

인공신경망에 기반한 제주시 신재생 에너지 발전량 예측 모델

강민주**, 변세정*, 김지환*, 이정훈*

*제주대학교 전산통계학과

**제주대학교 컴퓨터교육과

red.jade@icloud.com, {rha4578,2631hwan}@gmail.com, jhlee@jejunuac.kr

A forecast model of renewable energy generation based on artificial neural networks in Jeju city

Minju Kang**, Sejung Byun*, Jihwan Kim*, Junghoon Lee*

*Dept. of Computer Science and Statistics, Jeju National University

**Dept. of Computer Education, Jeju National University

요 약

본 논문은 신재생에너지와 전기자동차의 보급이 활발한 제주에서 태양광 발전량과 기후변화 기록들을 활용할 수 있는 데이터처리 프레임워크를 구축하고 인공신경망으로 태양광 발전량 예측모델을 구축한다. 이 인공신경망 모델은 일조시간, 일사량, 전운량 등을 입력 노드로 설정하고 일별 생산량을 출력 노드로 설정한다. 가장 상관관계가 높은 발전기 3개에서 학습 패턴을 추출하였으며, 모든 대상 발전기에 대해 최대 평균 오류율은 평균 36.7 %를 보이고 있다.

1. 서론

최근 기존의 전력망에 컴퓨터의 지능을 더한 스마트 그리드가 발전됨에 따라 태양광과 같은 신재생 에너지가 전력 시스템에서 조금씩 점유율을 높여가고 있다 [1]. 집중형 관리 시스템에 의해 효율적이고 계획적으로 에너지를 생산할 수 있는 원자력에너지와는 달리 신재생 에너지 발전은 기후 상황에 민감하게 영향을 받을 수밖에 없다. 따라서 실시간으로 급변하는 에너지 수요에 즉각적으로 반응하여 생산량을 조절할 수 없다. 그러나 신재생 에너지 발전량에 대해 정확하게 예측할 수 있다면 이 에너지는 좀더 지능적으로 소비될 수 있다. 예측모델 구축에 있어서 가능하면 많은 양의 과거 이력 분석이 필요한데, 지역적인 영향을 많이 받기 때문에 특정 지역에서 생성된 데이터들을 모델 학습에 사용하여야 한다.

본 논문은 2018년 제주지역의 177개 태양광 발전기로부터 수집된 발전량 이력과 기상청에서 다운로드한 기상데이터를 결합하여 태양광 발전량 예측모델을 구축한다. 데이터처리 프레임워크는 MySQL, R 통계 패키지, Python 등으로 구성되어 있어서 다양한 모듈과 데이터베이스가 결합되어 있고 새로운 모듈을 추가할 수 있다. 이런 모델에 의해 특히 전기자동차 충전 수요를 신재생에너지 발전이 활발한 시

간으로 조정함에 의해 에너지 소비를 더욱 효율화할 수 있다 [2]. 기계학습 과정에서는 숨겨진 패턴을 발견하는데 널리 사용되고 있는 인공신경망(ANN; Artificial Neural Network)을 이용하는데, 이는 FANN (Fast ANN)과 같은 오픈 소스들이 공개되어 있어서 지정된 형태로 학습패턴을 변경하면 쉽게 데이터를 결합할 수 있다 [3].

2. 데이터처리 프레임워크

데이터 분석에 있어서 CSV 형태로 주어진 태양광 발전량 원시 파일을 Python 프로그램으로 읽어 일련의 SQL insert 문장으로 변환하고 Linux의 MySQL에서 수행시킨다. 입력과정에서 데이터의 무결성 검사가 이루어지며 전체 117기의 발전기중 97개가 99kw급이다. 설치된 발전기의 숫자는 2018년 1월 29개에서 12월 117개로 급격히 늘어났으며 일부분은 운영중에 고장을 겪어 데이터가 존재하지 않는다. 월간 발전량 분석결과에 의하면 이 발전기 설치에 따른 발전량 증가가 다른 요소보다 커서 선형적인 형태를 이루며 기후 영향으로 6월, 8월, 10월의 발전량이 제일 많다.

일별 기후요소 데이터는 기상청으로부터 다운로드받았으며 발전량에 영향을 줄 수 있는 요소는 <표 1>에 정리되어 있다. 제주도에는 4개의 기상 포스트가

위치하고 있는데 이중 제주시 포스트만 관찰기간 동안 모든 정보가 포함되어 있다. 따라서 제주시 포스트에 가장 영향을 받는 24개 발전기에 대해 발전량의 예측하도록 하며 통계 패키지인 R로 데이터를 변환 입력하여 24개 발전기와 각 기후요소와의 상관관계를 구한다. 풍속, 습도, 온도 등의 상관계수가 0.4 정도로 무시할 수는 없지만 결정적인 영향요소라고는 할 수 없다. 반면, <표 2>에서 보는 바와 같이 일사량, 일조시간, 전운량 등은 0.8 정도의 강한 상관관계를 보이고 있어서 ANN의 입력인자로 포함시켜야 한다.

<표 1> 기후요소 리스트


| | | |
|-----|----|------|
| 위치 | 시간 | 온도 |
| 강수량 | 풍속 | 풍향 |
| 습도 | 기압 | 일조시간 |
| 일사량 | 눈 | 전운량 |

<표 2> 상관관계 분석 결과

| | |
|------|--------|
| 기후요소 | 상관관계 |
| 전운량 | 0.7732 |
| 일조시간 | 0.8846 |
| 일사량 | 0.8845 |

3. 예측모델

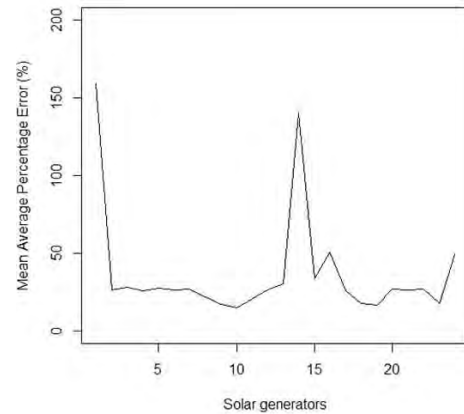
24개의 발전기중에서 가장 기후요소와 상관관계가 높은 3개를 선택하여 학습 패턴을 생성하였다. <그림 1>은 해당 발전기들의 일일 발전량에 대해 트레이스한 결과이다. 이들의 RMSE (Root Mean Square Error)는 50.05 kwh로 측정되었으며 일일발전량의 최대치는 700 kwh까지 올라가진 않는다.



<그림 1> ANN 기반 태양광발전량 예측 모델

이와 아울러, <그림 2>는 생성된 발전량 예측모델에 있어서 실제 발전량과 예측량과의 오차를 보이고 있다. 오차 분석 결과, MAPE (Mean Average Percentage Error)는 36.7 %를 보이고 있으며 최악

의 경우는 160 % 까지 올라가기도 한다. 대부분 발전기의 MAPE는 30%대에 유지되고 있는데 특히 기후 등의 요인으로 발전량이 적은 날에 그 오류의 비율이 크게 늘어나 이 오류가 전체 평균을 증가시키고 있다. 또한 두 발전기의 MAPE는 100%를 상회하는데 이들은 운영중 고장기간을 겪었으며 이 경우를 제외하고 기후 조건이 양호한 날의 예측은 비교적 정확할 수 있다.



<그림 2> MAPE에 기반한 발전기별 오류 분석

3. 결론

개발된 예측 모델은 36.7 % 정도의 MAPE를 보여주고는 있지만 발전량이 적은 날의 영향이 크기 때문인데 이 발전량이 적은 정도를 정량화할 필요가 있다. 발전량이 적은 날은 예측 결과의 정확성의 의미가 없어질 가능성이 높다. 이 예측 모델에 의해 신재생 에너지 발전을 실제 수요에 효율적으로 매칭시킬 수 있는데 역시 수요의 예측과 이 오차를 흡수할 수 있는 전기자동차 충전 등에 적용할 수 있다.

Acknowledgment

본 결과물은 교육부와 한국연구재단의 재원으로 지원을 받아 수행된 사회맞춤형 산학협력 선도대학 (LINC+) 육성사업의 연구결과입니다.

참고문헌

[1] X. Yu, and Y. Xue, Y.. "Smart grids: A cyber-physical systems perspective," Proceedings of the IEEE, vol. 104, Issue 5, pp. 1058-1070, 2016.
 [2] J. Lee and G. Park, "Price effect analysis and pre-reservation scheme on electric vehicle charging networks," IJECE, vol. 9, no. 6, pp. 5586-5595, 2019.
 [3] S. Nissen, Neural networks made simple. *Software 2.0*. 2005.