 데이터이므로 열이 24개(일별 데이터로 구분)인 행렬로 변환한 후 스케일 함수를 이용하여 데이터를 0~1 사이의 값으로 표준화한다. 표준화식은 다음과 같다.

$$y' = \frac{y - y_{\min}}{y_{\max} - y_{\min}} \quad (13)$$

4. 학습 데이터와 테스트 데이터로 구분 : 분류한 데이터를 지도학습을 통해 예측모델을 만들 학습 데이터와 만들어진 예측모델의 성능을 테스트할 테스트 데이터로 구분한다.
5. LSTM 모델 설정 : LSTM 모델을 구성하는 은닉 스테이트 수, 세대 수, 학습률, 모멘텀 값을 설정한다.
6. 지도학습을 통한 LSTM 모델 만들기 : 학습 데이터를 통해 지도학습을 이용하여 LSTM 예측모델을 만든다.
7. 테스트 데이터를 활용한 결과 확인 : 테스트 데이터를 만들어진 모델에 입력하여 실제 출력값과 예측값의 비교를 통한 결과를 확인한다.
8. 결과가 만족스러운가?

yes : 예측값 산출, no : 결과에 따라 LSTM 모델의 재설정




그림 2 LSTM 최적 모델 선정 과정

Fig. 2 The structure for finding optimal LSTM model

4. 확률적 리스크 평가

4.1 확률적 시나리오 생성

기후변화에 따른 Local level 전력시스템의 리스크 분석을 위하여 불확실성에 따른 시나리오를 생성한다. 시나리오 생성과정은 난수를 통해 시나리오를 생성하는 몬테카를로 시뮬레이션을 통해 1000개의 시나리오를 생성한 뒤, 원활한 시뮬레이션을 위해 K-means 클러스터링 기법을 통해 10개의 대표 시나리오를 산출하였다. 몬테카를로 시뮬레이션 과정은 다음과 같다.

4.1.1 몬테카를로 시뮬레이션

몬테카를로 시뮬레이션은 무작위 추출된 난수를 이용하여 미래를 예측하는 시나리오 생성에 널리 사용된다 [14]. 주어진 문제에 적합한 확률분포를 적용하여 해당 확률분포를 따르는 난수를 생성한다. 본 연구에서는 불확실성 요소로 풍력, 태양광, 부하량을 사용했으며, 각각 와이بل 분포, 베타 분포, 정규 분포를 활용하여 난수를 생성하였다. 몬테카를로 시뮬레이션을 통한 시나리오 생성은 다음과 같다.

$$\phi_L^n = (L^n, \psi_L^n), \quad \sum_1^n \psi_L^n = 1 \quad (14)$$

$$\phi_{WT}^n = (WT^n, \psi_{WT}^n), \quad \sum_1^n \psi_{WT}^n = 1 \quad (15)$$

$$\phi_{PV}^n = (PV^n, \psi_{PV}^n), \quad \sum_1^n \psi_{PV}^n = 1 \quad (16)$$

$$S^n = (\phi_L^n, \phi_{WT}^n, \phi_{PV}^n), \quad \sum_1^n \psi_L^n \times \psi_{WT}^n \times \psi_{PV}^n = 1 \quad (17)$$

여기서, L^n, WT^n, PV^n 는 각각 n번째 시나리오의 부하량, 풍력 발전량, 태양광 발전량을 의미하며 $\psi_L, \psi_{WT}, \psi_{PV}$ 는 각각의 확률을 의미한다.

식(14)-(16)을 통해 각각 부하, 풍력, 태양광의 발전량과 확률의 시나리오를 생성한 후 식(17)을 통해 통합 시나리오를 모델링한다.

4.1.2 k-means 클러스터링 기법

k-means 클러스터링 기법은 표본이 많은 집단을 비슷한 공통점이 있는 그룹으로 군집화하는 방법이다 [15]. 식(18)을 통해 그룹 간의 거리가 최소가 되도록 군집화하고 그 군집의 대표값을 뽑아낸다.

$$\arg \min_S \sum_{i=1}^k \sum_{x \in S_i} \|x - \mu_i\|^2, S_{k-means} = \{S_1, S_2, \dots, S_k\} \quad (18)$$

여기서, $S_{k-means}$ 는 k-means 클러스터링을 통해 나뉜 그룹들이며, μ_i 는 S_i 그룹의 평균값을 의미한다.

4.2 리스크 평가 지수

SRI(Severity Risk Index)는 현재 전력네트워크의 리스크를 평가할 때 많이 사용되고 있다 [16]. 이는 전력계통의 송전망과 발전기 고장에 따른 부하 차단량을 기반으로 전력계통의 스트레스를 계산하여 전력계통의 리스크를 평가하는 지수이다. 본 논문은 이 SRI 지수에 Local level 전력네트워크의 신재생에너지 영향을 추가하여 L-SRI (Local level SRI)를 개발하여 리스크를 평가하며, L-SRI 계산식은 다음과 같다.

$$L-SRI = [0.6MW_L + 0.3N_T + 0.08N_G + 0.02N_R] \times 1,000 \quad (19)$$

여기서, MM_L : 부하차단비율 = $\frac{\text{부하차단량}[MW]}{\text{총 부하량}[MW]}$

N_T : 송전선로 차단용량비율 = $\frac{\text{송전선로 차단용량}[MVA]}{\text{총 송전선로용량}[MVA]}$

N_G : 발전기 탈락용량비율 = $\frac{\text{탈락발전기용량}[MW]}{\text{총 발전기용량}[MW]}$

N_R : 신재생 발전기 발전오차

N_R 은 기존 SRI에 새로 적용한 요소로서, 신재생 발전량의 오차 또한 계통의 리스크를 평가하는 지표이므로 신재생에너지 예측 발전량 오차를 수치화해서 나타낸 것이다.

5. 사례 연구

본 논문은 Local level 네트워크 운영 리스크를 줄이기 위하여 각 신재생에너지 발전량 예측에 최적화된 LSTM 모델 개발을 제시하고자 한다. 예측에 사용한 데이터는 2019년 서울특별시의 시간별 기후데이터를 사용했으며 학습 데이터는 예측 데이터 이전의 30일(720시간) 테스트 데이터는 7일(168시간)을 사용한다. 학습 데이터 중 20일은 예측모델을 만들고 10일은 예측모델의 성능을 검사와 피드백하는 강화학습 데이터로 사용된다. 예측 결과가 실제 리스크 평가 지수에 미치는 영향을 알아보기 위해 다른 예측 기법을 사용했을 때와 SRI를 비교하여 나타낸다. SRI를 측정할 Local level 전력네트워크로 서울특별시 내 강서구의 계통을 바탕으로 모의 계통을 만들었으며 신재생에너지의 비중은 2030년 목표에 맞게 전체 발전량의 20%를 차지하도록 계통을 수정하였다. 그림 3은 모의 계통의 계통도를 나타내며, 평균 부하, 태양광 발전량, 그리고 풍력 발전량은 각각 231.69MW, 30.90MW, 그리고 15.44MW이다. 최적 LSTM 모델 개발을 위해서 R프로그램(3.5.2 version)을




그림 3 Local level 모의 계통
Fig. 3 Local level test system

활용했으며 SRI 계산을 위한 계통의 조류계산은 PSS/E (33 version)을 활용한다.

5.1 최적 LSTM 모델 개발

5.1.1 LSTM을 통한 바람세기 예측모델

첫 번째 시뮬레이션은 기본적으로 설정되어있는 LSTM 모델로 시뮬레이션하며, 결과를 바탕으로 모델을 수정하여 시뮬레이션을 반복 진행한다. 우선 바람세기 예측을 수행하였으며, 설정값은 표 1과 같고 결과는 그림 4와 같다. 예측 모형의 error 값이 매우 크며 세대 수가 300 이상이 되면서 오히려 error 값이 발산하는 불안정한 상태를 보인다. 테스트 데이터와의 오차 또한 16.4%로 매우 높게 나타난다. 이는 학습률과 모멘텀 값이 크게 설정되어 이전 시간의 결과가 다음 시간에 영향을 크게 주어 나타나는 모습이며 따라서 다음 값을 조정하여 다음 시뮬레이션을 진행한다.

표 1 바람세기 첫 번째 시뮬레이션 LSTM 설정 값

Table 1 The LSTM parameter for first simulation

	은닉 스테이트 수	세대 수	학습률	모멘텀
설정 값	20	500	0.2	0.8





그림 4 바람세기 첫 번째 시뮬레이션 결과 (a) 실제 값과 예측값, (b) 모델 오차값

Fig. 4 The first simulation results of wind speed (a) actual and predicted value, (b) simulation error


첫 번째 시뮬레이션 결과를 토대로 학습률과 모멘텀 값을 수정하여 두 번째 시뮬레이션을 진행하며 두 번째 시뮬레이션의 설정값은 표 2와 같고 결과는 그림 5와 같다. 모델의 예측률이 이전 시뮬레이션보다 잘 나타나며 테스트 데이터의 오차

또한 7.2%로 많이 향상된 모습을 보인다. 하지만 초기 세대의 모델 오차 값이 크며 수렴속도가 느린 모습을 보인다. 수렴속도가 빠르고 예측률 또한 더 향상된 LSTM 모델을 만들기 위하여 기계학습을 더 시키기 위한 세대 수와 은닉 스테이트의 개수를 증가시켜 다음 시뮬레이션을 진행한다.


표 2 바람세기 두 번째 시뮬레이션 LSTM 설정 값

Table 2 The LSTM parameter for second simulation

	은닉 스테이트 수	세대 수	학습률	모멘텀
설정 값	20	500	0.1	0.6



(a)



(b)

그림 5 바람세기 두 번째 시뮬레이션 결과 (a) 실제 값과 예측값, (b) 모델 오차값


Fig. 5 The second simulation results of wind speed (a) actual and predicted value, (b) simulation error

두 번째 시뮬레이션 결과를 바탕으로 세대 수와 은닉 스테이트 수를 수정하여 세 번째 시뮬레이션을 진행한다. 시뮬레이션의 설정값은 표 3과 같으며 그 결과는 그림 6와 같다. 은닉 층수 증가로 인해 초기 수렴률이 향상되며 세대 수가 증가할수록 모델의 오차 값이 안정된 모습을 보인다. 테스트 데이터 오차 역시 5.6%로 지금까지 모델 중 가장 좋은 모습을 나타낸다.


표 3 바람세기 세 번째 시뮬레이션 LSTM 설정 값

Table 3 The LSTM parameter for third simulation

	은닉 스테이트 수	세대 수	학습률	모멘텀
설정 값	20	500	0.2	0.8



(a)



(b)

그림 6 바람세기 세 번째 시뮬레이션 결과 (a) 실제 값과 예측값, (b) 모델 오차값

Fig. 6 The third simulation results of wind speed (a) actual and predicted value, (b) simulation error

이후 설정값을 변화시켜 시뮬레이션해본 결과 세대 수의 과도한 증가가 오히려 발산을 발생시키거나 시뮬레이션 시간을 과도하게 증가시켜버리는 문제가 발생했다. 따라서 세 번째 시뮬레이션의 결과가 예측모델로서 충분히 활용 가능하다고 판단하여 바람세기 예측모델로 선정한다. LSTM을 활용한 바람세기 예측 시뮬레이션 결과를 정리해보면 표 4와 같다.

표 4 시뮬레이션 별 LSTM을 이용한 바람세기 예측 결과

Table 4 The results of prediction wind speed each simulation

	S 1	S 2	S 3
은닉 스테이트 수	20	20	30
세대 수	500	500	750
학습률	0.2	0.1	0.1
모멘텀 값	0.8	0.6	0.6
테스트 데이터 오차	16.4	7.2	5.6

5.1.2 LSTM을 통한 일사량 예측모델

일사량의 경우 바람세기보다 시계열의 특징이 뚜렷하여 규칙성 있는 패턴을 보인다. 그래서 LSTM을 통한 예측률이 더 높게 나타났으며 여러 시뮬레이션 설정값과 결과는 표 5에 나타내었다. 시뮬레이션 1은 모델 오차 값이 초기에 수렴하지 못하여 모멘텀 값과 학습률을 감소시켜 다음 시뮬레이션을 진행하였으며 다음 시뮬레이션 결과 수렴을 잘하고 예측 오차 또한 낮게 나타났다. 시뮬레이션 속도 및 성능을 향상시키기 위해 세대 수를 변경하여 3번째, 4번째 시뮬레이션을 진행하

였고 그 결과 충분히 학습되지 않아 예측 오차 값이 커지거나 예측 오차는 비슷하지만, 시뮬레이션 시간이 증가하는 결과를 보였다. 따라서 두 번째 시뮬레이션 결과가 예측모델로서 충분하다고 판단하여 일사량의 예측모델로 선정하였다. 두 번째 시뮬레이션의 결과는 그림 7과 같다.




그림 7 일사량 두 번째 시뮬레이션 결과 (a) 실제 값과 예측값, (b) 모델 오차값
Fig. 7 The second simulation results of solar irradiance (a) actual and predicted value, (b) simulation error

표 5 시뮬레이션 별 LSTM을 이용한 일사량 예측 결과

Table 5 The results of prediction solar irradiance each simulation

	S 1	S 2	S 3	S 4
은닉 스테이트 수	30	30	30	30
세대 수	750	750	300	1000
학습률	0.1	0.05	0.05	0.05
모멘텀 값	0.8	0.3	0.3	0.3
테스트 데이터 오차	2.6	2.3	3.8	2.4

5.2 시나리오 생성 및 군집

앞의 시뮬레이션 결과를 바탕으로 식(14)-(17)을 활용하여 시나리오 1000개를 생성했다. 태양광과 풍력의 정격용량은 모의 계통에 적합하게 각각 40MW, 30MW이고, 부하의 오차는 평균적으로 4%라고 설정했다. 그림 8은 몬테카를로 시뮬레이션으로 시나리오를 생성한 후 k-means 클러스터링 기법으로 10개의 그룹으로 군집화한 것을 나타내며, 10개의 군집화 된 시나리오는 표 6과 같다. 풍력 발전량의 예측값이 가장 표준편차가 크게 나타났으며 최대 예측 발전량보다 73% 감소하는 경우도 발생하는 것으로 보인다.




그림 8 시나리오 생성 및 군집 결과
Fig. 8 The results of scenarios generation and clustering

표 6 k-means 클러스터링을 통해 생성된 군집 시나리오

Table 6 Scenarios created by k-means clustering techniques

Cluster means:	Wind	PV	Load
sc1	14.73MW	29.68MW	231.99MW
sc2	18.43MW	35.76MW	228.24MW
sc3	10.14MW	36.56MW	230.31MW
sc4	4.06MW	34.84MW	228.40MW
sc5	18.33MW	25.16MW	235.70MW
sc6	19.97MW	34.68MW	231.15MW
sc7	13.04MW	31.56MW	227.95MW
sc8	9.81MW	24.64MW	234.92MW
sc9	7.11MW	23.68MW	237.78MW
sc10	26.01MW	22.48MW	235.24MW

5.3 시나리오 별 리스크 평가

표 7은 시나리오별 L-SRI를 측정하여 나타낸 결과이다. 시나리오 8, 9의 경우 두 신재생 발전기의 출력 저하로 인해 부하 차단이 발생하여 L-SRI 값이 각각 16.87, 29.68로 높게 나타난다. 이는 리스크를 예측하지 않고 대응하지 않는다면 순간 정전과 같은 사고가 발생한다는 것을 의미한다.

표 7 각 시나리오별 L-SRI 측정 결과

Table 7 The results of L-SRI for each scenario

scenario	sc1	sc2	sc3	sc4	sc5
WT error(%)	-4.6	19.4	34.3	-80.2	18.8
PV error(%)	-4.0	15.7	-18.3	12.8	-18.5
MW_L	0	0	0	0	0
L- SRI	0.8	0	2.28	5.4	2.5
scenario	sc6	sc7	sc8	sc9	sc10
WT error(%)	29.3	-15.5	-49.3	-53.9	68.4
PV error(%)	-2.2	2.1	-20.2	-23.3	-27.2
MW_L	0	0	0.01	0.04	0
L- SRI	0.29	1.04	16.9	29.7	3.6

표 8은 가장 보편적으로 예측 분석에 활용하는 회귀 분석과 ARIMA 모형을 사용하여 각 기후요소 오차량을 나타냈으며

이를 통해 L-SRI를 계산한 값을 나타냈다. 회귀 분석의 경우 시계열 영향이 적은 바람세기를 예측할 때 오차가 크게 나타났으며 L-SRI 값 역시 14.80으로 크게 나타났다. ARIMA 모형은 회귀 분석보다는 좋은 결과를 나타냈지만, L-SRI 값은 LSTM 모델보다 월등히 큰 11.83으로 나타났다. 이는 LSTM을 활용한 예측방법이 높은 예측률을 보였으며 이를 통해 계통을 운영하였을 때 리스크의 영향이 가장 적게 나타난 것으로 보인다. 이는 계통운영자가 신재생에너지에 대한 ESS나 수요자원 같은 유연성 에너지자원을 설치하거나 예비력을 산정할 때 더 효율적으로 의사결정을 할 수 있음을 나타낸다.

표 8 다른 예측 기법들과 제한한 방법의 결과 비교

Table 8 Comparison the results with other predicted methods

	회귀 분석	ARIMA 모형	LSTM 모델
바람세기 오차	11.2	8.6	5.6
일사량 오차	3.5	3.2	2.3
L- SRI	14.80	11.83	6.25

6. 결 론

최근 세계적으로 온실가스 감축 및 환경에 관한 관심이 높아지면서 전력산업에서도 신재생에너지의 보급 확대를 추진 중이다. 신재생에너지는 친환경적이라는 장점이 있지만, 기후 요소에 많은 영향을 받고 출력이 불안정하여 계통의 신뢰도를 떨어뜨리고 안정성을 저해시키는 요인으로 작용할 수 있다. 하지만 이러한 변동성을 미리 파악하고 이에 맞는 유연성 에너지를 미리 확보해 놓는다면 계통의 신뢰도를 유지하며 신재생에너지를 운영할 수 있을 것이다. 따라서 신재생에너지의 변동성이 어느 정도인지 정확하게 파악하는 것이 중요하며 이를 통해 유연성 에너지원의 설치비용을 감축시킬 수 있다.

본 논문에서는 신재생에너지원의 출력을 예측하기 위하여 인공신경망 중 시계열분석에 적합한 RNN의 진보된 기술인 LSTM을 활용하였다. 반복된 시뮬레이션을 통해 신재생에너지원에 영향을 미치는 각 기후요소에 적합한 LSTM 모델을 설정하였으며, 그 결과 바람세기와 일사량을 예측하는데 설정된 LSTM 모델값은 다르게 나타났고 각각 5.6%, 2.3%의 준수한 오차율을 보였다. 시나리오 생성 및 군집 과정을 통해 10개의 군집 시나리오를 생성했으며, 신재생에너지가 포함된 Local level 전력네트워크의 리스크 평가를 위해 SRI에 신재생에너지를 접목한 L-SRI 지수를 개발했다. 각 시나리오별 L-SRI를 평가하였고 그 결과 평균 6.25의 값을 보였다. 이는 회귀 분석과 ARIMA 분석의 결과보다 월등히 좋은 모습을 보였으며 이처럼 LSTM 모델을 사용하여 계통을 운영하였을 때 리스크의 영향이 가장 적은 것으로 판단된다.

따라서 본 논문에서 제한한 LSTM을 활용하여 시뮬레이션을 통해 각 지역에 맞는 모델을 만들고 이를 반복 학습시켜 예측률을 높인다면, 계통운영자는 리스크를 대응하기 위하여

유연성 에너지를 설치할 때 보다 효율적인 용량으로 리스크를 대응할 수 있을 것이다.

본 논문에서는 신재생에너지의 발전량 예측에 따른 계통의 리스크 평가를 진행했으며 이에 따른 경제적 평가는 고려하지 않았다. 향후 이번 시뮬레이션을 바탕으로 변동성 에너지의 최적 설치 용량 산정이나 계통운영의 경제성 분석에 관한 연구가 필요하다.

Acknowledgements

본 연구는 2020년도 한국연구재단(2020R1A2C1004743)의 지원과 2019년도 한국전력공사(R19X001-37)의 지원에 의하여 이루어진 연구로서, 관계부처에 감사드립니다.

References

- [1] X. Wang, Y. Yu, and L. Lin, "Tweeting the United Nations Climate Change Conference in Paris (COP21): An analysis of a social network and factors determining the network influence," *Online Social Networks and Media*, vol. 15, 2020.
- [2] H. T. Kim and S. S. Jhang, "Key Technologies for Stabilization of Power System for Successful Achievement of 3020 Renewable Energy Policy," *KIEE*, vol. 67, no. 2, pp. 144-157, 2018.
- [3] C. Zhang, X. Zhao, M. Shahidehpour, W. Li, L. Wen, and Z. Yang, "Reliability Assessment of Coordinated Urban Transportation and Power Distribution Systems Considering the Impact of Charging Lots," *IEEE*, vol. 8, pp. 30536-30547, Feb. 2020.
- [4] V. Khare, S. Nema, and P. Baredar "Reliability analysis of hybrid renewable energy system by fault tree analysis," *Energy & Environmental*, vol. 30, pp. 542-555, May 2019.
- [5] K. H. Kim, R. J. Park, S. W. Jo, and K. B. Song, "24-Hour Load Forecasting Algorithm Using Artificial Neural Network in Summer Weekdays," *Journal of the Korean Institute of Illuminating and Electrical Installation Engineers*, vol. 31, no. 12, pp. 13-19, 2017.
- [6] S. Y. Park, J. H. Bang, I. H. Ryu, and T. H. Kim, "The Prediction of Photovoltaic Power Using Regression Models Based on Weather Big-data and Sensing Data," *KIEE*, vol. 68, no. 12, pp. 1662-1668, 2019.
- [7] N. Sharma, P. Sharma, D. Irwin, and P. Shenoy, "Predicting Solar Generation from Weather Forecasts Using Machine Learning," in *Proc. of 2011 IEEE International Conference on Smart Grid Communications (Smart-GridComm)*, IEEE, pp. 528-533, 2011.
- [8] J. Han and J. Baek, "The Load Forecasting in Summer Considering Day Factor," *The Transactions of KAIS*, vol. 1, no. 8, p. 2793-280, 2010.
- [9] D. Kim, H. J. Jo, M. S. Kim, J. H. Roh, and J. B. Park, "Short-Term Load Forecasting Based on Deep Learning

- Model,” KIEE, vol. 68, no. 9, pp. 1094-1099, 2019
- [10] H. S. Tak, T. Y. Kim, H. G. Cho, and H. J. Kim, “A New Prediction Model for Power Consumption with Local Weather Information,” Journal of The Korea Contents Association, vol. 16, no. 11, pp. 488-498, Nov. 2016.
- [11] K. H. Jo and M. K. Kim, “Stochastic Unit Commitment Based on Multi-Scenario Tree Method Considering Uncertainty,” Energies, vol.11, no. 740, Mar. 2018.
- [12] I. N. Silva, D. H. Spatti, and R. A. Flauzino, Artificial Neural Networks, Springer, 2017.
- [13] K. Greff, R. K. Srivastava, J. Koutnik, B. R. Steunebrink, and J. Schmidhuber, “LSTM: A Search Space Odyssey,” IEEE, vol. 28, no. 10, Jul. 2016.
- [14] S. Youli and K. Nagasaka, “Monte Carlo Simulation Method Used in Reliability Evaluation of a Laboratory-based Micro Grid,” IEEE, Jan. 2010.
- [15] K. Krishna and M. N. Murty, “Genetic K-means algorithm,” IEEE, vol. 29, no. 3, Jun. 1999.
- [16] D. N. Trakas, N. D. Hatziaargyriou, M. Panteli, and P. Mancarella, “A severity risk index for high impact low probability events in transmission systems due to extreme weather,” IEEE, Feb. 2017.

저자소개



유호성 (Ho-Sung Ryu)

2019년 중앙대학교 에너지시스템공학부 졸업.
2019년~현재 동 대학원 에너지시스템공학과 석사 과정.



이용래 (Yong-Rae Lee)

2019년 중앙대학교 에너지시스템공학부 졸업.
2019년~현재 동 대학원 에너지시스템공학과 석사 과정.



김문겸 (Mun-Kyeom Kim)

2004년 고려대학교 전기전자전파공학부 졸업.
2006년 서울대학교 대학원 전기컴퓨터공학부 졸업 (석사).
2010년 동대학원 전기컴퓨터공학부 졸업(공학).
2011년~2014년 동아대학교 전기공학과 조교수.
2014년~2016년 중앙대학교 에너지시스템공학부 조교수.
2017년~현재 중앙대학교 에너지시스템공학부 부교수.