

나카가미 페이딩 채널에서 딥러닝 기반 송신 전력 제어 기법을 이용하는 무선통신 시스템에 대한 성능 분석

김동현¹ · 김동연² · 이인호^{2*}

Performance Analysis of Wireless Communication Systems Using Deep Learning Based Transmit Power Control in Nakagami Fading Channels

Donghyeon Kim¹ · Dongyon Kim² · In-Ho Lee^{2*}

¹Graduate Student, School of Electronic and Electrical Engineering, Hankyong National University, Anseong, 17579 Korea

^{2*}Professor, School of Electronic and Electrical Engineering, Hankyong National University, Anseong, 17579 Korea

요 약

본 논문에서는 무선통신 시스템의 주파수 효율과 에너지 효율을 개선하기 위하여 딥러닝 기반의 송신 전력 제어 기법을 제안한다. 무선통신 시스템에서 다수의 송수신기의 위치는 균일 분포를 따르고 송수신기 간 채널은 나카가미 페이딩 채널을 가정하여 제안하는 송신 전력 제어 기법에 대한 주파수 효율과 에너지 효율의 성능을 분석한다. 제안하는 송신 전력 제어 기법은 딥러닝 기반의 학습에서 주파수 효율과 에너지 효율을 개선하기 위하여 배치 정규화 기법을 이용한다. 시뮬레이션을 통해 송수신기의 위치 범위를 제한하는 지형적 크기와 나카가미 페이딩 지수에 대하여 제안하는 송신 전력 제어 기법과 기존의 송신 전력 제어 기법의 주파수 효율과 에너지 효율의 성능 결과를 비교한다. 성능 결과의 비교를 통해 제안하는 기법이 기존의 기법보다 우수한 성능을 제공함을 입증한다.

ABSTRACT

In this paper, we propose a deep learning based transmit power control (TPC) scheme to improve the spectral and energy efficiency of wireless communication systems. In the wireless communication system, the positions of multiple transceivers follow a uniform distribution, and the performances of spectral and energy efficiency for the proposed TPC scheme are analyzed assuming the Nakagami fading channels. The proposed TPC scheme uses batch normalization to improve spectral and energy efficiency in deep learning based training. Through simulation, we compare the results of the spectral and energy efficiency of the proposed TPC scheme and the conventional one for various area sizes that limit the position range of the transceivers and Nakagami fading factors. Comparing the performance results, we verify that the proposed scheme provides better performance than the conventional one.

키워드 : 딥러닝, 송신 전력 제어, 주파수 효율, 에너지 효율, 나카가미 페이딩 채널

Keywords : Deep learning, Energy efficiency, Nakagami fading channel, Spectral efficiency, Transmit power control

Received 4 March 2020, Revised 30 March 2020, Accepted 31 March 2020

* Corresponding Author In-Ho Lee (E-mail: ihlee@hknu.ac.kr, Tel:+82-31-670-5197)

Professor, School of Electronic and Electrical Engineering, Hankyong National University, Anseong, 17579 Korea

Open Access <http://doi.org/10.6109/jkiice.2020.24.6.744>

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. 서론

최근 무선통신 시스템에서 딥러닝을 접목하려는 시도가 활발하게 이루어지고 있다[1-4]. [1]의 연구에서는 딥러닝의 분류 기법을 통해서 채널정보를 바탕으로 하여 주변 단말을 파악했으며, [2]와 [3]의 연구에서는 딥러닝의 auto-encoder 기술을 이용하여 최적의 encoder와 decoder 구조를 제안하는 연구를 진행하였다. 또한 [4]의 연구에서는 가중 최소 평균 제곱 오차 (Weighted Minimum Mean Square Error, WMMSE)[5] 기반의 송신 전력 제어 기법을 고려하고, 사용자의 수에 따라 증가되는 계산의 복잡도를 심층신경망 구조를 이용하여 개선하였다. [6]의 연구는 합성곱 신경망(Convolution Neural Network, CNN) 기반의 장점인 2차원 배열의 특징을 추출 및 학습하는 것을 통하여 송신 전력을 도출하며, 학습방식 결정을 위하여 손실함수로 주파수 효율 또는 에너지 효율을 사용하여 각각의 학습방식에 대한 최적의 송신 전력을 도출하였다.

본 연구에서는 [6]의 시스템 모델에서 배치 정규화[7] 기법을 적용하여 학습 시간의 단축과 주파수 효율 및 에너지 효율을 개선한다. [6]의 딥러닝 기법은 방대한 채널 정보를 이용하는 송신전력 제어의 복잡성을 개선할 수 있다. 그러나, [6]의 연구는 지역 최소화(local optimum) 문제로 인하여 성능이 저하될 수 있다. 따라서 이 문제를 해결하기 위하여 제안된 기법은 CNN의 채널 특징을 추출하는 기능을 강화시키는 배치 정규화를 사용하여 높은 채널값을 갖는 사용자에게 전력이 할당될 수 있도록 한다. 또한 페이딩 지수 $m = 1$ 을 갖는 나카가미 페이딩 채널을 가정하여 주파수 및 에너지 효율을 최대화시키는 딥러닝 학습을 진행하고, 이와 같이 학습된 모델이 다양한 페이딩 지수를 갖는 나카가미 채널 환경에서도 성능을 개선시킬 수 있음을 보여준다.

II. 시스템 모델

본 연구에서는 그림 1과 같은 $D \times D$ 의 2차원 영역에서 N 개의 송수신기 쌍이 균일 분포로 분포하며 동시에 데이터를 전송하고 사용자 간에 간섭을 끼칠 수 있는 환경을 고려했다. 송수신기 간 채널은 거리에 따른 경로 손실 모델과 다중경로 페이딩으로 이루어지며 페이딩

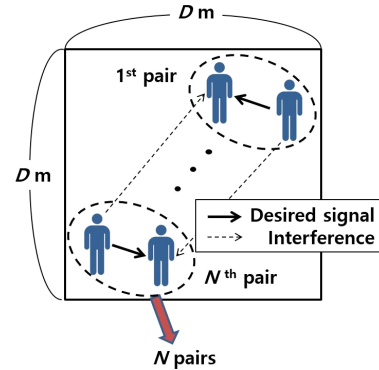


Fig. 1 System model for transmit power control.

은 나카가미 페이딩으로 가정하였다. 여기서 송신기 i 와 수신기 j 사이의 경로 손실 모델 $G_{i,j}$ 은 다음과 같이 표현된다.

$$G_{i,j} = \beta d_{i,j}^{-\alpha} . \quad (1)$$

여기서, β 는 경로손실계수이고, α 는 경로손실지수이고, $d_{i,j}$ 는 송신기 i 와 수신기 j 사이의 거리이다. 식(1)을 이용하여 송신기 i 와 수신기 j 에 대한 채널의 수식은 다음과 같이 표현된다.

$$h_{i,j} = |g_{i,j}|^2 G_{i,j} . \quad (2)$$

여기서, $g_{i,j}$ 는 페이딩 지수 m 을 갖는 나카가미 페이딩 채널의 복소 계수이다. 식 (2)를 이용하여 본 시스템 모델에서 딥러닝을 위한 손실함수로 이용될 송신기 i 에 대한 주파수 효율 SE_i 와 에너지 효율 EE_i 는 각각 다음과 같이 표현된다.

$$SE_i = \log_2 \left(1 + \frac{h_{i,i} P_i}{N_0 W + \sum_{k \in I/i} h_{k,i} P_k} \right) , \quad (3)$$

$$EE_i = \frac{SE_i}{P_i + P_C} . \quad (4)$$

여기서, P_i 는 송신기 i 의 송신전력이고, N_0 는 잡음전력이고, W 는 대역폭이고, P_C 는 회로에서 손실되는 전력이다.

식 (3), (4)의 주파수 효율과 에너지 효율을 최대화하기 위한 송신 전력 제어 기법의 문제는 다음과 같이 각각 표현될 수 있다.

$$\text{maximize } \sum_{1 \leq i \leq N} SE_i, \text{ s.t. } 0 \leq P_i \leq P_t, \quad (5)$$

$$\text{maximize } \sum_{1 \leq i \leq N} EE_i, \text{ s.t. } 0 \leq P_i \leq P_t. \quad (6)$$

여기서, 각 송신기의 최대 송신 전력은 P_t 이고, 식 (5), (6)의 함수들은 non-convex 형태의 함수이기 때문에 기존에는 WMMSE와 같은 반복을 통해서 최적화를 하였으나, 사용자가 많을 경우 수렴하기에 많은 시간이 걸리기 때문에 실시간 동작이 어려울 수 있다.

III. 심층신경망 구조 및 학습과정

본 연구에서 고려된 심층신경망 구조는 [6]의 연구를 바탕으로 진행했으며 배치 정규화 과정을 추가시켰다. 배치 정규화는 심층신경망 구조 내부 노드들마다 정규화를 시켜주는 과정으로써, 각 층의 활성화 함수의 입력 값 혹은 출력값이 적절한 범위에 있도록 조절해주는 것이다. 배치 정규화를 사용함으로써 과적합을 방지하기 위한 dropout과 같은 기법을 대체 가능하며 학습률을 높게 설정할 수 있기 때문에 학습 속도 또한 개선이 가능하며 가중치 초기값 설정 및 가중치 손실에 대한 문제가 해결이 가능하다[7]. 배치 정규화를 포함한 전체 심층신경망의 구조는 위의 그림 2와 같은 심층신경망 구조를 갖게 된다.

본 연구의 학습과정은 다음과 같은 형태로 이뤄지며 신경망의 입력은 정규화 된 채널로 다음과 같다.

$$\hat{h}_{i,j} = \frac{h_{i,j} - E[h_{i,j}]}{\sqrt{E[(h_{i,j} - E[h_{i,j}])^2]}}. \quad (7)$$

배치 정규화 과정을 통해서 각 배치 데이터들의 평균과 표준편차를 구하여 신경망 내부에서 정규화 과정을 거치게 되며 다음과 같이 표현된다.

$$Y_{BN}[i,j] = \gamma \frac{\hat{h}_{i,j} - \mu}{\sqrt{\delta^2 + \epsilon}} + \eta \equiv BN(\hat{h}_{i,j}). \quad (8)$$

여기서, $BN()$ 은 배치 정규화 과정을 나타내며, 그림 2의 Batch Normalization (BN) 과정이다. 여기서, μ 와 δ 는 각각 배치 데이터의 평균과 표준편차, ϵ 은 분모가 0이 되는 것을 방지하는 값이다. 특히, γ 와 η 는 학습이 가능한 값이며 정규화 된 값의 크기와 이동을 가능하도록 하는 값이다. BN의 출력은 그림 2의 Rectified Linear Unit(ReLU)층의 입력이 되며 다음과 같이 표현된다.

$$Y_{ReLU}[i,j] = \max(Y_{BN}[i,j], 0). \quad (9)$$

여기서, ReLU는 $\max(\cdot, 0)$ 연산을 수행하여 음의 값을 제한하는 것이 가능하며 심층신경망에 비선형성을 제공할 수 있다. ReLU의 출력은 Convolution Layer의 입력으로 사용되며 Convolution Layer 연산은 다음과 같이 표현된다.

$$Y_{conv}[i,j] = \sum_{m=0}^2 \sum_{n=0}^2 Y_{ReLU}[m+i-1, n+j-1] W_C. \quad (10)$$

여기서, W_C 는 Convolution Layer의 가중치이자 필터이다. 8개의 3x3의 필터가 1의 보폭(stride)으로 연산

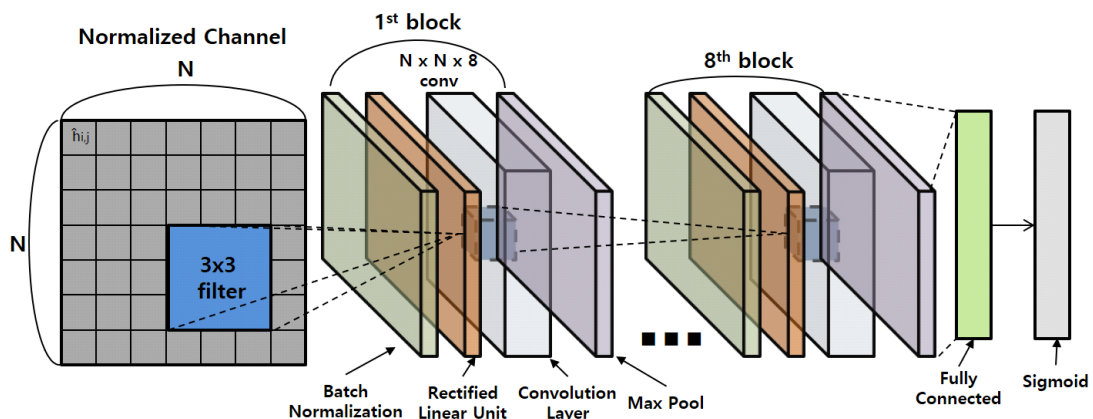


Fig. 2 CNN Model.

을 하게 되며 zero padding을 통해서 입력 채널의 $N \times N$ 배열의 크기가 작아지지 않도록 한다[8]. 그 이후 특징을 추출하는 그림 2의 Max Pool과정은 다음과 같이 표현된다.

$$Y_{\max}[i,j] = \max_{m=0,1,n=0,1} Y_{conv}[m+i-1,n+j-1]. \quad (11)$$

식 (11)은 Max Pool과정의 2×2 배열의 필터가 1의 보폭으로 4개의 값들 중 최댓값을 추출하는 과정을 표현한 것이며 Convolution Layer하고 동일하게 zero padding 과정을 거쳐서 $N \times N$ 배열이 작아지지 않도록 한다[8].

식(8)부터 (11) 과정을 8번 거친 후 그림 2의 fully connected (FC)층을 거치게 되며 다음과 같이 표현된다.

$$Y_{FC} = W_{FC}Y_{\max} + b_{FC}. \quad (12)$$

여기서, W_{FC} 와 b_{FC} 는 각각 FC의 가중치와 기준값이며, 이 때 FC의 입력의 배열은 Max Pool 출력의 배열을 재배열시킨 $1 \times N \times N \times 8$ 이다. 이를 N개의 출력을 갖도록 W_{FC} 와 b_{FC} 를 각각 $N \times N \times 8 \times N$, $1 \times N$ 의 배열로 설정한다. 마지막으로 FC의 출력은 그림 2의 Sigmoid 층의 입력으로 사용이 되며 다음과 같이 표현된다.

$$Y_{sig}[i] = \frac{1}{1 + e^{-Y_{FC}[i]}}. \quad (13)$$

여기서, Sigmoid 층은 출력을 0과 1사이로 제한시킬 수 있다. 즉, 값이 제한된 Y_{sig} 값에 P_t 을 곱하여 송신전력 P_t 의 범위를 0부터 P_t 사이로 설정할 수 있다.

본 연구는 주어진 심층신경망에서 Adam 최적화 방안을 통해서 (5)와 (6)의 최적화 문제를 해결한다[9]. 딥러닝의 최적화 함수들은 손실함수의 값을 감소시키는 방향으로 학습을 진행하며, 이 점을 착안하여 손실함수를 다음과 같이 각각 정의한다.

$$Loss_{SE} = - \sum_{1 \leq i \leq N} SE_i, \quad (14)$$

$$Loss_{EE} = - \sum_{1 \leq i \leq N} EE_i. \quad (15)$$

IV. 수치적 결과

본 장에서는 제안한 딥러닝 기반의 송신 전력 제어 (Deep Power Control, DPC)를 [6]의 연구에 비한 성능 비교와 페이딩 지수 m 의 변화에 따른 성능 변화를 보여 준다. 성능 검증은 시뮬레이션을 통해서 이루어지며 학습 시 $D = 40$ m, $N = 10$, $\alpha = 3.8$, $\beta = 10^{-3.453}$, $P_t = 43$ dBm, $P_C = 40$ dBm, $W = 10$ MHz, $N_0 = -174$ dBm/Hz로 설정했으며 [10], 학습 파라미터는 학습 데이터 20000개의 채널 샘플, 테스트 데이터 4000개의 채널 샘플, 배치 크기는 200, 학습률은 0.0001으로 설정한다.

그림 3과 4는 기존의 딥러닝 기반의 송신 전력 제어

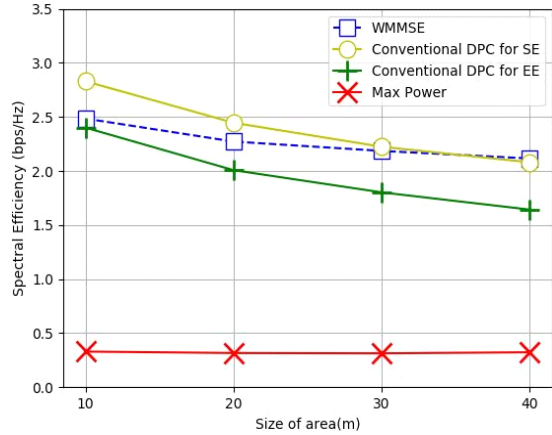


Fig. 3 Spectral efficiency with area size of conventional scheme.




Fig. 4 Energy efficiency with area size of conventional scheme.

기법[6]의 성능을 보여준다. 또한 성능 비교를 위하여[6]의 주파수 효율 최대화 기법 (Conventional DPC for SE)과 에너지 효율 최대화 기법 (Conventional DPC for EE), 모든 송신기의 송신전력을 최대 전력으로 설정한 법 (Max Power), WMMSE 기법에 대한 성능도 함께 보여준다. 주파수 또는 에너지 효율을 최대화 시키는 기법 [6]과 WMMSE 기법을 비교할 때, 최대화 기법이 우수한 성능을 보이는 것을 확인할 수 있다. Max Power 기법의 경우, 간섭의 영향을 많이 받아 성능이 가장 낮은 것을 확인할 수 있다.

그림 5와 6은 본 연구에서 제안하는 주파수 효율 최대화 기법(Proposed DPC for SE)과 에너지 효율 최대화

기법(Proposed DPC for EE)의 성능 결과와 기존의 딥러닝 기반의 송신 전력 제어 기법[6]의 성능 결과를 보여준다. 그림 5와 6으로부터 제안된 기법이 배치 정규화를 사용하여 채널값이 높은 사용자에게 전력을 할당하는 것이 기존의 기법보다 향상되어 주파수 및 에너지 효율이 기존의 기법에 비하여 우수한 것을 확인할 수 있다.

그림 7과 8에서 페이딩 지수 m 의 변화에 따른 기존의 기법[6]과 제안한 기법 및 WMMSE의 주파수 효율과 에너지 효율의 성능을 비교한다. m 의 증가에 따라 WMMSE는 주파수 및 에너지 효율의 변화가 거의 없지만, 딥러닝 기반 기존의 기법[6] 및 제안된 기법은 주파수 및 에너지 효율 성능이 개선됨을 확인할 수 있다.

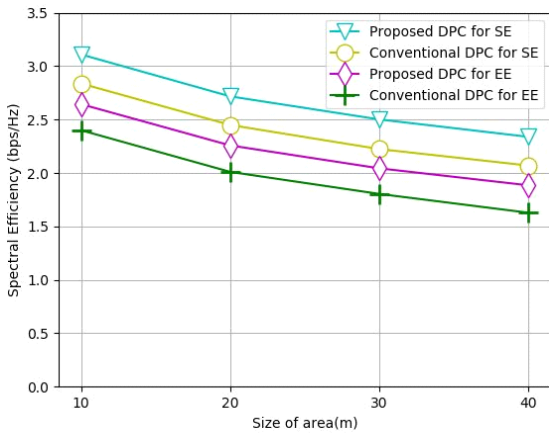


Fig. 5 Spectral efficiency with area size of proposed and conventional schemes.

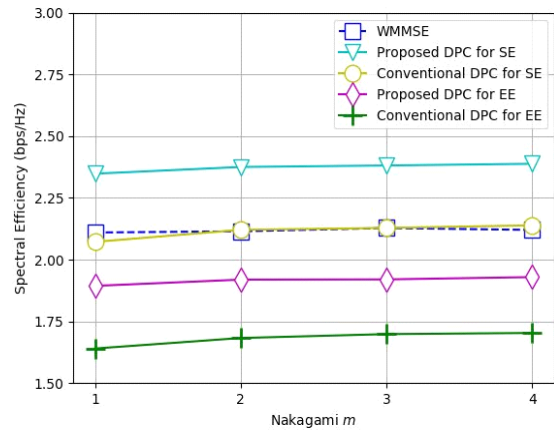


Fig. 7 Spectral efficiency with fading factor m of proposed and conventional schemes.

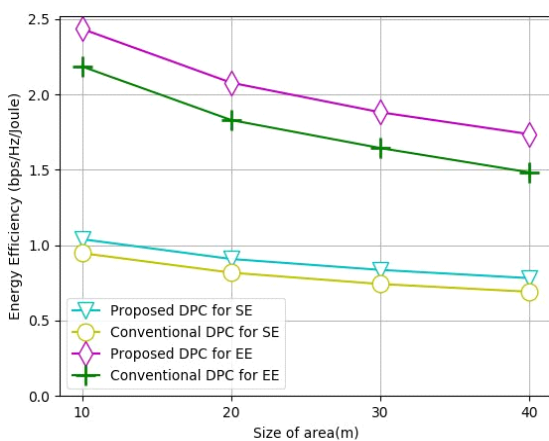


Fig. 6 Energy efficiency with area size of proposed and conventional schemes.

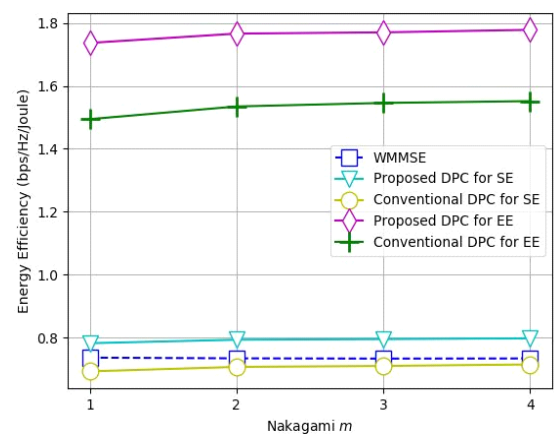


Fig. 8 Energy efficiency with fading factor m of proposed and conventional schemes.

여기서, 제안된 기법의 결과는 m 을 1로 고정하여 학습을 진행하여 얻어진 것이다. 즉, 제안된 송신 전력 제어 기법이 학습되지 않은 채널에서도 WMMSE 및 기존의 딥러닝 기반 송신 전력 제어 기법에 비해서 높은 주파수 및 에너지 효율을 제공할 수 있음을 보여준다.

V. 결 론

본 연구에서는 딥러닝 기반 송신 전력 제어 기법을 제안하였고, 나카가미 페이딩 채널을 가정한 시뮬레이션을 통해서 제안된 기법과 기존의 기법들의 성능을 분석하였다. 제안 기법은 무선 채널상태를 입력으로 받으며 각 송수신기쌍의 송신전력을 출력으로 하는 심층신경망을 기반으로 한다. 각 손실함수는 주파수 효율과 에너지 효율을 사용했으며 통신시스템에서 주파수 효율과 에너지 효율을 최대화할 수 있는 학습을 진행하였다. 시뮬레이션 결과를 통해 각각의 제안하는 학습방식들이 기존의 기법들보다 우수한 성능을 제공함을 확인하였다. 또한 페이딩 지수의 변화에 대한 성능 분석을 통해서 채널 환경의 변화에도 제안된 기법이 성능 향상에 도움을 줄 수 있음을 보였다.

ACKNOWLEDGEMENT

This research was supported by Basic Science Research Program through the National Research Foundation of Korea(NRF) funded by the Ministry of Education (Grant number: NRF-2018R1D1A1B07042499).

References

- [1] 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.
- [2] 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.
- [3] 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.
- [4] 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, Oct. 2018.
- [5] 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.
- [6] 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.
- [7] S. Ioffe, and C. Szegedy, "Batch normalization: accelerating deep network training by reducing internal covariate shift," *Proceedings of the 32nd International Conference on Machine Learning*, Lille: France, pp. 448-456, 2015.
- [8] K. Simonyan, and A. Zisserman. (2014). "Very deep convolutional networks for large-scale image recognition," [Internet]. Available: <https://arxiv.org/abs/1409.1556>.
- [9] Kingma, Diederik P., and Jimmy Ba. (2014) "Adam: A method for stochastic optimization," [Internet]. Available: <https://arxiv.org/abs/1412.6980>.
- [10] IEEE 802.20 Channel Models Document, *IEEE Standard 802.20-PD-08r1*, IEEE, Jan. 2007.




김동현(Donghyeon Kim)

2020년 2월 : 국립한경대학교 전기전자제어공학과 학사
2020년 3월 ~ 현재 : 국립한경대학교 전자전기공학부 석사과정
※관심분야 : 무선 통신 시스템, 딥러닝, 송신 전력 제어



김동연(Dongyon Kim)

1986년 2월 : 연세대학교 전자공학과 공학사
1988년 2월 : 연세대학교 전자공학과 공학석사
1995년 2월 : 연세대학교 전자공학과 공학박사
1988년 1월 ~ 1996년 8월 : 쉐데이콤 과장
1996년 9월 ~ 현재 : 국립한경대학교 전자전기공학부 교수
※관심분야 : 컴퓨터네트워크, 무선 통신 시스템



이인호(In-Ho Lee)

2003년 2월 : 한양대학교 전자컴퓨터공학부 학사
2005년 2월 : 한양대학교 전자전기제어계측공학과 공학석사
2008년 8월 : 한양대학교 전자전기제어계측공학과 공학박사
2008년 9월 ~ 2010년 4월 : 삼성전자 DMC 연구소 책임연구원
2010년 4월 ~ 2011년 3월 : 한양대학교 ERICA 부설연구소 공학기술연구소 박사후과정
2011년 3월 ~ 현재 : 국립한경대학교 전자전기공학부 교수
※관심분야 : 무선 협력 통신 시스템, MIMO 전송 기술, 무선자원관리 기술, 비직교 다중 접속 기술