

NARX 신경망을 이용한 동·하계 단기부하예측에 관한 연구

Short-term Electric Load Forecasting in Winter and Summer Seasons using a NARX Neural Network

정희명* · 박준호†

(Hee-Myung Jeong · June Ho Park)

Abstract - In this study the NARX was proposed as a novel approach to forecast electric load more accurately. The NARX model is a recurrent dynamic network. ISO-NewEngland dataset was employed to evaluate and validate the proposed approach. Obtained results were compared with NAR network and some other popular statistical methods. This study showed that the proposed approach can be applied to forecast electric load and NARX has high potential to be utilized in modeling dynamic systems effectively.

Key Words : NARX neural network, Short-term electric load forecasting, Temperature data

1. 서론

전력부하 예측은 전통적으로 전력 계통의 최적 운용 및 계획 수립과 발전, 송배전 계통의 운영비용을 줄이는 데 있어 중요한 문제이다. 전력부하 예측은 예측기간에 따라 단기, 중기 및 장기 예측으로 분류되며 중장기 예측은 일반적으로 송전계통에서 새로운 변전소나 전송선로를 계획하는데 사용되고 단기 예측은 배전 계통 운영 및 비용관리에서 중요한 역할을 한다. 특히 단기부하 예측은 전력계통의 제어 및 운용에 필요한 조류계산, 발전예비력, 경제급전 등을 계산하는데 중요한 역할을 하기 때문에 보다 정확한 전력부하 예측을 해야 한다. 예를 들면, 1984년에 부하예측의 평균절대백분비오차 (MAPE)가 1% 증가하여 운영비용을 1000만 파운드 초과 지출한 것으로 보고했다[1]. 예에서 보듯 이러한 중요성 때문에 전력부하를 예측하는 많은 문헌[21]들이 있으며, 예측기법에 따라 통계적 방법[2~4], 인공지능 방법[5, 19] 또는 두 가지 기법의 융합[6, 20]을 포함하여 여러 기술이 연구되었다.

인공신경망은 부하예측 뿐만 아니라 기계적 학습 문제에 지난 몇 년 동안 주로 사용된 기법이다. 그러나 많은 뉴런을 가진 신경망은 빠른 계산 속도와 작은 훈련 오차를 가질 수 있지만 초과훈련이 되어 훈련과 다른 패턴이 입력으로 들어오면 성능이 나빠지는 한계가 있다. 이러한 문제점을 해결하기 위해 신경망의 훈련과정을 개선하기 위한 많은 알고리즘이 개발되었다. Kermanshahi [7], Pai과 Hong [8, 9]는 ANN과 SVM (Support Vector Machine)을 사용하여 순환형 모델(Recurrent Model)을 제시하였

고, 이 방법이 피드포워드 신경망보다 피드백 연결이기 때문에 동적 시스템을 모델링하는데 성능이 좋았다고 보고했다.

전력부하 예측은 큰 부하의 변동이 한 시간이나 하루 기간에 가능하기 때문에 까다로운 문제이다. 이러한 변동은 기상 조건 [10, 11], 온도[12], 요일[12], 시간대[1], 계절 요인[8, 9], 사회 활동[13] 및 사회경제적 요인[14] 등 많은 변수에 의존한다. 그래서 본 연구에서 좀 더 부하 예측에 효율적인 기법을 개발하기 위해 예측 방법 중 하나인 Nonlinear Autoregressive neural network with exogenous input (NARX)를 제시하였다. NARX는 순환형 신경망 중의 하나이며[15, 16] 다른 순환형 신경망 (Recurrent Neural Network)과는 달리 숨겨진 뉴런 대신 출력 뉴런에서만 피드백 구조를 가지는 신경망이다. 이러한 학습 구조는 다른 순환형 구조보다 NARX 모델에서 더 효과적인 결과를 산출 할 수 있다고 보고되었다[17].

본 연구에서 제안한 방법의 평가와 입증을 위해 ISO-New England 데이터[18]를 사용하였고 이 데이터에는 기온데이터와 부하데이터로 구성되어 있다. 제안한 방법에서 얻은 결과를 기존의 기법, 즉 선형회귀법, 이동평균법 등과 비교하였고 보다 높은 정확성을 확인하였다.

2. 본론

2.1 기온데이터와 전력부하간의 연관도

두 변수의 연관도(measures of association)를 측정할 수 있는 대표적 척도로는 공분산(covariance)과 상관계수(coefficient of correlation)가 있다. 본 논문에서는 기상데이터 중 건구온도(dry-bulb temperature), 노점온도(dew-point temperature)와 전력부하 세 변수의 연관도를 측정하기 위해 상관계수 분석을 실

† Corresponding Author : School of Electrical and Computer Engineering, Pusan National University, Korea.
E-mail: parkjh@pusan.ac.kr

* Dept. of Electrical Engineering, Pusan National University, Korea.

Received : January 19, 2017; Accepted : June 20, 2017

시하였다. 상관계수 관련 식은 아래와 같다.

$$r_{xy} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{(n-1)s_x s_y} \quad (1)$$

여기서, \bar{x}, \bar{y} : 각각 x, y 의 평균값
 s_x, s_y : 각각 x, y 의 표준편차

표 1 기온데이터와 전력부하간의 상관계수 전머

Table 1 Coefficient of correlation in the temperature and load

	Spring	Summer	Fall	Winter
Dry-bulb temperature	0.2178	0.8606	0.0408	-0.3066
Dew-point temperature	-0.0066	0.4041	-0.1246	-0.3785

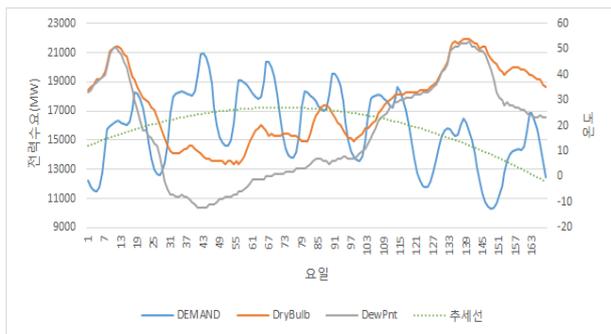


그림 1 동계 전력부하와 기온과의 관계(2014년 1월6일~1월12일)

Fig. 1 Correlation of the temperature and load in winter

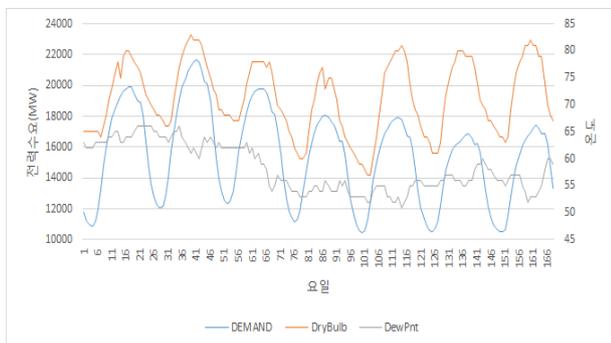


그림 2 하계 전력부하와 기온과의 관계(2014년 8월4일~8월10일)

Fig. 2 Correlation of the temperature and load in summer

표 1에서 각 계절전력부하와 기온과의 상관관계를 살펴보면 하계일 때 전력부하와 기온과의 상관계수가 각각 0.8606, 0.4041이며 동계일 때 각 상관계수가 -0.3066, -0.3785로 측정되었다. 반

면에 춘·추계일 때 상관계수 값이 동·하계 상관계수 값보다 상당히 작음을 알 수 있다. 따라서 전력부하가 동·하계일 때 기온데이터의 영향을 많이 받음을 알 수 있다. 그림 1과 2에서 일주일 동안의 동·하계 전력부하와 기온데이터의 관계를 나타내었다. 동계일 때 온도가 내려가면 전체적으로 부하가 증가하는 것을 볼 수 있고 하계일 때 온도와 부하 그래프가 비슷한 모양을 보임을 확인할 수 있다. 그래서 본 연구에서는 보다 정확한 동·하계 전력부하 예측을 위해 기온데이터를 예측모델의 입력으로 사용하였다.

2.2 NARX 신경망

지금까지 논의된 모든 특정 동적 신경망들은 입력 층에서만 동적인 특성을 가진 네트워크이거나 피드포워드 네트워크였다. NARX는 네트워크의 여러 층을 둘러싸는 피드백 연결을 가진 재순환 동적 네트워크이다. NARX는 다음과 같이 많은 응용 분야에서 사용되고 있다. 예를 들면 입력 신호의 다음 값을 예측하는 예측기 (Predictor), 입력 신호의 잡음을 제거하는 비선형 필터링, 비선형 동적 시스템의 모델링 등에 사용되었다. NARX의 구성도는 그림 3과 같으며 2층 피드포워드 네트워크로 구성되어 있으며 출력값이 입력신호로 들어가는 피드백 구조이다.

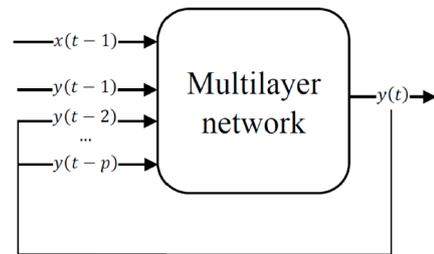


그림 3 NARX 구조

Fig. 3 NARX neural network structure

표 2 NARX 신경망 입력

Table 2 NARX model input

Exogenous input	Endogenous input
Dry-bulb temperature(F)	Load (MW)
Dew-point temperature(F)	
Time (h)	

NARX 모델의 관계식은 아래와 같다[22].

$$y(t) = f(y(t-1), y(t-2), \dots, y(t-n_y), x(t-1), x(t-2), \dots, x(t-n_x)) \quad (2)$$

여기서, n_y 는 출력(피드백)의 시간지연 개수, n_x 는 입력의 시간지연 개수, f 는 비선형함수이다.

식 (2)를 보면 출력 y 는 외부 변수 x 외에 지연출력 y 를 포함한다. 본 논문에서는 날씨 변수는 외생적 입력 x 이고 부하는

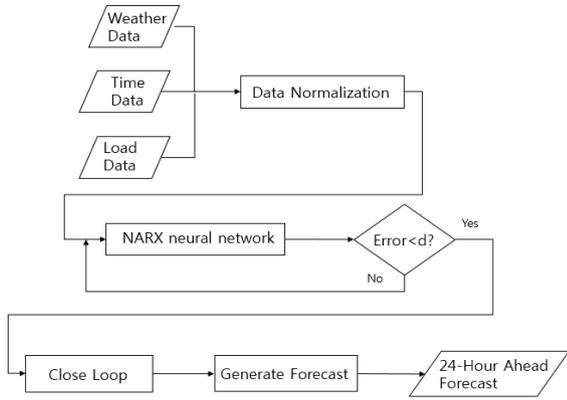


그림 4 제안한 부하예측 순서도
Fig. 4 Proposed flowchart

내생적 입력 y_t 이며 각 입력을 표 2에 나타내었다. NARX 네트워크는 부하의 실제값을 사용하여 개루프에서 학습한 후 부하의 각 1시간 간격 예측을 피드백하여 다음 24시간 예측을 위해 폐루프를 사용한다. NARX를 통해 부하예측을 위한 데이터를 준비하고 처리하는 절차를 그림 4에 나타내었다.

2.3 사례연구

2.3.1 데이터

본 연구에서 동·하계의 기온데이터를 고려한 단기부하 예측을 실시하기 위해 ISO-New England의 2012-2014년 데이터를 사용하였다. 이 데이터는 뉴잉글랜드 지역의 현재 부하, 건구온도, 노점온도를 1시간마다 측정해서 기록해 놓았다. 2012, 2013년까지의 동·하계 부하데이터를 훈련과정에 사용하였고 2014년 동·하계 부하데이터로 정확성을 평가하였다. 부하와 온도간의 데이터 크기가 다르므로 모든 데이터를 (0, 1) 사이로 정규화하였고 신경망의 훈련 과정 중에는 정규화된 데이터에 대해 평균제곱오차(Mean Square Error)로 정확도를 평가하였고 평가과정에서는 예측된 부하 값과 실제 부하 값을 비교하기 위해 평균절대백분위오차(Mean Absolute Percent Error)를 계산하였다.

2.3.2 NARX parameters 결정

NARX는 동적 신경망의 종류이므로 식 (2)에 의해 은닉 층의 뉴런 개수와 피드백 되는 출력과 입력 값의 지연 개수를 결정해야 한다. 먼저 출력과 입력 값의 지연 개수를 결정하기 위해 각 시간별 부하와 온도의 상관계수를 계산하여 연관도를 살펴보았다. 표 3에 시간별 각 데이터의 상관계수의 결과를 나타내었다. 부하 데이터의 경우 t-6시간, 건구온도인 경우 t-4시간, 노점온도인 경우 t-6시간까지 상관계수가 높은 것을 알 수 있다. 그래서 각 경우에 대해 NARX 신경망으로 시뮬레이션 하여 MSE값이 제일 작은 값을 가진 내생입력(피드백)지연은 t-4, 외생입력지연은 t-3으로 표 4처럼 결정하였다.

표 3 부하, 건구 및 노점온도 데이터의 시간별 상관계수

Table 3 Time correlation coefficient of load, dry bulb and dew point temperature

	t-6	t-5	t-4	t-3	t-2	t-1
Load	0.912098	0.930824	0.950587	0.968231	0.983832	0.995394
Dry. Temp.	0.743308	0.784592	0.825323	0.866157	0.907698	0.946869
Dew. Temp.	0.916587	0.933404	0.948719	0.96483	0.978696	0.98981

표 4 지연개수를 결정하기 위한 NARX의 MSE

Table 4 MSE of NARX to determine the number of delays

		t-1	t-2	t-3	t-4	t-5
Winter	feedback delay	0.000592	0.000233	0.000173	0.000152	0.000159
	input delay	1.55E-04	1.54E-04	1.56E-04	1.74E-04	1.62E-04
Summer	feedback delay	0.000206	0.00017	0.000109	9.21E-05	9.92E-05
	input delay	9.25E-05	9.53E-05	8.61E-05	9.38E-05	1.11E-04

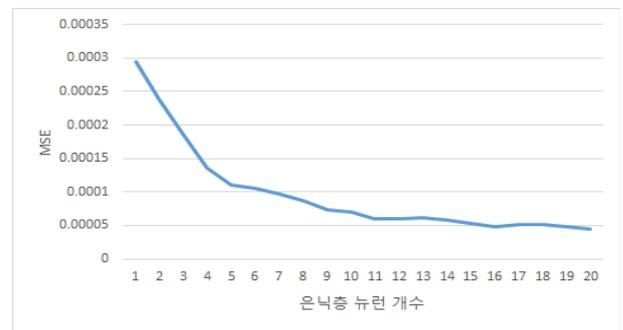


그림 5 은닉층 뉴런 개수에 따른 MSE 결과

Fig. 5 MSE according to the number of neuron in hidden layer

다음으로 신경망의 은닉 층의 최적 뉴런 개수를 결정하기 위해 은닉 층의 뉴런 개수를 1부터 20개까지 변화시키면서 그 결과 나타나는 MSE 값을 살펴보았다. 그 결과가 그림 5와 같으며 최종적으로 NARX의 은닉 층의 뉴런 개수를 20개로 결정하였다. 표 5에 시뮬레이션을 위한 신경망 구성 및 파라메타를 정리하였다.

2.3.3 결과

제안한 방법인 NARX의 결과와 비교하기 위하여 선형회귀법 (Linear Regression), 이동평균법 (Moving Average), 비선형자기회귀신경망(Nonlinear Autoregressive Neural Network), 일반회귀신경망 (Generalized Regression Neural Network)들과 비교를 하였다[19]. 동일한 조건에서 비교하기 위해 LR과 GRNN 기법에서는 외부입력(날씨데이터)과 출력(부하)의 회귀분석을 위해

NARX 신경망과 동일하게 외부입력, t-1에서 t-3까지, 각각 3개 식의 입력을 설정하였고 MA, NAR 기법에서는 내생입력개수, 즉 t-1에서 t-4까지의 입력을 사용하여 시뮬레이션하였다. 그 비교 결과를 표 6에 나타내었다.

표 5 NARX 구성 및 파라메타

Table 5 NARX architecture and parameter

	Traing (open-loop)	Forecasting (close-loop)
The number of input neurons	6(Exogenous), 4(Endogenous)	6(Exogenous)
The number of hidden layers	1	1
The number of hidden neurons	20	20
The number of output neurons	1	1
Activation Function	Sigmoid	Sigmoid
Learning Algorithm	Levenberg-Marquardt backpropagation	Levenberg-Marquardt backpropagation
Performance Error	0.001	

표 6 예측기법의 전력부하 예측 결과

Table 6 Results comparison for LR, GRNN, MA, NAR and NARX

	LR	GRNN	MA	NAR	NARX
Winter (MAPE)	11.83%	7.91%	3.47%	0.49%	0.40%
Summer (MAPE)	9.28%	6.99%	4.09%	0.46%	0.39%

예측 결과를 비교해보면 크게 자기회귀모형을 사용하는 기법과 아닌 것으로 나눌 수 있는데 선형회귀기법과 일반회귀신경망은 과거 데이터를 입력으로 사용하는 자기회귀 모형이 아니고 그 결과 전력부하 예측 값이 크게 나타나는 것을 확인하였다. 자기회귀 모형을 사용하는 이동평균법과 NAR, NARX의 결과를 비교해보면 선형과 비선형으로 구분할 수 있는데 비선형 모형인 NAR, NARX가 보다 전력부하 예측 모형을 잘 반영하여 결과가 상당히 정확함을 확인하였다. 마지막으로 NAR과 NARX는 외부 입력의 유무에 의해 구분되는데 본 연구에서 제한한 기온데이터를 입력으로 사용한 NARX가 더 좋은 성능을 보임을 확인하였다. 그림 6와 7은 2014년 동·하계 실제부하와 NARX로 예측한 부하를 표시한 그림이다.

3. 결 론

전력부하 예측은 큰 부하의 변동이 한 시간이나 하루 기간에 가능하기 때문에 까다로운 문제이다. 이러한 변동은 기상 조건, 온도, 요일, 시간대, 계절 요인, 사회 활동 및 사회경제적 요인 등 많은 변수에 의존한다. 본 연구에서 좀 더 부하 예측에 효율적인 기법을 개발하기 위해 동적 시스템의 예측 방법 중 하나인 NARX를 제시하였다. NARX는 순환형 신경망 중의 하나이며, 다른 순환형 신경망과는 달리 숨겨진 뉴런 대신 출력 뉴런에서만 피드백 구조를 가지는 신경망이다. 제한한 방법의 평가와 입증을 위해 ISO-New England 데이터를 사용하였고 제안한 방법에서 얻은 결과를 기존의 예측 기법과 비교한 결과 동·하계 부하 예측 결과인 MAPE값이 각각 0.4%, 0.39%로 다른 기법보다 높은 정확성을 가짐을 확인하였다. 앞으로 본 연구에서 제안한 순환형 동적 신경망인 NARX의 외부 입력을 동·하계부하에 영향을 주는 기온데이터뿐만 아니라 전체 전력부하에 영향을 미치는 여러 요인을 분석하여 적용할 계획이다.

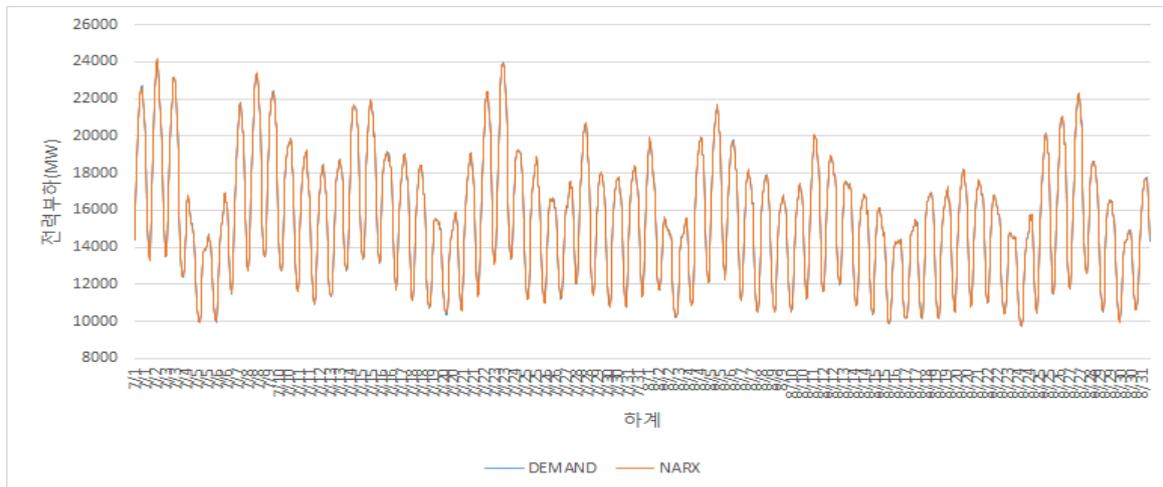


그림 6 2014년 하계 전력부하 예측결과(7, 8월)

Fig. 6 Load forecasting in the summer of 2014

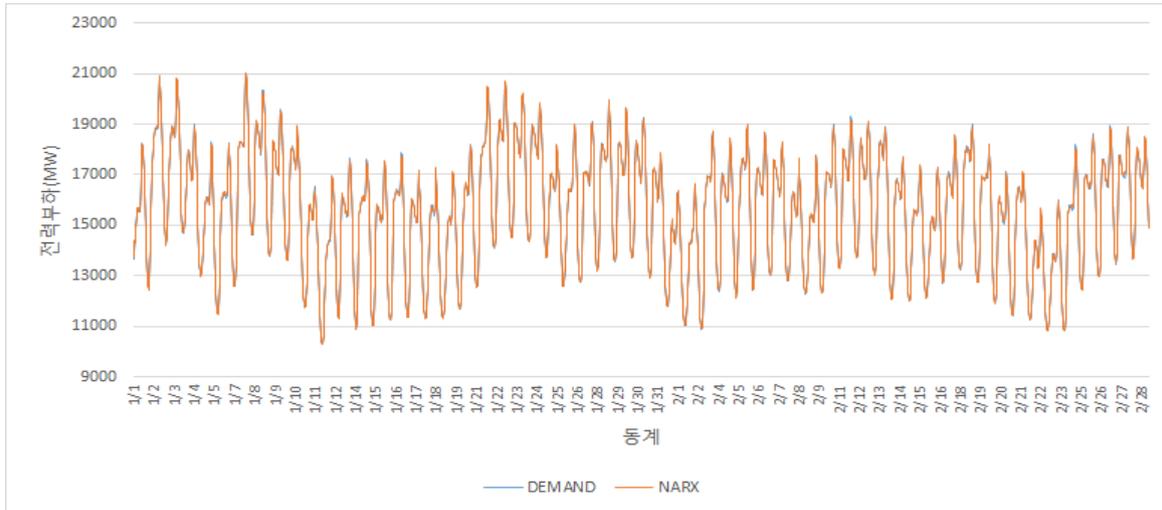


그림 7 2014년 동계 전력부하 예측결과(1, 2월)
 Fig. 7 Load forecasting in the winter of 2014

감사의 글

이 논문은 부산대학교 기본연구지원사업(2년)에 의하여 연구되었음.

References

[1] Hippert HS, Pedreira CE, and Souza RC. "Neural networks for short-term load forecasting: a review and evaluation". *IEEE Trans Power Syst.*, vol. 16(1), pp. 44-55, 2001.

[2] T. Hong, J. Wilson, and J. Xie, "Long term probabilistic load forecasting and normalization with hourly information", *IEEE Trans. Smart Grid*, vol. 5, no. 1, pp. 456-462, Jan. 2014.

[3] D. Singhal and K. Swarup, "Electricity price forecasting using artificial neural networks", *Int. J. Elect. Power Energy Syst.*, vol. 33, no. 3, pp. 550-555, Mar. 2011.

[4] A. Karsaz, H. R. Mashhadi, and M. M. Mirsalehi, "Market clearing price and load forecasting using cooperative co-evolutionary approach", *Int. J. Elect. Power Energy Syst.*, vol. 32, no. 5, pp. 408-415, Jun. 2010.

[5] Hernandez, L., Baladron, C., Aguiar, J.M., Calavia, L., Carro, B., Sanchez-Esguevillas, A., Sanjuan, J., Gonzalez, L. and Lloret, J. "Improved short-term load forecasting based on two-stage predictions with artificial neural networks in a microgrid environment". *Energies*, vol. 6, pp. 4489-4507, 2016.

[6] N. Amjady and F. Keynia, "Short-term load forecasting

of power systems by combination of wavelet transform and neuro-evolutionary algorithm," *Energy*, vol. 34, no. 1, pp. 46-57, Jan. 2009.

[7] Kermanshahi B. "Recurrent neural network for forecasting next 10 years loads of nine Japanese utilities". *Neurocomputing*, vol. 23, pp. 125-133, 1998.

[8] Pai P-F and Hong W-C. "Forecasting regional electricity load based on recurrent support vector machines with genetic algorithms", *Electric Power Syst Res.*, vol. 74, pp. 417-425, 2005.

[9] Pai PF. and Hong WC. "Support vector machines with simulated annealing algorithms in electricity load forecasting", *Energy Convers Manage*, vol. 46(17), pp. 2669-2688. 2005.

[10] Chow TWS and Leung CT. "Neural network based short-term load forecasting using weather compensation", *IEEE Trans Power Syst*, vol. 11(4), pp. 1736-1742. 1996.

[11] Metaxiotis K, Kagiannas A, Askounis D and Psarras J. "Artificial intelligence in short term electric load forecasting: a state-of-the-art survey for the researcher", *Energy Convers Manage*, vol. 44(9), pp. 1525-1534. 2003.

[12] Lu CN, Wu HT, and Vemuri S. "Neural network based short term load forecasting", *IEEE Trans Power Syst.*, vol. 8(1), pp. 336-342. 1993.

[13] Hong WC. "Electric load forecasting by support vector model", *Appl Math Model*, vol. 33(5), pp. 2444-2454. 2009.

[14] Hahn H, Meyer-Nieberg S, and Pickl S. "Electric load forecasting methods: tools for decision making", *Eur J Oper Res.*, vol. 199(3), pp. 902-907. 2009.

- [15] Narendra, K.S. and Parthasarathy, K., "Identification and control of dynamical systems using neural networks", IEEE Transactions, Vol. 1 No. 1, pp. 4-27. 1990.
- [16] Chen, S., Billings, S.A. and Grant, P.M., "Non-linear system identification using neural networks", International Journal of Control, Vol. 51 No. 6, pp. 1191-1214. 1990.
- [17] Horne, B.G. and Giles, C.L., "An experimental comparison of recurrent neural networks", Proceedings of the Conference Neural Information Processing Systems 1994, MIT Press, Denver, pp. 697-704. 1995.
- [18] [Online]. Available http://iso-ne.com/markets/hstdata/znl_info/hourly/index.html
- [19] Omer F. E. "Forecasting electricity load by a novel recurrent extreme learning machines approach", Int. J. Elect. Power Energy Syst., vol. 78, pp. 429-435. 2016.
- [20] Ekonomou, L., Christodoulou, C. and Mladenov, V., "A Short-Term Load Forecasting Method Using Artificial Neural Networks and Wavelet Analysis", Int. J. Power Syst., vol. 1, pp. 64-68. 2016.
- [21] Raza, M. and Khosravi, A. "A review on artificial intelligence based load demand forecasting techniques for smart grid and buildings", Renew. Sustain. Energy Rev., vol. 50, pp. 1352-1372. 2015.
- [22] Venturini, M. "Simulation of compressor transient behavior through recurrent neural network models". J. Turbomach. Trans. ASME, vol. 128, pp. 444-454. 2006.

저 자 소 개



정 희 명 (Hee-Myung Jeong)

1978년 1월 6일생, 2004년 부산대 공대 전자전기컴퓨터공학부 졸업, 2006년 동 대학원 전기공학과 졸업(공학석사), 현재 동 대학원 박사과정



박 준 호 (June Ho Park)

1955년 9월 17일생, 1978년 서울대 공대 전기공학과 졸업, 1980년 동 대학원 전기공학과 졸업(공학석사), 1987년 동 대학원 전기공학과 졸업(공학박사), 현재 부산대 전기컴퓨터공학부 교수