

단기 전력 부하 첨두치 예측을 위한 심층 신경회로망 모델

황희수
한라대학교 전기전자공학과

Deep Neural Network Model For Short-term Electric Peak Load Forecasting

Heesoo Hwang

Department of Electrical and Electronic Engineering, Halla University

요 약 스마트그리드에서 정확한 단기 부하 예측을 통한 자원의 이용 계획은 에너지 시스템 운영의 불확실성을 줄이고 운영 효율을 높이는데 있어서 매우 중요하다. 단기 부하 예측에 얽은 신경회로망을 포함한 다수의 머신 러닝 기법이 적용되어 왔지만 예측 정확도의 개선이 요구되고 있다. 최근에는 컴퓨터 비전이나 음성인식 분야에서 심층 신경회로망의 뛰어난 연구 결과로 인해 심층 신경회로망을 단기 전력수요 예측에 적용해 예측 정확도를 개선하려는 시도가 주목 받고 있다. 본 논문에서는 일별 전력 부하 첨두치를 예측하기 위한 다층신경회로망 구조의 심층 신경회로망 모델을 제안한다. 제안된 심층 신경회로망은 층별 학습이 선행된 후 전체 모델의 학습이 이루어진다. 한국전력거래소에서 얻은 4년 동안의 일별 전력 수요 데이터를 사용, 하루 및 이를 앞선 전력수요 첨두치를 예측하는 심층 신경회로망 모델을 구축하고 예측 정확도를 비교, 평가한다.

주제어 : 융합, 전력수요 예측, 전력부하 첨두치 예측, 심층 신경회로망, 심층 학습

Abstract In smart grid an accurate load forecasting is crucial in planning resources, which aids in improving its operation efficiency and reducing the dynamic uncertainties of energy systems. Research in this area has included the use of shallow neural networks and other machine learning techniques to solve this problem. Recent researches in the field of computer vision and speech recognition, have shown great promise for Deep Neural Networks (DNN). To improve the performance of daily electric peak load forecasting the paper presents a new deep neural network model which has the architecture of two multi-layer neural networks being serially connected. The proposed network model is progressively pre-learned layer by layer ahead of learning the whole network. For both one day and two day ahead peak load forecasting the proposed models are trained and tested using four years of hourly load data obtained from the Korea Power Exchange (KPX).

Key Words : Convergence, Convergence, Power Demand Forecasting, Electric Peak Load Prediction, Deep Neural Network, Deep Learning

1. 서론

스마트그리드에서 에너지 시스템 운영의 불확실성을 줄이고 운영 효율을 높이는데 정확한 단기 부하 예측을

통한 자원의 이용 계획은 매우 중요하다. 정확한 단기 부하 예측을 위해 머신 러닝을 포함한 다양한 기법이 적용되어왔고, 특히 신경회로망은 데이터를 사용해 사전 가정 없이 예측 모델의 복잡한 입출력 관계를 학습에 의해

*Corresponding Author : Hee soo Hwang (hshwang@halla.ac.kr)

Received March 8, 2018
Accepted May 20, 2018

Revised April 3, 2018
Published May 28, 2018

표현할 수 있는 장점 때문에 널리 사용되어 왔다[1-9]. 빅 데이터를 적용하려는 시도도 있지만 아직은 기존에 사용되는 데이터 범위를 벗어나지 못하고 있다[19,20]. 이들 연구는 여전히 부하의 변동성이 큰 경우 예측 정확도의 개선이 요구되고 있다.

최근에는 컴퓨터 비전과 음성인식 분야에서 뛰어난 결과를 보인 심층 신경회로망 (DNN)을 단기 부하 예측에 적용하여 예측 정확도를 높이려는 연구가 시도되고 있다. Deep Belief Network를 적용한 단기 부하 예측[10], 구글의 텐서플로우(Tensor-flow) 플랫폼을 이용해 심층 신경회로망에서 다양한 활성화 함수의 결합을 시도한 연구[11], 단기 부하 예측에 심층 신경회로망인 Convolution Neural Network (CNN)를 적용한 연구[12]와 유용한 특징 추출을 위한 CNN과 내재적인 동특성 모델링을 위한 Recurrent Neural Network (RNN)을 결합한 심층 신경회로망 연구가 있다[13]. 그러나 단기 부하 예측에 심층 신경회로망을 적용하는 연구는 시작 단계이며 특히 부하 변동이 심한 경우 예측 정확도는 기존의 얇은 신경회로망과 유사한 수준으로 개선의 필요성이 있다.

본 논문에서는 일별 전력수요 침두치의 예측 정확도를 높이기 위해 2개의 다층 신경회로망이 직결된 구조의 심층 신경회로망 모델을 제안한다. 이 모델은 시간별 전력 수요를 예측하는 신경회로망과 이 신경회로망의 출력으로 침두치를 예측하는 2차 신경회로망이 결합된 구조를 가진다. 제안된 심층 신경회로망의 학습은 층별로 진행되는 사전 학습과 전체 신경회로망의 학습으로 이루어진다. 일별 전력 수요 데이터를 사용, 1일 및 2일 앞선 전력수요 침두치를 예측하는 심층 신경회로망 모델을 구축하고 기존의 모델과 예측 정확도를 비교, 평가한다.

2. 단기 전력 부하 예측 모델

2.1 입력변수 선정

단기 부하 예측 모델을 구성할 때 가장 중요한 이슈 가운데 하나는 모델의 입력 변수를 선정하는 것이다. 실제 입력 변수의 선정은 정답이 있는 것은 아니고 경험과 통계적 분석에 의존한다. 기존 전력부하 침두치에 대한 분석을 보면 여름과 겨울에 냉난방 수요로 인해 전력수요 침두치의 변동성이 커진다. 대한민국은 계절적 요인으로 전력수요 변동성이 큰 나라이다. 기존 연구를 보면 전력 수요 침두치에 영향을 미치는 기후 인자는 최고 기

온이다[15, 16]. 시간별 전력 수요 곡선의 패턴을 분석해 보면 기존 이외에 주말, 주중, 주중에서 월요일과 화-금요일 및 공휴일은 시간별 전력 부하 곡선이 서로 상이하게 나타난다. 또한 공휴일 전일, 공휴일 다음 날 및 공휴일이 연휴인지에 따라 전력 부하 곡선이 달라진다 [15,17,18]. 본 논문에서는 이를 종합해서 전력 부하 곡선의 패턴이 다른 날은 서로 다른 그룹으로 분류되도록 Table 1에 보인 것과 같이 일 유형(day type)을 정의하는 월요일, 주중(화~금), 토요일, 일요일 및 공휴일 변수를 만든다. 변수는 날이 그 변수에 해당하면 1, 그렇지 않으면 0의 값을 가진다. 월요일은 오전에 침두치가 상승하는 경향이 있어서 주중과 별개로 추가된다. 따라서 날은 월 표시 입력 변수와 일 유형 표시를 위해 0 또는 1의 값을 갖는 5개의 입력 변수로 표시된다.

본 논문에서는 예측에 연휴의 영향을 반영하기 위해 전일 Day(t-1), 예측 일 Day(t) 이외에 예측 다음 일 Day(t+1) 및 예측 2일 후 Day(t+2)의 월과 일 유형을 입력변수로 추가한다. 전일의 최고 기온, 부하 침두치와 24 시간별 부하 및 예측 일의 최고 기온도 변수로 포함된다. 이를 정리하면 Table 2에 보인 것과 같이 총 51개의 변수가 된다. Day(t-1)의 변수, Day(t-2)의 변수, ..., Day(t+2)의 변수 순서로 정렬하고 [-1, 1] 범위로 정규화 한 후 심층 신경회로망의 입력변수 In(1) ~ In(51)로 사용한다.

Table 1. Variables for day type

Mon	Tues-Fri	Sat	Sun	Holiday
-----	----------	-----	-----	---------

Table 2. The number of input variables

Day	Month	Day type	MT	PL	24 HLP
Day(t-1)	1	5	1	1	24
Day(t)	1	5	1		
Day(t+1)	1	5			
Day(t+2)	1	5			

t: The day to predict
 MT: Maximum temperature
 PL: Daily peak electric load
 24 HLP: 24 hourly electric load profile

2.2 심층 신경회로망 모델

심층 신경회로망 가운데 CNN은 컴퓨터 비전과 음성 인식 분야에 대부분 적용되었다. CNN은 특징 추출을 위한 필터 역할의 층을 다층으로 갖고 있기 때문에 이런 구

조의 심층신경회로망을 전력 부하 예측에 그대로 적용할 수는 없다. 파라메타용 Copula 모델과 Deep Belief Network (DBN)을 사용한 연구가 있지만 일주일 앞선 전력 침두치 Mean Absolute Percent Error (MAPE) 예측 오차는 1.95%이고 RNN을 사용한 연구의 예측 오차는 1.349%이다[11]. 특징 추출을 위해 다수의 CNN들을 병렬로 사용하고 추출된 특징에 기후 정보를 결합하여 RNN으로 전력 부하를 예측하는 연구[13]가 있지만 CNN과 RNN의 입력이 달라 독립적인 학습이 필요하며 대한민국의 계절적 변동 조건이 유사하다고 할 때 MAPE 예측 오차 1.405%(1일 후 예측 결과)는 본 논문에서 제시한 DNN의 1일 후 예측치 오차 1.275%와 2일 후 예측치 오차 1.276%(2일 후)에 비해 예측 정확도가 낮다.

본 논문에는 전력부하 침두치의 예측 정확도를 높이기 위해 Fig. 1의 심층 신경회로망 모델(Deep Neural Network: DNN)을 제안한다. 이 DNN은 정규화 된 입력 In(1) ~ In(51)을 사용해 예측된 전력 부하 침두치를 출력한다. DNN은 In(1) ~ In(51)을 입력으로 은닉층 1개와 출력 층(중간 출력층, intermediate output layer)을 갖는 Multi Layer Perceptron (MLP)과 중간 출력층을 입력으로 은닉층 1개와 출력층을 갖는 또 하나의 MLP가 연결된 구조를 갖는다. 중간 출력 층에서 노드 수는 24개로 이들 노드는 24시간 시간별 전력 부하 값, 즉 24시간 전력 부하 곡선 프로파일 값을 출력한다.

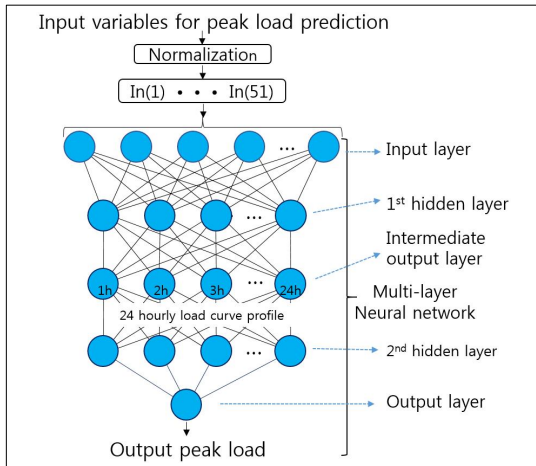


Fig. 1. The architecture of the proposed deep neural network (DNN)

신경회로망의 학습에는 역전파 알고리즘이[14] 사용

되는데 심층 신경회로망의 경우 출력층의 오차가 하위 은닉층에서 미미해 질 수 있어 심층 신경회로망은 층별 학습이 선호된다. 교사 방식의 층별 학습에는 층별 학습 목표치가 필요하기 때문에 본 논문에서는 중간 출력층(24시간 시간별 부하 값)을 도입하여 교사 방식으로 학습하고 다음 층 학습에서 중간 출력층 출력을 입력으로 사용해 최종 출력(부하 침두치)을 추종하도록 Fig.1의 심층 신경회로망 모델을 제안한다.

3. 심층 신경회로망 모델의 학습

제안된 심층 신경회로망 모델은 층별로 학습이 선행되고 층별로 학습된 심층 신경회로망 전체에 대해 한 번 더 학습을 진행한다. DNN 모델의 학습은 다음과 같이 단계적으로 이루어진다.

[단계1] MLP의 사전 학습: Fig. 2.a에 보인 바와 같이 입력층과 1개의 은닉층을 가지며 24시간 시간별 부하를 출력(24 출력 노드)으로 하는 MLP를 교사 방식으로 학습한다. 사용한 입력변수는 Table 2와 같고 모든 입력층 데이터는 [-1, 1] 범위로 정규화 된다.




Fig. 2. Pre-learning of DNN
 a. Pre-learning of the 1st MLP
 b. Pre-learning of the 2nd MLP

[단계2] 두 번째 MLP의 사전 학습: Fig. 2.b에 보인 바와 같이 단계1에서 학습된 MLP의 출력(24시간 시간별 부하)을 입력으로 사용하고 1개의 은닉층을 가지며 부하 침두치를 출력으로 하는 MLP를 교사 방식으로 학습한다.

[단계3] Fig. 3과 같이 심층 신경회로망 DNN을 정규화된 입력(In)과 출력(부하 침두치) 데이터로 최종 학습

한다.

DNN에서 뉴런의 전달함수로 logistic sigmoid 함수를, 학습에는 scaled conjugate gradient descent[14] 역전파 알고리즘을 사용한다.




Fig. 3. Learning of DNN

4. 시뮬레이션

DNN 모델을 사용하여 1일 및 2일 후의 전력 부하 첨두치를 예측하는 모델을 만들었다. 모델의 학습에는 한국전력거래소에 제공한 3년 동안(2005년 1월 ~ 2007년 12월)의 일별 전력 부하 데이터가 사용되었고 학습된 모델의 평가에는 1년(2008년) 동안의 데이터가 사용되었다. DNN의 학습 횟수와 층별 MLP의 사전 학습 횟수는 최대 100이다. 반복 학습을 통해 얻는 DNN의 최적 매개변수는 Table 3과 같다.

Table 3. Deep neural network parameters for the electric peak load prediction model

Model		n_{h1}	n_{h2}
DNN	1 day	19	15
	2 days	23	19

n_{h1} : The number of neurons in the 1st hidden layer

n_{h2} : The number of neurons in the 2nd hidden layer

1 day: 1 day ahead peak load prediction model

2 day2: 2 days ahead peak load prediction model

Table 3에서 1 day와 2 days는 DNN 모델 출력이 각각 1일 및 2일 후 부하 첨두치인 경우이다. Table 4는 본 논문의 예측 모델인 DNN과 다른 신경회로망 모델의 예측 오차인 MAPE를 비교한 것이다. Table 4에서 신경회

로망 Multi-Layer Perceptron (MLP)는 중간 은닉층이 하나이고 은닉층 노드 수가 17이고 Radial Basis Function Network (RBFN)는 최소 65에서 최대 93개의 뉴런으로 구성된 복수의 신경회로망이다[15]. 본 논문에서 제시한 DNN 모델이 기존 방법에 비해 학습에서는 5.20%~ 15.86%, 평가에서는 0.70% ~ 5.63%의 예측 정확도를 개선시켰다.

Table 4. Comparison of 1 day ahead peak load prediction accuracy

Model	MPAE	
	Train	Test
RBFN[15]	1.142	1.298
RBFN error correction[15]	1.192	1.284
MLP	1.058	1.351
DNN	1.003	1.275

2일 후 전력 부하 첨두치 예측 결과는 Table 5와 같다. Table 5에서 MLP는 중간 은닉층이 1개, 은닉층 노드 수는 17이다. DNN 모델의 경우 MLP에 비해 학습에서 27.48%, 평가에서 27.95%의 예측 정확도가 높다. 특히 DNN 모델의 2일 후 전력 부하 첨두치 예측치는 1일 후의 것과 동등한 수준의 정확도를 보인다.

Table 5. Comparison of 2 days ahead peak load prediction accuracy

Model	MPAE	
	Train	Test
MLP	1.252	1.771
DNN	0.908	1.276




Fig. 4. A day ahead peak load prediction in the learning




Fig. 5. A day ahead peak load prediction in the test




Fig. 6. Two days ahead peak load prediction in the learning




Fig. 7. Two days peak load prediction in the test

Fig. 4와 Fig. 5는 1일 후의 전력 부하 침투치 예측을 위한 DNN 모델의 학습 및 평가에 사용한 실 데이터와 예측된 값을 비교한 그림이다. 실선은 실 데이터이고 •

은 예측된 값이다. Fig. 6과 Fig. 7은 2일 후 전력 부하 침투치 예측을 위한 DNN 모델의 학습 및 평가에 사용한 실 데이터와 예측된 값을 비교한 그림이다. 실선은 실 데이터이고 •은 예측된 값이다. DNN 모델이 1일과 2일 후 부하 침투치 예측에서 실 데이터를 잘 추종하고 있음을 보인다.

5. 결론

본 연구는 신경회로망에 의한 단기 부하 침투치 예측의 정확도를 개선하기 위해 심층 신경회로망 모델을 제안하였다. 시뮬레이션 결과를 보면 1일 및 2일 후의 전력 부하 침투치를 예측함에 있어 본 논문에서 제시한 DNN 심층 회로망 모델이 기존 방법에 비해 예측 정확도를 개선할 수 있음을 보였다. 또한 제시된 모델로 예측된 1일 및 2일 후의 전력 부하 침투치의 정확도가 동등한 수준으로 이는 실전에서 1일 대신 2일 후의 예측치를 사용한다면 큰 부하 변동에 따른 자원 운용 계획 수립에 시간적 여유를 줄 수 있을 것으로 판단된다. 향후 연구 과제로 지역별 전력 수요, 지역별 대표 기후 정보 등의 빅데이터를 활용해 예측 정확도를 더욱 높이고자 한다.

REFERENCES

- [1] A. J. Al-Shareef, E. A. Mohamed & E. Al-Judaibi. (2008). Next 24-hours Load Forecasting Using Artificial Neural Network for the Western Area of Saudi Arabia, *JKAU: Eng. Sci.*, 19(2), 25-40.
- [2] B. H. Wang. (2009). Short-term Electrical Load Forecasting Using Neuro-fuzzy Model with Error Compensation, *International Journal of Fuzzy Logic and Intelligent Systems*, 9(4), 249-342.
- [3] C. Ying, P. B. Luh, G. Che, Z. Yige, L. D. Michel, M. A. Coolbeth, P. B. Friedland & S. J. Rourke. (2010). Short-term Load Forecasting: Similar Day-based Wavelet Neural Networks, *IEEE Trans. on Power Systems*, 25(1), 322-330.
- [4] L. M. Saini. (2008). Peak Load Forecasting Using Bayesian Regularization, Resilient and Adaptive Backpropagation Learning Based Artificial Neural Networks, *Electric Power Systems Research* 78, 1302-1310.

- [5] K. K. Seo. (2015). Sales Prediction of Electronic Appliances Using A Convergence Model Based on Artificial Neural Network and Genetic, *Journal of digital Convergence*, 13(9), 177-182.
- [6] R. R. Agnaldo & P. A. Alexandre. (2005). Feature Extraction via Multi-resolution Analysis for Short-term Load Forecasting, *IEEE Trans. Power Systems*, 20(1), 189-198.
- [7] S. Fan & L. Chen. (2006). Short-term Load Forecasting Based on An Adaptive Hybrid Method, *IEEE Trans. Power Systems*, 23(1), pp. 392-401.
- [8] T. Senjyu, P. Mandal, K. Uezato & T. Funabashi. (2004). Next Day Load Curve Forecasting Using Recurrent Neural Network Structure, *IEE Proc.- Gener. Transm. and Distrib.*, 151(3), 388-394.
- [9] Z. Yun, Z. Quan, S. Caixin, L. Shaolan, L. Yuming & S. Yang. (2008). RBF Neural Network and ANFIS-based Short-term Load Forecasting Approach in Real-Time Price Environment, *IEEE Trans. on Power Systems*, 23(3), 853-858.
- [10] T. Ouyang, Y. He, H. Li, Z. Sun & S. Baek. A Deep Learning Framework for Short-term Power Load Forecasting, <https://arxiv.org/pdf/1711.11519>.
- [11] T. Hossen, S. J. Plathottam & R. K. Angamuthu. (2017). Short-term Load Forecasting Using Deep Neural Networks (DNN), *Power Symposium (NAPS), North American*, 17-19.
- [12] K. Amarasinghe, D. L. Marino & M. Manic. (2017). Deep Neural Networks for Energy Load Forecasting, *Industrial Electronics (ISIE), 2017 IEEE 26th International Symposium*, 19-21.
- [13] Wan He. (2017). Load Forecasting via Deep Neural Networks, *Procedia Computer Science*, 122, 308-314.
- [14] M. F. Moller. (1993). A Scaled Conjugate Gradient Algorithm for Fast Supervised Learning, *Neural Networks*, 6, 525 - 533.
- [15] H. S. Hwang. (2013). Daily Electric Load Forecasting Based on RBF Neural Network Models, *International Journal of Fuzzy Logic and Intelligent Systems*, 13(1), 39-49.
- [16] J. H. Lim, S. Y. Kim, J. D. Park & K. B. Song. (2013). Representative Temperature Assessment for Improvement of Short-Term Load Forecasting Accuracy, *Journal of the Korean Institute of Illuminating and Electrical Installation Engineers*, 27(6), 39-43.
- [17] O. S. Kwon & K. B. Song. (2011). Development of Short-Term Load Forecasting Method by Analysis of Load Characteristics During Chuseok Holiday, *The transactions of The Korean Institute of Electrical Engineers* 60(12), 2215-2220.
- [18] S. Y. Kim, J. H. Lim, J. D. Park & K. B. Song. (2013). Short-Term Electric Load Forecasting for the Consecutive Holidays Using the Power Demand Variation Rate, *Journal of the Korean Institute of Illuminating and Electrical Installation Engineers* 27(6), 17-22.
- [19] P. Zhang, X. Wu, X. Wang & S. Bi. (2015). Short-Term Load Forecasting Based on Big Data Technologies, *CSEE Journal of Power And Energy Systems*, 1(3), 59-67.
- [20] H. Zhao, Z. Tang, W. Shi & Z. Wang. (2017). Study of Short-term Load Forecasting In Big Data Environment, *Control And Decision Conference*, 28-30. DOI: 10.1109/CCDC.2017.7978378.

황 희 수(Heesoo Hwang)

[정회원]



- 1988년 2월 : 연세대학교 본대학원 전기과 (공학석사)
- 1993년 2월 : 연세대학교 본대학원 전기과 (공학박사)
- 1993년 4월 ~ 2001년 2월 : 한국고속철도기술개발사업단 선임 및 수석연구원
- 2001년 3월 ~ 현재 : 한라대학교 전기전자과 교수
- 관심분야 : 머신러닝, 시계열 예측, 데이터 기반 모델링
- E-Mail : hshwang@halla.ac.kr