

조건적 제한된 볼츠만머신을 이용한 중기 전력 수요 예측

Mid-Term Energy Demand Forecasting Using Conditional Restricted Boltzmann Machine

김수현*, 선영규*, 이동구*, 심이삭*, 황유민*,
김현수**, 김형석*, 김진영*

Soo-Hyun Kim*, Young-Ghyu Sun*, Dong-gu Lee*, Is-sac Sim*, Yu-Min Hwang*,
Hyun-Soo Kim**, Hyung-suk Kim*, Jin-Young Kim*

Abstract

Electric power demand forecasting is one of the important research areas for future smart grid introduction. However, It is difficult to predict because it is affected by many external factors. Traditional methods of forecasting power demand have been limited in making accurate prediction because they use raw power data. In this paper, a probability-based CRBM is proposed to solve the problem of electric power demand prediction using raw power data. The stochastic model is suitable to capture the probabilistic characteristics of electric power data. In order to compare the mid-term power demand forecasting performance of the proposed model, we compared the performance with Recurrent Neural Network(RNN). Performance comparison using electric power data provided by the University of Massachusetts showed that the proposed algorithm results in better performance in mid-term energy demand forecasting.

요약

미래에 스마트 그리드 도입을 위해 전력수요예측은 중요한 연구 분야 중 하나이다. 하지만 전력데이터는 많은 외부적 요소들에 영향을 받기 때문에 예측하기 어렵다. 기존의 전력수요예측 방법들은 가공되지 않은 전력데이터를 그대로 이용하기 때문에 정확도 높은 예측을 하는데 한계가 있어왔다. 본 논문에서는 가공되지 않은 전력데이터를 이용하는 전력수요예측의 문제를 해결하기 위해 확률기반 학습알고리즘을 제안한다. 확률 모델은 전력데이터의 확률적 특성을 분석하기에 적합하다. 제안한 모델의 중기 전력수요예측 성능을 비교하기 위해 신경망 네트워크 중 하나인 순환신경망과 성능 비교를 해보았다. 매사추세츠 대학에서 제공한 전력데이터를 이용하여 성능 비교를 한 결과 본 논문에서 제안한 확률기반 학습알고리즘이 중기 수요예측에 더 좋은 성능을 나타냄을 확인하였다.

Key words : Smart grid, Learning Algorithm, Energy Demand Forecast, RBM, CRBM

* Dept. of Electronic Convergence Engineering, Kwangwoon University

** Co. Gridwiz

★ Corresponding author

E-mail : jinyoung@kw.ac.kr, Tel : +82-2-940-5567

※ Acknowledgment

This work was supported by "Human Resources Program in Energy Technology" of the Korea Institute of Energy Technology Evaluation and Planning (KETEP), granted financial resource from the Ministry of Trade, Industry & Energy, Republic of Korea. (No. 20174010201620)

Manuscript received Mar. 8, 2019; revised Mar. 23, 2019; accepted Mar. 25, 2019.

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

I. 서론

미래의 전력망의 해결책 중 하나인 스마트 그리드는 전력망과 정보기술이 결합한 기술로 소비자의 전력사용량에 맞추어서 전기를 생산, 공급하는 시스템을 말한다. 기존 전력망은 사용전력 예측량의 10%이상을 추가생산하게 되어 이에 따른 전력효율 감소의 문제가 있다. 이러한 문제를 해결하기 위해 기존의 전력 공급시스템에서 추가 공급 에너지를 효율적으로 줄일 수 있는 스마트 그리드 기술이 필요하게 된다. 이러한 스마트 그리드 시스템의 기술 중 소비자가 미래에 사용할 전력량을 정확히 예측하는 전력수요예측기술은 중요한 연구 분야 중 하나이다[1].

전력수요예측기술은 소비자가 사용하는 전력의 양을 사전에 계산하는 기술로 공급자는 예측된 전력량에 맞춰 전기를 생산함으로써 안정적이고 효율적인 전력운용을 할 수 있다. 하지만 전력수요예측은 요일, 시간, 날씨, 기온, GDP 등 복합적인 변수들에 영향을 받기 때문에 정확한 예측이 힘들다는 단점이 있다[2]. 이러한 단점을 해결하기 위해 다양한 방법과 연구들이 진행되고 있다.

기존의 전력수요예측 방법으로는 이동평균 방법(Moving Average, MA), 회귀 분석(Regression) 방법 등이 있다[3]. 이동평균 방법은 2개 이상의 연속된 데이터를 계속적으로 평균화 하는 방법이다. 회귀 분석방법은 연속된 변수들 사이의 상관관계를 수식화 하는 방법이다. 기존의 전력수요예측 방법들은 전력소비패턴이 급격히 변화하는 환경에서 예측 정확도가 떨어진다.

이러한 문제를 해결하기 위해 최근 연구에서는 기계학습 알고리즘 중 하나인 신경망 네트워크의 발전으로 전력수요예측을 위해 신경망네트워크를 적용한 연구들이 진행되고 있다[4-5]. 하지만 신경망을 이용한 전력수요반응예측은 높은 차원의 전력데이터로 사용함으로써 오버피팅 문제, 로컬 옵티멈 문제 등이 발생한다.

본 연구에서 제안하는 조건적 제한된 볼츠만머신(Conditional Restricted Boltzmann Machine, CRBM)은 확률을 기반으로 한 학습알고리즘으로 많은 변수들에 영향 받아 변동이 큰 가정용 전력수요반응을 예측 하는데 기존의 방법들보다 더 좋은 해결책이 될 수 있다.

본 연구에서 제안하는 조건적 제한된 볼츠만머신의 성능을 보이기 위해 중기 전력사용예측에 대한 실험을 진행하였다. 전력데이터는 매사추세츠 대학에서 제공한 가정용 전력데이터를 사용하였다[6].

본 논문의 구성은 다음과 같다. II장에서는 전력수요예측을 위한 본 논문에서 제안하는 시스템 모델에 대한 설명을 하고, III장에서는 실험 환경에 대한 서술 및 신경망 네트워크인 순환신경망(Recurrent Neural Network, RNN)의 성능과 확률기반 조건적 제한된 볼츠만머신 모델의 성능 비교를 보인다. 마지막으로 IV장에서는 결론을 제시하며 마무리 짓는다.

II. 시스템 모델

1. 제한된 볼츠만머신

볼츠만머신(Boltzmann Machine, BM)은 양방향성의 그래프 모델로 노드들이 확률 분포로 정의된 신경망 네트워크이다. 이 모델은 층간 노드 사이에 상관관계를 모두 고려하기 때문에 학습 과정이 복잡하여 연산시간이 길다는 문제가 있다[7]. 이러한 문제를 해결하기 위해 각 층의 노드들 사이의 연결을 없애는 제한을 두었고, 이렇게 제한된 모델이 제한된 볼츠만 머신(Restricted Boltzmann Machine, RBM)모델이다. 그림 1은 볼츠만머신과 제한된 볼츠만머신의 구조를 나타내고 있다. 제한된 볼츠만머신은 비지도 학습의 한 종류이다. 비지도 학습이란 무작위로 분포된 데이터를 비슷한 특성을 가진 분류로 묶어주는 역할을 하고 초기 딥러닝 모델에서 학습 성능을 높이기 위한 데이터 전처리 단계로 사용되었다[8].




Fig. 1. Structure of Boltzmann Machine and Restricted Boltzmann Machine.

그림 1. 볼츠만머신과 제한된 볼츠만머신 구조

제한된 볼츠만머신 모델은 입력 시각층(visible layer)와 은닉층(hidden layer)로 구성된다. 시각층에는 이진형태의 입력값을 받아들이는 시각노드(visible node)들이 있고, 은닉층에는 입력값들의 특징으로 결정되는 은닉 노드(hidden node)들이 있다.

제한된 볼츠만머신은 이진데이터로 구성된 \mathbf{v} 와 \mathbf{h} 의 결합 확률분포(joint probability)로 정의 한다. 수식으로 나타내면 다음과 같다.

$$P(v, h) = \frac{e^{-E(v, h)}}{Z}. \quad (1)$$

$$Z = \sum_{v, h} e^{-E(v, h)}. \quad (2)$$

위 식에서 E 는 에너지 함수를 나타내며, Z 는 분배함수로 확률값의 합을 1로 만드는 정규화상수 값이다. 수식에서 확률은 에너지가 높을수록 존재 확률 P 가 낮아지게 된다. 에너지 함수의 수식은 다음과 같다.

$$E(v, h) = -(v^T W h + v^T a + h^T b). \quad (3)$$

여기서 가중치 \mathbf{W} 는 시각노드와 은닉노드를 연결하는 가중치에 대한 행렬을 의미하고 바이어스(bias) \mathbf{a} 와 \mathbf{b} 는 각각 시각노드와 은닉노드들의 바이어스를 의미한다.

그림 1. (b)에서, 제한된 볼츠만머신은 시각층과 은닉층 내부에 노드들 간 연결이 없는데, 이는 노드들 간에 독립성을 의미한다. 이러한 특징으로 제한된 볼츠만머신은 두 가지의 간단한 형태의 함수를 얻을 수 있다. 첫 번째로는, 시각층과 은닉층 간에 조건적 확률 수식 (4-5)이다. 시각층과 은닉층 간에 조건적 확률은 σ 인 시그모이드 함수 형태로 나타나고 이는 제한된 볼츠만머신의 활성화 함수로 사용 된다[9].

$$P(h_j = 1|v) = \sigma(b_j + W_j^T v). \quad (4)$$

$$P(v_i = 1|h) = \sigma(a_i + W_i^T h). \quad (5)$$

두 번째로는 시각층의 노드들에 대한 확률이다. 제한된 볼츠만머신 모델에서 시각층에 노드들의 확률은 은닉층의 모든 경우의 수를 고려하여 다음과 같이 계산할 수 있다:

$$p(v) = \sum_h p(v, h) = \frac{\sum_h e^{-E(v, h)}}{Z}. \quad (6)$$

유사한 형태의 데이터가 입력된 경우, 제한된 볼츠만머신에서 각각의 파라미터(W , a , b)는 에너지 함수가 작은 값이 되도록 조정이 되고, 반대로 상이한 데이터가 입력된 경우는 에너지 함수가 큰 값이 되도록 가중치와 바이어스가 조정이 된다. 가중치와 바이어스를 조정하기 위해 제한된 볼츠만머신 모델에서는 목적함수로 negative log-likelihood 함수를 사용한다:

$$L(\theta, D) = -\sum_{i=0}^D \log P(x_i, \theta). \quad (7)$$

여기서 θ 는 모델의 파라미터 값을, D 는 훈련데이터 셋을 그리고 x_i 는 입력 데이터를 의미한다. 목적함수 L 이 최소가 되도록 파라미터 θ 를 설정한다.

$$\min_{\theta} L(\theta, D). \quad (8)$$

목적함수가 최소가 되는 파라미터를 구하기 위해 목적함수의 경사 하강법을 이용하면 다음과 같이 앙상블 평균(ensemble average)으로 나타난다[7].

$$\frac{\partial \log p(v)}{\partial w_{ij}} = \langle v_i h_j \rangle_{data} - \langle v_i h_j \rangle_{model}. \quad (9)$$

$$\frac{\partial \log p(v)}{\partial a_i} = \langle v_i \rangle_{data} - \langle v_i \rangle_{model}. \quad (10)$$

$$\frac{\partial \log p(v)}{\partial b_j} = \langle h_j \rangle_{data} - \langle h_j \rangle_{model}. \quad (11)$$

위 식에서 $\langle x \rangle_{data}$ 은 입력데이터 변수 x 에 대한 $p(v_j|h)$ 에 기댓값을 나타내고 $\langle x \rangle_{model}$ 은 학습된 모델의 변수 x 에 대한 $p(v, h)$ 의 기댓값을 나타낸다. 식 (9-11)에서 앞부분은 조건부 확률로 식 (4-5)와 같이 시그모이드 형태로 계산된다. 하지만 뒷부분은 결합 분포 함수형태로 정확한 값을 얻기 위해서는 모든 \mathbf{v} , \mathbf{h} 에 대해 계산이 필요하며 계산과정이 복잡하다. 이러한 제한된 볼츠만머신의 문제를 해결하기 위해 CD-k(Contrastive Divergence-k) 알고리즘을 사용한다[10].

2. CD-K 알고리즘

CD-k 알고리즘은 제한된 볼츠만머신 모델의 파라미터를 학습하기 위한 알고리즘이다. 파라미터를 학습시키기 위해서는 랜덤 변수들의 결합 확률분포함수를 계산해야 한다. 랜덤 변수들의 결합 확률

분포함수 풀기 위한 대표적인 알고리즘으로 Gibbs Sampling이 있다[10]. 결합 확률분포를 계산할 때, CD-k알고리즘은 Gibbs Sampling을 통해 수렴되는 값이 나올 때 까지 반복하는 것이 아닌 Gibbs Sampling을 k번 수행으로 나온 근사값으로 결합 확률분포함수를 계산한다.

3. 조건적 제한된 볼츠만머신

제한된 볼츠만머신은 입력값들의 특징 추출을 통해 데이터의 차원을 낮춰주기 위한 모델로써 사용된다. 즉, 복잡한 형태의 데이터를 분석하기 쉬운 데이터 형태로 만들어 준다고 할 수 있다. 이와 달리 조건적 제한된 볼츠만머신 모델은 제한된 볼츠만 머신의 변형된 형태로 주로 협업필터링, 사람 움직임에 대한 예측과 같이 앞으로의 사건에 대한 예측분야에서 사용된다[11-12]. 조건적 제한된 볼츠만머신의 에너지 함수는 다음과 같다:

$$E(v,h,u) = -v^T W_1 h - u^T W_2 v - u^T W_3 h - v^T a - h^T b. \quad (12)$$

위 수식에서 u 는 이전 입력값에 대한 시각층을 말한다. 기존 제한된 볼츠만머신과 에너지 함수를 비교해보면 조건적 제한된 볼츠만머신은 시간 정보를 처리하기 위해 이전 시각층 값들을 조건적으로 사용하여 가중치와 바이어스들을 갱신한다. 이전 입력값들을 모델 파라미터 학습에 반영함으로써 시간 정보를 가지고 있는 시계열 데이터를 학습 및 처리할 수 있다. 그림 2는 본 논문에서 이용한 학습 모델인 조건적 제한된 볼츠만머신의 구조를 나타내고 있다.




Fig. 2. Structure of CRBM.
그림 2. 조건적 제한된 볼츠만머신 구조

III. 전력데이터를 이용한 모델 성능

1. 전력 데이터

본 논문에서 제안하는 조건적 제한된 볼츠만머신의 성능을 평가하기 위해 매사추세츠대학교에서

제공한 가정용 전력데이터를 사용했다[6]. 학습 데이터로는 2014년 1월 1일부터 2014년 10월 27일까지 총 300일의 일일 전력 데이터를 사용하였다. 그림 3은 모델 학습을 위한 훈련 데이터 그래프로 개형을 보여준다. 그래프의 개형은 가정용 일일 전력 사용량 데이터로 여러 가지의 복합 요소로 인하여 데이터의 규칙성 없이 나타난다. 모델의 성능 평가를 위한 검증 데이터로는 2014년 10월 28일부터 2014년 12월 31일까지 65일을 사용하였다. 그림 4는 검증 데이터의 그래프 개형을 보여준다.

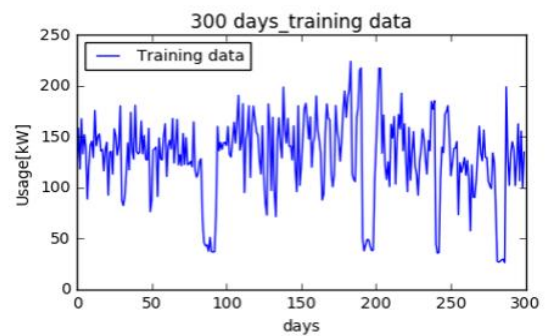


Fig. 3. Training data for learning model.
그림 3. 모델 학습을 위한 훈련 데이터




Fig. 4. Validation data for performance evaluation.
그림 4. 성능 평가를 확인하기 위한 검증 데이터

2. 조건적 제한된 볼츠만머신 모델파라미터

Table 1. Parameters of experiments.

표 1. 실험 파라미터

Parameters	Value
TIMESTEPS	2
Number of hidden nodes	10
learning rate	0.001
Batch size	4
Epoch	200
k value(CD-k)	3

본 실험에서 조건적 제한된 볼츠만머신에서 설정한 파라미터는 실험 및 설정 가이드라인을 기반으로 설정하였다[9]. 표 1은 본 실험에서 설정한 파라미터들을 정리한 표다.

3. 성능 지표

본 실험에서 시행된 모델들의 성능을 평가하기 위한 평가지표로 평균 절대백분율오차(Mean Absolute Percentage Error, MAPE)를 사용하였다. 평균 절대 백분율오차 수식은 다음과 같다:

$$MAPE = 100 \times \frac{1}{N} \sum_{i=1}^N \frac{|val(i) - predic(i)|}{|val(i)|} \quad (13)$$

위 수식에서 N 은 전체 데이터 수를 의미하며, val 값은 검증 데이터를 의미하고 $predic$ 값은 모델 결과로 나온 예측 값을 의미한다. 평균 절대 백분율오차는 같은 데이터로 다른 모델들의 성능 평가를 비교하는데 적합하며 값이 작을수록 성능이 좋은 모델임을 나타내는 지표이다.

4. 시뮬레이션 결과

가정용 전력 데이터를 이용하여 동일한 훈련데이터와 검증 데이터를 가지고 순환신경망 네트워크와 본 논문에서 제안한 확률 기반 학습 알고리즘의 성능을 비교한 결과는 표 2에 나타난다. 순환신경망의 시뮬레이션 결과를 보면 15일까지는 예측 그래프의 개형이 그려지지만 15일 이후부터는 검증 데이터와 전혀 무관한 그래프 개형이 그려진다. 반면에 조건적 제한된 볼츠만머신 모델의 시뮬레이션 결과를 통해 검증 데이터와는 상당부분 일치하며 이를 통해 가정에서의 소비전력량을 파악할 수

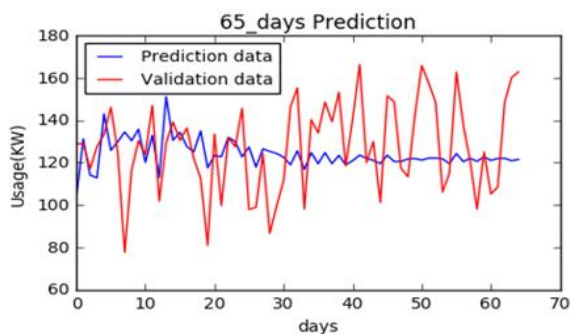


Fig. 5. Simulation results using Recurrent Neural Network.
그림 5. RNN을 이용한 시뮬레이션 결과

있다. 표 2에서 두 모델의 성능 지표인 MAPE 값을 비교해보면 조건적 제한된 볼츠만머신이 순환신경망보다 15.66% 개선되었다. 개선된 이유로 학습데이터인 전력데이터는 고차원의 변수들을 내포하고 있기 때문에 이러한 데이터를 학습하고 예측을 하는데 확률 기반의 학습알고리즘이 더 좋은 성능을 보인다.




Fig. 6. Simulation results using Conditional Restricted Boltzmann Machine.

그림 6. CRBM을 이용한 시뮬레이션 결과

Table 2. Performance indicator of models.

표 2. 모델 성능 지표

	RNN	CRBM
MAPE	32.24	16.58

IV. 결론

본 논문에서는 기존의 전력수요예측 기술의 단점을 보완하기 위해 조건적 제한된 볼츠만머신의 적용을 제시하고 이에 대한 성능을 검증하였다. 조건적 제한된 볼츠만머신은 확률 기반으로 한 학습 알고리즘으로써 가공되지 않은 전력데이터를 학습하고 예측하는데 적합한 기술이다. 본 논문에서는 시스템복잡도 감소를 위해 2개 층을 사용하여 모델링하였다. 시뮬레이션 결과를 통해 기존 순환신경망 기술보다 전력수요예측 성능이 15% 이상 개선된 걸 확인하였다. 해당 기술을 통해 더 적은 복잡도로 소비자의 전력소비예측이 가능하다는 것을 확인하였다. 향후 연구는 다양한 전력 데이터에 따른 파라미터 선정방법 및 데이터베이스 구성방법, 신경망층의 고차원화, 다양한 수학적 기법을 활용방안에 대해 연구가 진행될 것이다.

References

- [1] Y. Fu, D. Sun, Y. Wang, L. Feng and W. Zhao, "Multi-level load forecasting system based on power grid planning platform with integrated information," in *Proc. of 2017 Chinese Automation Congress(CAC)*, IEEE, Jinan, China, pp. 933-938, 2017. DOI: 10.1109/CAC.2017.8242900
- [2] D. Zhang, Y. Yan, X. Li, X. Ren, J. Zhang and F. Zhang, "Mid-long term electricity demand forecasting based on markov chain screening combination forecasting models," *Power System Protection and Control*, vol. 44, no. 12, pp. 63-67, 2016. DOI: 10.1109/CICED.2016.7576282
- [3] I. E. Kafazi, R. Bannari and A. Abouabdellah, "Modeling and forecasting energy demand," in *Proc. of 2016 International Renewable and Sustainable Energy Conference (IRSEC)*, IEEE, Marrakech, Morocco, pp. 746-750, 2016. DOI: 10.1109/IRSEC.2016.7983974
- [4] L. Wei and S. Yumin, "Prediction of energy production and energy consumption based on BP neural networks," in *Proc. of 2008 IEEE International Symposium on Knowledge Acquisition and Modeling Workshop*, Wuhan, China, pp. 15-19, 2008. DOI: 10.1109/KAMW.2008.4810454
- [5] M. de Oliveira, "The influence of ARIMA-GARCH parameters in feed forward neural networks prediction," *Neural computing & applications*, vol. 20, no. 5, pp. 687-701, 2011. DOI: 10.1007/s00521-010-0410-8
- [6] UMass website; Available at <http://traces.cs.umass.edu/>
- [7] A. Fischer and C. Igel, *An introduction to restricted boltzmann machines*. Springer, 2012.
- [8] G. W. Taylor, G. E. Hinton and S. T. Roweis, "Modeling human motion using binary latent variables," in *Proc. of Twentieth Annual Conference on Neural Information Processing Systems*, Vancouver, Canada, pp. 1345-1352, 2006.
- [9] G. E. Hinton, *A practical guide to training restricted boltzmann machines*. Springer, 2012.
- [10] G. E. Hinton, "Training products of experts

by minimizing contrastive divergence," *Neural Computation*, vol. 14, no. 8, pp. 1771-1800, 2002.

DOI: 10.1162/089976602760128018

[11] S. Wang, Y. Liu and X. Zhang, "A differentiated DBN model based on CRBM for time series forecasting," in *Proc. of 2017 IEEE 17th International Conference on Communication Technology (ICCT)*, pp. 1926-1931, 2017.

DOI: 10.1109/ICCT.2017.8359965

[12] X. Cai and X. Lin, "Forecasting high dimensional volatility using conditional restricted boltzmann machine on GPU," in *Proc. of Parallel and Distributed Processing Symposium Workshops & PhD Forum (IPDPSW)*, pp. 1979-1986, 2012.

DOI: 10.1109/IPDPSW.2012.258

BIOGRAPHY

Soo Hyun Kim (Member)



2019 : B. Sc. degree in Electronic Convergence Engineering, Kwangwoon University.

2019~present : M. Sc. Course in Electronic Convergence Engineering, Kwangwoon University.

Young Ghyu Sun (Member)



2018 : B. Sc. degree in Electronic Convergence Engineering, Kwangwoon University.

2018~present : M. Sc. Course in Electronic Convergence Engineering, Kwangwoon University.

Dong gu Lee (Member)



2019 : B. Sc. degree in Electronic Convergence Engineering, Kwangwoon University.

2019~present : M. Sc. Course in Electronic Convergence Engineering, Kwangwoon University.

Issac Sim (Member)

2016 : B. Sc. degree in Electronic Convergence Engineering, Kwangwoon University.
2016~present : Ph. D. Course in Electronic Convergence Engineering, Kwangwoon University.

Yu Min Hwang (Member)

2012 : B. Sc. degree in Wireless Communications Engineering, Kwangwoon University.
2012~present : Ph. D. Course in Electronic Convergence Engineering, Kwangwoon University.

Hyun Soo Kim (Member)

2015 : B. S. degree, Dept. of Electronics Engineering, Sogang University.
2017 : M. S. degree, Dept. of Electronics Engineering, Sogang University.
2017~ present : Associate Researcher, Gridwiz, Co., Ltd..

Hyung suk Kim (Member)

2008 : Ph.D degree, Dept. of Electrical and Computer Engineering, University of Wisconsin-Madison, USA.
2008~present : Associate Professor in Dept. of Electrical Engineering, Kwangwoon University.

Jin Young Kim (Member)

1998 : Ph. D. degree, Dept. of Electronics Engineering, Seoul National University.
2001 : Senior Research Engineer, SK Telecom Networks Research center.

2001~present : Professor in Dept of Electronic Convergence Engineering, Kwangwoon University.