

딥러닝 기반 송신전력 조절방안의 성능검증

이용섭¹ · 김성환² · 류종열² · 반태원^{1*}

Performance Verification of Deep Learning based Transmit Power Control

Woongsup Lee¹ · Seong Hwan Kim² · Jongyeol Ryu² · Tae-Won Ban^{1*}

^{1*}Associate Professor, Department of Information and Communication Engineering, Institute of Marine Industry, Gyeongsang National University, Tongyeong, 53064, Korea

²Assistant Professor, Department of Information and Communication Engineering, Institute of Marine Industry, Gyeongsang National University, Tongyeong, 53064, Korea

요약

최근 딥러닝 기술이 큰 관심을 받으며 다양한 분야에 적용되고 있다. 특히 다양한 무선통신기술에 딥러닝을 접목하여 기존 통신시스템의 한계를 뛰어넘으려는 시도가 이루어지고 있다. 본 논문에서는 딥러닝 기반 무선통신 시스템 송신전력 조절방안의 성능검증을 수행하였다. 딥러닝 기반 송신전력 조절방안에서는 수학적 최적화 문제를 직접 풀어서 최적의 전력을 결정하는 기존 방식과 달리 심층신경망 구조를 학습시켜서 채널에 따라 최적의 송신전력을 찾는 General solver를 도출하여 이를 이용한다. 특히 시스템의 주파수 효율을 심층신경망 학습의 손실함수로 사용함으로써 라벨없이 학습을 가능케 한다. 본 논문에서는 Tensorflow 기반 성능분석을 통해 딥러닝 기반 송신전력 조절방안과 최적방안의 성능이 일치함을 보였고, 또한 제안 방안이 기존의 방식에 비해서 1/200의 계산복잡도로 송신전력을 찾을 수 있음을 보임으로써 실제 무선통신시스템에서의 적용가능성을 검증하였다.

ABSTRACT

Recently, the deep learning technology has gained lots of attention which leads to its application to various fields. Especially, there are recent attempts to overcome the limit of wireless communications systems through the use of the deep learning. In this paper, we have verified the performance of deep learning based transmit power control scheme. Unlike previous transmit power control schemes where the optimal transmit power is derived by solving the optimization problem explicitly, in the deep learning based transmit power control, the general solver for the optimization problem is derived through the deep neural network (DNN). Especially, by using the spectral efficiency as the loss function of DNN, the training can be performed without needing labels. Through simulation based on Tensorflow, we confirm that the transmit power control based on deep learning can achieve the optimal performance while reducing the computational complexity by 1/200.

키워드: 딥러닝, 전송파워조절, 무선통신시스템, 최적화, 검증

Key word: Deep learning, Transmit power control, Wireless communication systems, Optimization, Verification

Received 15 January 2019, Revised 17 January 2019, Accepted 22 January 2019

* Corresponding Author Tae-Won Ban (E-mail: twban35@gnu.ac.kr, Tel:+82-55-772-9177)

Associate Professor, Department of Information and Communication Engineering, Gyeongsang National University, Tongyeong 53064, Korea

Open Access <http://doi.org/10.6109/jkiice.2019.23.3.326>

print ISSN: 2234-4772 online ISSN: 2288-4165

©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.
Copyright © The Korea Institute of Information and Communication Engineering.

I. 서 론

최근 심층신경망(Deep neural network, DNN)에 기반을 둔 딥러닝(Deep learning) 연구가 큰 주목을 받고 있다 [1-3]. 딥러닝은 기계학습(Machine learning)의 하위 분야로서 두뇌의 동작을 모방하여 동작한다. 특히 직접 최적의 구현방안을 수식을 통해 개발하기보다는 심층신경망이 데이터로부터 직접 최적의 방안을 도출하기 때문에, 사람이 모든 데이터를 확인할 수 없는 빅데이터 환경에 매우 적합하다. 딥러닝은 최근 인터넷의 발달로 학습 데이터가 풍부해지고, 새로운 알고리즘들이 개발되고, 병렬분산 컴퓨팅을 통한 효율적 학습이 가능해지면서 그 성능이 크게 향상되었다. 현재 딥러닝은 많은 분야에 활용되고 있고 특히 이미지 처리 및 음성인식분야에서는 기존 기술을 상회하는 성능을 보여주면서 학문의 패러다임을 바꾸고 있다 [1].

현재 딥러닝은 컴퓨터 과학 분야에서 활발하게 연구가 이루어지고 있지만, 축산 및 무선통신과 같이 타 분야에서도 딥러닝을 접목하려는 시도가 꾸준히 이루어지고 있다 [2-3]. 특히 무선통신분야에서는 2018년부터 본격적으로 딥러닝을 활용하려는 연구가 진행되고 있다 [3-6].

[3]의 연구에서는 딥러닝의 분류방안을 이용하여 무선채널정보를 기반으로 주변단말을 파악하는 방식을 개발하였고, 성능분석을 통해 높은 정확도로 주변 단말을 찾을 수 있음을 보였다. [4]와 [5]의 연구에서는 딥러닝의 오토인코더(Auto-encoder) 기술을 이용하여 직교 주파수 분할 다중 방식(Orthogonal frequency division multiplexing) 시스템에서 Peak-to-average power ratio (PAPR)을 줄이는 인코더/디코더 구조와 Sparse code multiple access(SCMA)에서 최적의 인코더/디코더 구조를 도출하였다. 더불어 [6]에서는 딥러닝을 이용하여 무선신호의 특성 및 변조방식(Modulation)을 찾는 방안이 제안되었다.

앞에서 살펴본 것과 같이 무선통신에서의 딥러닝 적용은 주로 오토인코더를 활용한 인코더/디코더 개발 및 무선신호 탐지 쪽으로 많이 진행되고 있다. 하지만 최근 딥러닝의 종단간학습(End-to-end learning)을 이용한 자원할당에 대한 연구가 일부 이루어졌다. [7]의 연구에서는 Weighted minimum mean square error (WMMSE) 전송전력 조절방안을 모사하는 심층신경망 구조를 개발

하였고 이를 통해서 기존 방식의 문제점인 계산복잡도 (Computational complexity) 문제를 해결하였다. [8]의 연구에서는 심층신경망 학습의 손실함수로 주파수 효율(Spectral efficiency) 및 에너지 효율(Energy efficiency)을 직접 사용하여 현재 채널 값에 따라서 최적의 전송파워를 도출하는 심층신경망을 개발하였다. [7]과 [8]의 연구에서 볼 수 있듯이 딥러닝 기반 송신전력 조절방안은 기존의 방안들에 비해서 낮은 계산 복잡도로 전송파워를 결정할 수 있고 따라서 실시간 동작에 용이하다 [8]. 특히 단말의 수가 매우 많은 경우에서 두 방안의 계산시간 차이가 크게 나므로 단말의 수가 매우 많은 사물인터넷 환경에서는 딥러닝 기반의 송신전력 조절방안이 더 유리하다 [8].

기존의 연구에서는 딥러닝 기반 전송전력 조절기술의 성능을 WMMSE기반 송신전력 조절방안과만 비교를 하였고 실제 최적전송전력과 비교하지 않았다 [7, 8]. 또한 다양한 심층신경망 구조에서의 성능분석이 이루어지지 않아서 최적의 구조에 대한 정보를 얻기 어려웠다. 따라서 본 연구에서는 딥러닝 기반의 전송전력 조절기술의 성능을 최적 송신전력과 비교하여 성능을 명확히 검증하고 실제 다양한 심층신경망구조에서 성능을 비교함으로써 비교적 작은 심층신경망구조에서도 최적 값에 98%이상 근접한 성능을 보임을 확인하였다. 이를 통해서 계산능력(Computation power)이 부족한 무선단말들도 딥러닝 기반 전송전력 조절기술을 활용할 수 있음을 보였다.

II. 시스템 모델 및 딥러닝 기반 송신전력 조절 방안

본 장에서는 연구에서 고려한 무선통신 시스템 모델에 대해서 우선 설명하고 본 연구에서 고려한 심층신경망구조와 그 학습방안에 대해서 설명한다.

2.1. 시스템 모델

본 연구에서는 N개의 전송단말세트(Transmit pair, TX pair)가 동시에 데이터를 전송하는 환경을 고려하였다. 본 연구에서 고려한 시스템 모델은 그림 1에 나와 있다. 그림에서 확인할 수 있듯이 전송단말세트 i 는 P_i 의 송신전력으로 데이터를 전송하고 각 전송단말세트는

서로에게 간섭(Interference)을 미칠 수 있다. 또한 전송 단말세트 i 의 송신자와 전송단말세트 j 의 수신자간 채널은 $h_{i,j}$ 로 나타내었다. 더불어 각 전송단말세트의 최대 송신전력은 P_m 보다 작다고 가정하였다. 마지막으로 잡음전력은 N_0 으로 표기하였다.

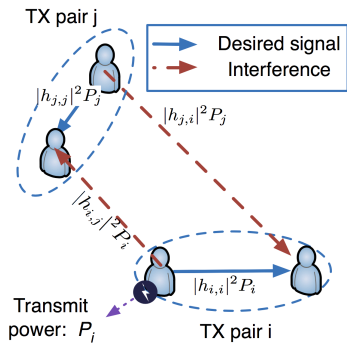


Fig. 1 Considered system model for transmit power control.

따라서 본 시스템 모델에서 전송단말세트 i 의 주파수 효율 S_i 는 다음과 같이 나타낼 수 있다.

$$S_i = \log_2 \left(1 + \frac{|h_{i,i}|^2 P_i}{N_0 + \sum_{j \neq i} |h_{j,i}|^2 P_j} \right). \quad (1)$$

본 연구에서는 전체 무선통신 시스템의 주파수 효율을 최대화하는 전송전력을 설정하는 문제를 고려하였다. 따라서 최적의 전송전력은 아래의 최적화 문제를 통해 구할 수 있다.

$$\begin{aligned} & \text{maximize} && \sum_{i=1 \leq i \leq N} S_i \\ & \text{s.t.} && 0 \leq P_i \leq P_m \quad \text{for } 1 \leq i \leq N \end{aligned} \quad (2)$$

위의 문제에서 i 는 전송단말세트의 인덱스를 의미한다. (2)의 최적화 문제는 전송전력이 최대 송신전력보다 작을 때 전체 전송단말세트의 주파수 효율을 최대화하는 전송전력을 찾는 최적화 문제이다 [8]. S_i 가 non-convex 함수이므로 (2)의 최적화 문제는 non-convex optimization 문제이다 [9]. 따라서 적은 복잡도로 (2)의 최적 해를 구하는 것이 어렵다. [9]에서는 반복(iteration)을 통해 최적 해를 구하는 방식을 제안하였지만 반복방

식의 수렴에 많은 시간이 걸릴 수 있고 특히 단말의 수가 많은 경우 ($N \gg 0$) 수렴에 더 오랜 시간이 걸리므로 전송전력 조절의 실시간 동작이 어려울 수 있다.

2.2. 심층신경망 구조 및 학습

본 연구에서 고려한 심층신경망 구조가 그림 2에 나와 있다. 본 연구에서는 심층신경망 기반의 통신기술의 적용가능성을 확인해보는 것이므로 fully connected 기반의 가장 간단한 구조를 고려하였다. 그림에서 확인할 수 있듯이 각 전송단말세트간의 채널 상태($h_{i,j}$)가 심층신경망의 입력이 되고 각 전송단말세트의 전송파워(P_i)가 출력이 된다.




Fig. 2 Considered DNN structure to derive optimal transmit power.

제안한 심층신경망은 L개의 선형 레이어(Linear layer)와 시그모이드(Sigmoid) 및 곱셈(Multiply) 레이어로 이루어져 있다. 또한 각 선형 레이어는 W개의 은닉노드(Hidden node)를 갖도록 설정하였고 Activation function으로 Rectifier linear unit(ReLU)를 사용하였다 [8]. 본 선형레이어에서 각 은닉노드의 출력은 ReLU로 입력이 되는데, ReLU는 심층신경망에 비선형성을 주는 구성요소로서 $\max(\cdot, 0)$ 연산을 통해 음의 입력이 후속 레이어로 전파되는 것을 막고 양수 값만 출력시킨다[3]. ReLU의 사용을 통해서 심층신경망에 비선형성을 줄 수 있고 이를 통해 딥러닝 구조가 단순한 매트릭스 연산이 되는 것을 막을 수 있다 [8].

또한 심층신경망의 과적합을 막기 위해서 [3], [8]의 연구에서는 드롭아웃(Dropout)을 사용하였지만 본 연구에서는 좀 더 발전된 형태인 배치정규화(Batch normalization)

1) 일부 연구에서는 Fully connected (FC) layer로 표기하기도 한다. [8]

을 사용하였다. 따라서 심층신경망의 레이어 입력마다 정규화를 시켜주어 각 레이어의 입력이 적절한 범위에 있도록 조절해준다 [10].

마지막 선형 레이어의 출력은 시그모이드 레이어의 입력으로 들어간다. 시그모이드 레이어에서는 시그모이드 함수 ($\frac{1}{1+e^{-x}}$)를 이용하여 출력범위를 0과 1사이로 제한한다. 시그모이드 레이어는 총 N개의 출력을 갖고 각 출력은 전송단말세트의 정규화 된(Normalized) 출력 ($\frac{P_i}{P_m}$)을 나타낸다. 따라서 시그모이드 레이어 출력에 최대 출력인 P_m 을 곱함으로써 실제 각 전송단말세트의 출력을 구할 수 있다. 본 심층신경망의 출력이 0과 P_m 사이로 한정되므로 최적화 문제 (2)의 제한조건 (constraint)인 $0 \leq P_i \leq P_m$ 를 언제나 충족시킬 수 있다.

이렇게 구성된 심층신경망은 기존의 확률적 경사하강법(Stochastic gradient method)을 이용하여 학습될 수 있다. 확률적 경사하강법 사용을 위해서는 손실함수(Loss function, L)를 먼저 설정해야 한다. 본 연구에서는 최적화 문제 (2)의 목적함수를 아래의 (3)수식과 같이 손실함수로 설정하였다.

$$L = -\sum_{1 \leq i \leq N} S_i \tag{3}$$

수식 (3)에서 주파수 효율 S_i 는 심층신경망의 출력 P_i 의 함수이다. 또한 경사하강법에서는 손실함수를 줄이는 방향으로 학습이 진행되기 때문에 주파수 효율에 음수를 취하여 사용하였다.

[7]에서와 달리 주파수 효율을 직접 손실함수로 사용함으로써 최적화 문제 (2)의 해를 찾는 General solver를 도출할 수 있다. 기존의 연구와 다른 손실함수를 사용하였지만 주파수 효율이 심층신경망의 출력 P_i 에 대해서 미분가능 하므로 확률적 경사하강법 기반 학습을 사용할 수 있다.

III. 결과분석

본 장에서는 제안한 딥러닝 기반 송신전력 조절방안의 성능을 다양한 환경에서 검증하였다. 성능검증은 Tensorflow 기반 시뮬레이션을 통해 이루어졌다. 성능

분석에서는 각 단말의 채널이 독립 항등 분포(Independent and identically distributed, i.i.d.)를 갖는 순환대칭 복소 가우시안(Circularly symmetric complex gaussian)으로 가정하였다. 또한 최대 전송전력과 잡음전력을 1로 가정하였고 성능 분석을 위해서 총 10^7 개의 채널 샘플을 생성하여 심층신경망의 학습에 사용하였고 10^4 개의 채널 샘플을 추가로 생성하여 성능검증에 사용하였다. 더불어 학습을 위해 Adaptive Moment Estimation 알고리즘을 사용하였고 학습 시 batch 사이즈는 128, epoch은 10^2 , 학습속도는 1^{-3} 으로 설정하였다. 과적합의 영향을 확인하기 위해서 학습데이터셋에 대한 성능(Proposed(Training))과 검증데이터셋에 대한 성능(Proposed(Test))을 모두 표시하였다. 마지막으로 성능 분석에서 최적방안(Optimal scheme)의 성능은 실제 Exhaustive search를 통해서 구하였다. 따라서 모든 가능한 전송 전력값에 대해서 주파수 효율을 구하고 이 중 가장 높은 값을 보이는 전력값을 선택하였다.

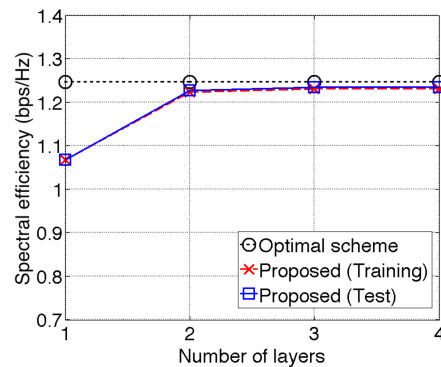


Fig. 3 Spectral efficiency vs. number of layers.

그림 3에서는 심층신경망 레이어 수에 따른 성능을 분석하였다. 본 성능분석에서는 은닉노드(W)의 수는 32로 설정하였고 전송단말세트의 수(N)는 5로 설정하였다. 최적방안의 경우 심층신경망 레이어수에 따라서 성능이 변화하지 않기 때문에 성능변화가 없다. 성능에서 확인할 수 있듯이 사용된 레이어 수가 1일 때는 최적의 성능과 일정한 차이를 보이나 레이어의 수가 2만 되더라도 최적성능의 98%에 해당하는 높은 성능을 보이는 것을 확인할 수 있다. 본 성능분석을 통해 비교적 작은 심층신경망을 사용하더라도 최적의 성능에 충

분히 근접한 결과를 얻을 수 있는 것을 확인할 수 있다. 또한 학습데이터셋과 검증데이터셋에 대한 성능이 동일한 것을 통해 심층신경망 학습에서 과적합이 일어나지 않고 올바른 학습이 이루어진 것을 확인할 수 있다.

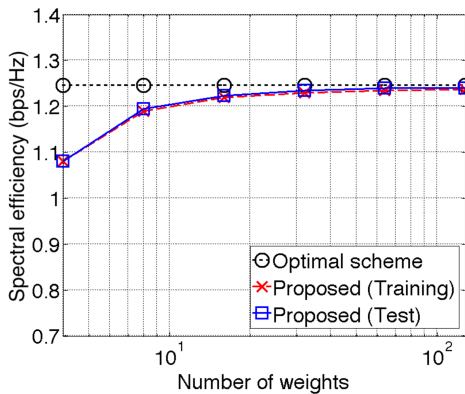


Fig. 4 Spectral efficiency vs. number of weights.

다음으로 그림 4에는 심층신경망의 은닉노드 수에 따른 성능변화를 살펴보았다. 본 성능분석에서는 레이어의 수는 3으로 설정하였고 전송단말세트의 수 (N)는 5로 설정하였다. 그림 3과 마찬가지로 최적방안은 은닉노드 수에 따라 성능변화가 없다. 그림4에서 확인할 수 있듯이 은닉노드의 수가 16개만 되더라도 최적방안 성능의 98%에 달하는 높은 성능을 보이는 것을 확인할 수 있고 은닉노드의 수가 128개가 되면 최적방안 성능의 99.5%를 달성할 수 있음을 확인할 수 있다.

다음으로 그림 5에는 전송단말세트 수에 따른 성능변화를 살펴보았다. 본 성능분석에서 레이어의 수는 3으로 설정하였고 은닉노드의 수는 32로 설정하였다. 이전의 결과와 달리 전송단말세트 수를 변화시켰기 때문에 최적방안의 성능도 같이 변한다. 결과에서 확인할 수 있듯이 전송단말세트의 수가 적을 때는 (N<6) 딥러닝 기반 방안과 최적방안의 성능이 거의 동일한 것을 확인할 수 있지만 단말의 수가 늘어남에 따라 이 둘의 격차가 발생하는 것을 확인할 수 있다. 이는 심층신경망의 성능한계 때문이며 심층신경망의 크기를 키우면 격차를 줄일 수 있다. 또한 전송단말세트의 수가 7일 때도 제안방안의 주파수 효율이 최적방안 주파수 효율의 97%를 달성할 수 있는 것을 확인할 수 있다.

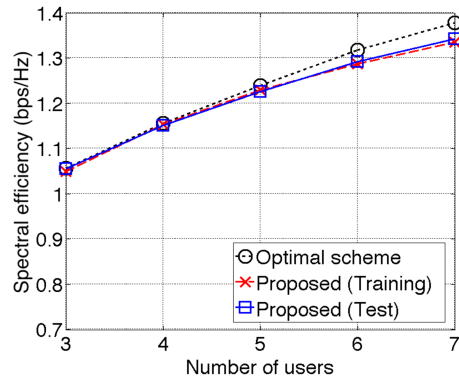


Fig. 5 Spectral efficiency vs. number of users.

마지막으로 제안방안과 최적방안의 계산시간을 그림 6에 비교하였다. 제안 방안에서는 Small network (2개 레이어, 8개 은닉노드)와 Large network (4개 레이어, 128개 은닉노드)를 고려하였다. 또한 공정한 비교를 위해서 GPU를 이용한 병렬분산계산을 사용하지 않았다. 결과에서 확인할 수 있듯이 전송단말세트의 수가 적을 때는 Large network와 최적방안의 계산시간이 거의 동일하지만 전송단말세트의 수가 증가함에 따라서 최적방안의 계산시간이 급격하게 증가하여 전송단말세트의 수가 9개일 때는 딥러닝기반기술에 비해서 200배 이상 높은 계산시간을 요구하는 것을 확인할 수 있다. 따라서 단말의 수가 매우 많은 사물인터넷 환경에서 딥러닝 기반 송신전력 조절방안이 유용하게 활용될 수 있음을 확인할 수 있다. 또한 Large network이 Small network에 비해서 2배 정도의 높은 계산시간을 요하지만 그 차이가 그리 크지 않고 전송단말세트의 수가 증가함에 따라서 그 차이가 줄어드는 것을 확인할 수 있다.




Fig. 6 Computation time vs. number of users.

IV. 결 론

본 연구에서는 딥러닝 기반 송신전력 조절방안을 제안하고 제안 방안의 성능을 다양한 환경에서 검증하였다. 제안 방안은 무선채널상태를 입력으로 받고 각 전송 단말세트의 송신전력을 출력으로 하는 심층신경망을 기반으로 한다. 제안 심층신경망의 학습에서 주파수 효율을 직접 손실함수로 사용함으로써 전체 시스템의 주파수 효율을 최대화하는 심층신경망을 도출할 수 있다. 성능분석을 통해서 제안방안이 최적의 성능을 달성할 수 있음을 검증하였고 기존 방안에 비해서 1/200 낮은 계산 복잡도를 갖는 것을 확인할 수 있다. 제안방안은 중앙집중적 환경에서 동작하지만 실제 무선통신에서 활용되기 위해서는 분산 환경으로의 확장이 필요하다.

ACKNOWLEDGEMENT

This research was supported by Basic Science Research Program through the National Research Foundation of Korea(NRF) funded by the Ministry of Education(NRF-2018R1D1A1B07040796).

REFERENCES

- [1] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, no. 7553, pp.436-444, May. 2015.
- [2] W. Lee, S. H. Kim, J. Ryu, and T.-W. Ban, "Fast Detection of Disease in Livestock based on Deep Learning," *Journal of the Korea Institute of Information and Communication Engineering*, vol. 21, no. 5, pp. 1009-1015, May 2017.
- [3] W. Lee, T.-W. Ban, S. H. Kim, and J. Ryu, "Neighbor Discovery for Mobile Systems based on Deep Learning," *Journal of the Korea Institute of Information and Communication Engineering*, vol. 12, no. 3, pp. 527-533, Mar. 2018.
- [4] M. Kim, W. Lee, and D. Cho, "A Novel PAPR Reduction Scheme for OFDM System based on Deep Learning," *IEEE Communications Letters*, vol. 22, no. 3, pp.510-513, Mar. 2018.
- [5] M. Kim, N. Kim, W. Lee, and D. Cho, "Deep Learning Aided SCMA," *IEEE Communications Letters*, vol. 22, no. 4, pp.720-723, Apr. 2018.
- [6] T. J. O'Shea, J. Corgan, and T. C. Clancy, "Convolutional radio modulation recognition networks," in *Proc. of International Conference on Engineering Applications of Neural Network*, Aberdeen, UK, Sep. 2016.
- [7] H. Sun, X. Chen, Q. Shi, M. Hong, X. Fu, and N. D. Sidiropoulos, "Learning to Optimize: Training Deep Neural Networks for Interference Management," *IEEE Transactions on Signal Processing*, vol. 66, no. 20, pp.5438-5453, Aug. 2018.
- [8] W. Lee, M. Kim, and D. Cho, "Deep Power Control: Transmit Power Control Scheme Based on Convolutional Neural Network," *IEEE Communications Letters*, vol. 22, no. 6, pp.1276-1279, Jun. 2018.
- [9] Q. Shi, M. Razaviyayn, Z.-Q. Luo, and C. He, "An iteratively weighted MMSE approach to distributed sum-utility maximization for a MIMO interfering broadcast channel," *IEEE Transactions on Signal Processing*, vol. 59, no. 9, pp. 4331-4340, Sep. 2011.
- [10] S. Ioffe, and C. Szegedy, "Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift," in *Proceeding of International Conference on Machine Learning*, Lille: France, pp. 448-456, 2015.



이용섭(Woongsup Lee)

2006년 한국과학기술원 전기및전자공학과 학사
2011년 한국과학기술원 전기및전자공학과 박사
2012년 2월~2013년 2월 한국과학기술원 박사후 연구원
2013년 2월~2014년 2월 독일 FAU 박사후 연구원
2014년 3월~현재 경상대학교 정보통신공학과 조교수

※관심분야: 차세대 이동통신 시스템, 인지 라디오 시스템, 스마트 그리드, 빅 데이터 분석, 딥러닝



김성환(Seong Hwan Kim)

2006년 8월 고려대학교 전기전자전파공학부 학사
2008년 8월 KAIST 전자전산학과 석사
2013년 2월 KAIST 전기전자공학과 박사
2013년 8월~2016년 2월 맥길대학교 박사후 연구원
2016년 3월~국립경상대학교 정보통신공학과 조교수

※관심분야: 차세대 이동통신 시스템, 사물인터넷



류종열(Jong Yeol Ryu)

2008년 2월 충남대학교 전기정보통신공학부 학사
2010년 2월 KAIST 전기및전자공학과 석사
2014년 2월 KAIST 전기및전자공학과 박사
2014년 4월~2016년 8월 싱가포르기술디자인대학교 박사후 연구원
2016년 9월~국립경상대학교 정보통신공학과 조교수

※관심분야: 보안 통신 시스템, 차세대 이동통신 시스템, 사용자 릴레이 통신 등



반태원(Tae-Won Ban)

1998년 2월 경북대학교 전자공학과 학사
2000년 2월 경북대학교 전자공학과 석사
2010년 2월 KAIST 전기및전자공학 박사
2009년 6월~2010년 10월 KT 연구 엔지니어
2011년 2월~2012년 8월 KT Project Manager
2012년 9월~2016년 8월 경상대학교 정보통신공학과 조교수
2016년 9월~현재 경상대학교 정보통신공학과 부교수

※관심분야: 차세대 이동통신, 무선 자원 관리, Cognitive Radios, Relay Systems, OFDM/MIMO