JKIICE Journal of the Korea Institute of Information and Communication Engineering

한국정보통신학회논문지 Vol. 23, No. 8: 975~980, Aug. 2019

다중 사용자 다중 안테나 네트워크를 위한 심화 학습기반 사용자 스케쥴링

반태원[1] · 이웅섭[2*]

Deep Learning Based User Scheduling For Multi-User and Multi-Antenna Networks

Tae-Won Ban[1] · Woongsup Lee[2*]

[1]Assistant Professor, Department of Information and Communication Engineering, Gyeongsang National University, Tongyeong, 53064 Korea
[2*]Associate Professor, Department of Information and Communication Engineering, Gyeongsang National University, Tongyeong, 53064 Korea

요 약

본 논문에서는 차세대 이동통신 시스템의 핵심 요소 기술 중의 하나로 각광 받고 있는 다중 사용자 다중 안테나 네트워크에서 사용자 선택을 위한 심화 학습 기반 스케쥴링 기법을 제안한다. 제안된 신경망을 학습시키기 위하여 기존의 최적 방식을 통해서 90,000 데이터 샘플을 확보하였으며, 추가적인 10,000 데이터 샘플을 이용하여 최종 학습된 신경망의 과최적화 여부를 확인하였다. 제안된 신경망 기반의 스케쥴링 알고리즘은 초기 학습 시에는 상당한 복잡도와 학습 시간이 필요하지만, 일단 학습이 완료된 이후에는 추가적인 복잡도가 유발되지 않는 장점이 있다. 반면에, 기존의 최적 방식은 매 스케쥴링마다 동일한 복잡도의 계산이 지속적으로 요구된다. 다양한 컴퓨터 시뮬레이션 결과에 따르면, 제안된 심화 학습 기반의 스케쥴링 기법은 10dB 보다 낮은 SNR에서는 기존 최적 알고리즘의 약 88~96%에 이르는 평균 전송 속도의 합을 얻을 수 있으며, 10dB 이상의 SNR에서는 최적의 평균 전송 속도의 합을 얻을 수 있다.

ABSTRACT

In this paper, we propose a deep learning-based scheduling scheme for user selection in multi-user multi-antenna networks which is considered one of key technologies for the next generation mobile communication systems. We obtained 90,000 data samples from the conventional optimal scheme to train the proposed neural network and verified the trained neural network to check if the trained neural network is over-fitted. Although the proposed neural network-based scheduling algorithm requires considerable complexity and time for training in the initial stage, it does not cause any extra complexity once it has been trained successfully. On the other hand, the conventional optimal scheme continuously requires the same complexity of computations for every scheduling. According to extensive computer-simulations, the proposed deep learning-based scheduling algorithm yields about 88~96% average sum-rates of the conventional scheme for SNRs lower than 10dB, while it can achieve optimal average sum-rates for SNRs higher than 10dB.

키워드 : 다중 사용자, 다중 안테나, 빔포밍, 스케쥴링, 심화학습

Keywords : Multi-user, multi-antenna, beamforming, scheduling, deep learning

Received 18 June 2019, **Revised** 3 July 2019, **Accepted** 25 July 2019

*** Corresponding Author** Woongsup Lee(E-mail:wslee@gnu.ac.kr, Tel:+82-55-772-9174)
Associate Professor, Department of Information Communication Engineering, Gyeongsang National University, Tongyeong 53064, Korea

Open Access http://doi.org/10.6109/jkiice.2019.23.8.975 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/li-censes/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 급격히 증가하고 있는 무선 인터넷 트래픽을 효과적으로 수용하기 위하여 제한된 주파수 자원의 효율성을 높이기 위한 소형 셀 네트워크와 다중 안테나 기술 등이 많은 관심을 받고 있다 [1-3]. 특히, 다중 안테나 기술은 동일 주파수 대역에서 서로 다른 복수의 단말들에게 동시에 데이터를 전송함으로써 주파수 효율성을 획기적으로 개선할 수 있는 기술로써, 4세대 이동통신 뿐만 아니라 5세대 이동통신 네트워크의 핵심 요소 기술들 중의 하나이다. 그러나 많은 안테나를 쉽게 탑재할 수 있는 기지국과 달리, 단말은 크기, 비용, 그리고 복잡도 등의 문제로 인해서 많은 안테나를 탑재하기 쉽지 않다. 이러한, 안테나의 비대칭 문제를 해결하기 위하여 다중 사용자 다중 안테나 (Multi-User Multiple Input Multiple Output: MU-MIMO) 기법이 대안으로 거론되고 있다 [4-6]. MU-MIMO 시스템의 성능은 빔포밍 방식과 함께 동시에 데이터를 전송하는 단말의 수와 조합에 많은 영향을 받게 된다. 특히, 동시에 데이터를 전송할 최적의 단말 수와 조합을 찾는 문제는 높은 계산 복잡도를 유발할 뿐만 아니라, 복잡도는 전체 단말의 수가 증가할수록 기하급수적으로 증가한다.

본 논문에서는 기계 학습의 한 종류인 심화 학습을 이용하여 신경망을 학습시켜 MU-MIMO 시스템에서 동시에 데이터를 전송할 단말의 수와 단말의 조합을 찾는 알고리즘을 연구한다. 사용자 K명이 존재하는 다중 사용자 다중 안테나 네트워크의 성능 최적화를 위해서는, 특정 채널 계수들이 주어졌을 때 2^K개의 모든 사용자 조합에 대하여 빔 형성 계수들을 계산하여 데이터 전송 속도가 최대가 되는 사용자 조합을 찾는 완전 탐색 (Exhaustive searching) 방식이 필요하다. 이러한 방식은 사용자 수가 증가할수록 복잡도가 기하급수적으로 증가할 뿐만 아니라, 페이딩 환경에서 채널이 바뀔 때마다 동일한 절차가 반복적으로 수행되어야 하므로 그 복잡도로 인하여 실제 시스템에 적용은 불가능합니다. 따라서, 본 논문에서는 심화 학습을 이용하여 효율적인 사용자 선택 기법을 연구한다. 최근, 기계학습은 다양한 분야에서 널리 활용되고 있으며, 통신 시스템에서도 기계학습을 이용하기 위한 많은 연구가 이루어지고 있다 [7-12]. 먼저, 기계 학습을 활용한 네트워크 트래픽 제어 알고리즘이 연구되었고 [8], 심화 신경망(Deep Neural Network: DNN)을 이용하여 직교주파수분할다중화 (Orthogonal Frequency Division Multiplexing :OFDM) 시스템에서 채널 추정과 신호 감지 알고리즘이 연구되었다 [9]. 그리고, DNN을 활용한 거대 (Massive) MIMO 네트워크에서의 프리코딩 방식에 제안되었으며 [10], 심화 강화 학습(Deep Reinforcement Learning: DRL)을 이용하여 인지 위성 통신 시스템을 위한 무선 자원 할당 알고리즘이 제안되었다 [11]. 에너지 효율적인 DRL 기반 무인기 (Unmanned Aerial Vehicle: UAV) 제어 알고리즘이 제안되었다 [12]. 상대적으로 그 구조가 단순한 DNN은 쉽게 과최적화 되는 경향이 있는 반면에, 최근에 많은 각광을 받고 있는 DRL은 수많은 시도와 오류를 통해서 알고리즘이 도출되어야 하므로 학습에 많은 시간과 복잡도가 필요하다. 따라서, 본 논문에서는 심화 학습 신경망의 한 종류인 Convolutional Neural Network (CNN)을 활용하여 MU-MIMO 네트워크를 위한 사용자 스케쥴링 기법을 제안한다. CNN은 별도의 추출과정 없이 특징(feature)을 직접적으로 학습할 수 있어 이미지 인식 등에서 널리 활용되고 있다. 그리고, 다중 안테나 통신 네트워크에서 인접 안테나들 또는 인접 사용자들 간의 채널 및 경로 손실들 간에 상관도(correlation) 등을 고려할 때, 통신 네트워크에 적합한 학습 모델로 평가받는다. CNN도 학습 단계에서 무시할 수 없는 복잡도를 유발하지만, 이는 초기 학습 시에만 필요한 일회성이며 일단 학습이 완료되면 추가적인 복잡도 없이 스케쥴링이 이루어진다.

본 논문의 구성은 다음과 같다. 2장에서 본 논문에서 고려하는 MU-MIMO 시스템을 설명하고, 3장에서 CNN 기반 MU-MIMO 시스템용 스케쥴링 기법을 제안한다. 4장에서는 제안 방식의 성능을 정확도와 평균 전송 속도 측면에서 분석하고 이를 최적 방식과 비교한다. 마지막으로, 5장에서 본 논문의 결론을 맺는다.

Ⅱ. 시스템 모델

그림 1은 본 논문에서 고려하는 MU-MIMO 통신 시스템의 개념도를 보여준다. 기지국은 N개의 송신 안테나를 탑재하고 있으며, K명의 사용자를 서비스 한다. 각 사용자는 단일 수신 안테나를 가지고 있으며, $N \geq K$이다. s_k와 $\mathbf{v_k}$는 기지국이 사용자 $k(1 \leq k \leq K)$에 전

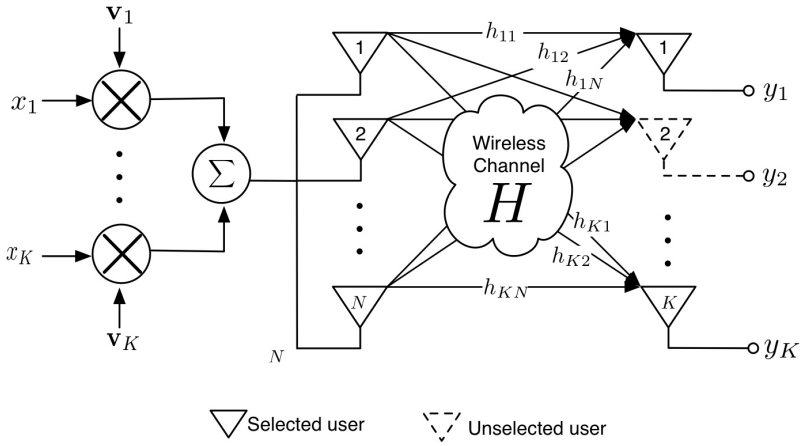

Fig. 1 An illustrative communication system of multi-user multi-antenna

송하는 정보와 $N\times 1$ 크기의 빔포밍 벡터를 각각 나타내고, $E\left[|s_k|^2\right]=1$와 $\|\mathbf{v_k}\|^2=1$를 만족한다. 기지국이 전체 K명 중에서 실제 데이터를 전송할 사용자들의 조합을 $\mathcal{S}$라고 하면, $\mathcal{S}$는 다음과 같이 전체 사용자들의 집합 $\mathcal{U}$의 부분집합이다.

$$\mathcal{S}\subset\{1,2,\cdots,K\}=\mathcal{U} \tag{1}$$

기지국이 실제 전송하는 신호 $\mathbf{x}$는 다음과 같이 주어진다.

$$\mathbf{x}=\sqrt{\frac{P}{|\mathcal{S}|}}\sum_{k\subset\mathcal{S}}\mathbf{v}_k s_k \tag{2}$$

여기서, P는 기지국의 전체 송신 전력을 나타내며 기지국은 데이터를 전송할 각 사용자에게 동일한 전력을 할당한다. 기지국 송신 안테나와 단말 수신 안테나 사이의 채널은 평균이 0이고 분산이 1인 복소 정규 분포 CN(0, 1)을 따르고 독립항등분포(independent and identically distributed:i.i.d.)이다. $\mathcal{S}$에 속하는 사용자 i가 수신하는 신호 y_i는 다음과 같이 표현된다.

$$y_{i\in\mathcal{S}}=\mathbf{h}_i\mathbf{x}+n_i \tag{3}$$

$\mathbf{h}_i$는 N개의 송신 안테나와 사용자 i의 수신 안테나 사이의 채널 정보를 원소로 가지는 $1\times N$의 행 벡터이며 n_i는 사용자 i 수신단에서의 부가 백색 가우시안 잡음(Additive White Gaussian Noise:AWGN)을 나타내며 $CN(0,N_0)$의 분포를 따른다. 사용자 i가 수신하는 신호 대 잡음간섭비 (Signal-to-Interference and Noise Ratio: SINR)는 다음과 같이 계산된다.

$$\begin{aligned} SINR_{i\in\mathcal{S}} &= \frac{\frac{P}{|\mathcal{S}|}\|\mathbf{h}_i\mathbf{v}_i\|^2}{N_0+\sum_{k=1,k\neq i}^{K}\frac{P}{|\mathcal{S}|}\|\mathbf{h}_k\mathbf{v}_k\|^2} \\ &= \frac{\frac{P}{N_0}\|\mathbf{h}_i\mathbf{v}_i\|^2}{|\mathcal{S}|+\frac{P}{N_0}\sum_{k\in\mathcal{S}k\neq i}\|\mathbf{h}_k\mathbf{v}_k\|^2} \\ &= \frac{\gamma\|\mathbf{h}_i\mathbf{v}_i\|^2}{|\mathcal{S}|+\gamma\sum_{k\in\mathcal{S}k\neq i}\|\mathbf{h}_k\mathbf{v}_k\|^2} \end{aligned} \tag{4}$$

식 (4)에서 두 번째 등호는 분모와 분자에 $\frac{|\mathcal{S}|}{N_0}$를 곱하여 얻어지며, γ는 $\frac{P}{N_0}$로 정의되며 송신 전력 대 잡음비(Signal-to-Noise Ratio: SNR)가 된다. 마지막으로, 식 (4)를 이용하여 MU-MIMO의 최적 전송률의 합은 다음과 같이 구할 수 있다.

$$C=\arg\max_{\mathcal{S}\subset\mathcal{U}}\sum_{i\in\mathcal{S}}\log_2(1+SINR_i) \tag{5}$$

식 (5)의 해답을 찾을 수 있는 유일한 알고리즘은 완전 탐색 방식으로 알려져 있다. 따라서, 기존의 최적 방식은 완전 탐색 방식을 통하여 사용자 조합을 선택하게 된다.

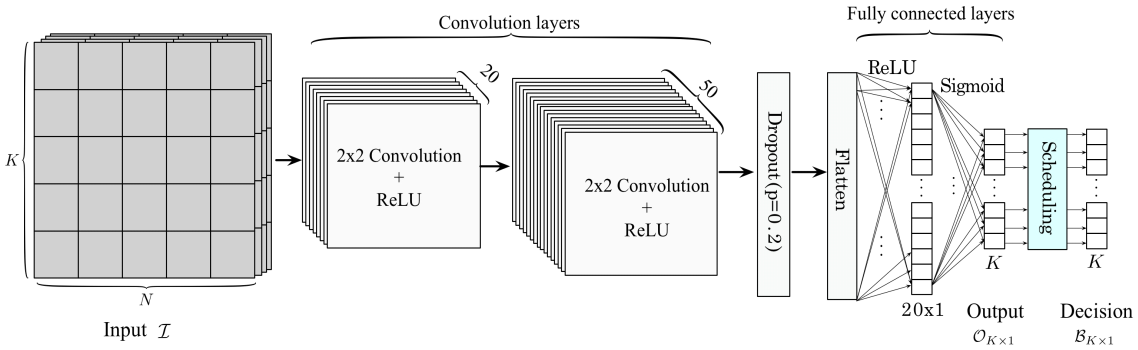

Fig. 2 The proposed scheme based on deep convolutional neural network

Ⅲ. CNN 기반의 제안 방식

그림 2는 본 논문에서 제안하는 MU-MIMO 네트워크의 사용자 스케쥴링을 위한 CNN의 구조를 보여준다. 두 개의 은닉 합성곱 계층으로 구성되어 있다. CNN의 입력은 N개의 송신 안테나와 K 사용자 사이의 채널 정보로 구성된 $K\times N$ 행렬로 구성이 된다. $K\times N$ 채널 정보의 실수부, 허수부, 신호 크기, 그리고 위상 정보를 각각의 차원으로 하여 최종 입력 I는 $4\times K\times N$의 3차원 행렬로 구성된다. 첫 번째 은닉 합성곱 계층은 20개의 합성곱 필터로 이루어져 있다. 각 필터의 크기는 인접 안테나간의 상관도 등을 고려하여 2×2로 설정하였으며, rectified linear unit(ReLU)[1] 함수에 의해서 활성화되어 진다. 두 번째 은닉 합성곱 계층은 2×2크기의 50개 합성곱 필터로 이루어져 있으며, 각 필터는 역시 ReLU 함수에 의해서 활성화된다. 모든 필터들은 Xavier normal initializer에 의해서 초기화 된다 [13]. 두 번째 합성곱 계층의 출력은 과최적화를 방지하기 위하여 드롭아웃(Dropout) 계층을 통과하면서 0.2의 확률로 랜덤하게 소거된 후, 완전 연결 계층을 통과하게 된다. 먼저, 평탄화(Flatten) 계층에 의해서 일차원 배열로 정렬되고, 다시 ReLU 함수에 의해 20×1 배열로 활성화된다. 식 (6)과 같이 정의된 Sigmoid 함수에 의해서 0과 1 사이의 값들을 가지는 $K\times1$ 배열 $\boldsymbol{O}$가 출력되며 이는 기지국이 각 사용자를 선택될 확률로 간주되어진다.

$$S(x)=\frac{1}{1+e^{-x}} \tag{6}$$

1) ReLU(x)=$\max(0,x)$

따라서, 배열 $\boldsymbol{O}$의 값에 따라서 다음과 같이 이진 배열 $\boldsymbol{B}$를 생성한다.

$$\boldsymbol{B}[i]=\begin{cases}1, \text{if } \boldsymbol{O}[i]\geq 0.5\\ 0, \text{otherwise}\end{cases}, 1\leq i\leq K \tag{7}$$

마지막으로, 배열 $\boldsymbol{B}$의 값에 따라서 각 사용자에게 데이터를 전송할지 여부를 결정한다. $\boldsymbol{B}[i]$가 1이면 사용자 i에게 데이터를 전송하며 $\boldsymbol{B}[i]$가 0인 경우에는 데이터를 전송하지 않는다. 제안된 CNN은 배열 $\boldsymbol{B}$와 기존 최적 방식을 통해서 확보된 스케쥴링 결과의 오류를 줄이는 방향으로 학습을 지속한다.

Ⅳ. 성능 분석

이번 장에서는 제안 방식의 성능을 정확도와 데이터 전송율 측면에서 분석하고 이를 기존 최적 방식의 성능과 비교한다. 먼저, 성능 분석을 위하여 block diagonalization 기반의 빔포밍 방식을 고려한다 [14]. 제안 방식의 사전 학습을 위하여 100,000 채널 샘플 데이터를 생성하였다. 그리고, 식 (5)의 해답을 찾을 수 있는 기존의 최적 방식을 이용하여 각 채널 샘플 데이터별로 성능을 최대화하는 최적의 단말 조합을 찾았다. 이러한 결과들 중에서, 90,000 데이터 샘플을 이용하여 제안된 CNN을 학습시키고, 나머지 10,000 데이터 샘플을 이용하여 학습된 CNN의 과최적화 여부를 검증하였다.

그림 3은 N=10, K=5일 때 다양한 γ 값들에 대하여, 기존 최적 방식 대비 제안 방식의 정확도 보여준다.

제안된 CNN 기반의 스케쥴링 기법은 식 (5)에 기반한 기존 최적 방식대비 약 80~100%에 이르는 정확도를 나타냄을 확인할 수 있으며, γ 값이 증가할수록 정확도가 향상됨을 알 수 있다. 그림 4는 N=10, K=5일 때 다양한 γ 값들에 대하여 제안 방식과 기존 최적 방식의 평균 전송 속도의 합을 보여준다. 제안된 방식은 SNR이 10dB보다 낮을 경우 기존 방식 대비 약 88~96%에 이르는 평균 전송 속도 합을 얻을 수 있으며, SNR이 10dB보다 같거나 높을 경우 최적 방식과 동일한 평균 전송 속도 합을 얻을 수 있다. 그리고, 별도의 검증 과정에서 학습 과정과 동일한 성능을 얻을 수 있음을 확인하였으며, 이는 제안된 심화 학습 기반의 스케쥴링 기법이 과최적화를 효과적으로 억제하였음을 나타낸다.

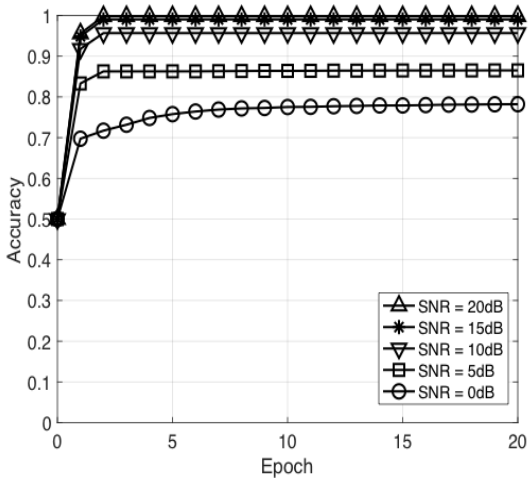

Fig. 3 Accuracies for various SNR (γ) when N=10 and K=5

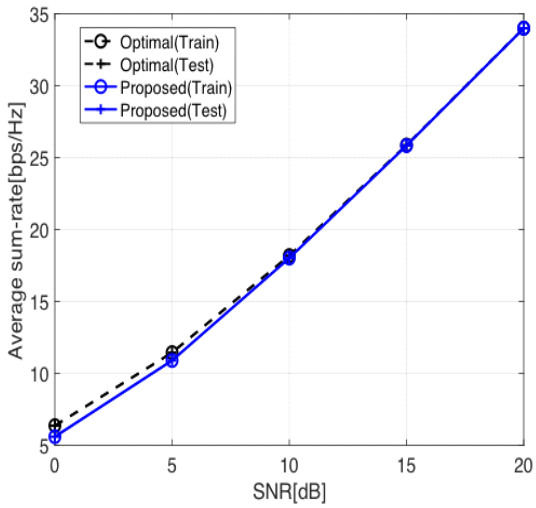

Fig. 4 Average sum-rates for various SNR (γ) when N=10 and K=5

Ⅴ. 결 론

본 논문에서는 주파수 효율성을 높임으로써 부족한 주파수 자원을 효율적으로 활용하기 위한 MU-MIMO 네트워크를 위한 사용자 스케쥴링 기법을 제안하였다. 제안된 스케쥴링 기법은 심화 학습 신경망의 한 종류인 CNN을 기반으로 하며 두 개의 합성곱 계층으로 이루어져 있다. 컴퓨터 시뮬레이션을 통해서 총 100,000 데이터 샘플을 확보하였으며, 확보된 각 샘플들에 대하여 기존 완전 탐색 방식을 활용하여 사용자 조합을 선택하였다. 90,000 샘플은 제안된 CNN을 학습시키기 위하여 사용되었으며 10,000 샘플은 학습된 CNN을 검증하기 위하여 사용되었다. 다양한 성능 분석 결과에 따르면, 제안된 방식은 10dB보다 낮은 SNR 환경에서 기존의 최적 방식대비 약 88~96%의 평균 전송 속도의 합을 얻을 수 있었으며, 10dB 이상의 SNR 환경에서는 최적 방식과 동일한 성능을 얻을 수 있었다. CNN 기반의 제안된 스케쥴링 기법은 초기에만 학습을 위한 오버헤드가 유발되며, 지속적으로 완전 탐색을 요구하는 기존의 최적 방식과 달리 학습이 완료된 이후에는 추가적인 오버헤드가 필요하지 않은 장점이 있다.

ACKNOWLEDGEMENT

This work was supported by Institute for Information & communications Technology Promotion (IITP) grant funded by the Korea government (MSIT) (No.2015- 0-00820, A research on a novel communication system using storage as wireless communication resource).

REFERENCES

[1] Cisco, Visual Networking Index: Global Mobile Data Traffic Forecast Update, 2017-2022, Whitepaper, 2018. [Internet] Available : https://www.cisco.com/c/en/us/solutions/collateral/service-provider/visual-networking-index-vni/white-paper-c11-741490.html

[2] Small Cell Forum [Internet]. Available: http://smallcellforum.org

[3] 3GPP Specification, TS 36.300 v11.5.0 E-UTRA and E-UTRAN Overall description;Stage 2 (Release 11)

[4] G. Lee, J. Park, Y. Sung, and J. Seo, "A new approach to beamformer design for massive MIMO systems based on k-regularity," in *Proceeding. of IEEE Globecom*, pp. 686-690, Dec. 2012

[5] R. W. Heath, S. Sandhu, and A. Paulraj, "Antenna Selection for Spatial Multiplexing Systems with linear receivers," *IEEE Communication Letters*, vol. 5, no. 4, pp. 142-144, Apr. 2001.

[6] T.-W Ban and B. C. Jung, "Adaptive User Selection in Downlink Multi-User MIMO Networks," *Journal of the Korea Institute of Information and Communication Engineering*, vol. 17, no. 7, pp. 1597-1601, July 2013.

[7] K. Arulkumaran, M. P. Deisenroth, M. Brundage, and A. A. Bharath, "Deep Reinforcement Learning: A Brief Survey," *IEEE Signal Processing Magazine*, vol. 34, no. 6, pp. 26-38, Nov. 2017.

[8] Z. Md. Fadlullah, F. Tang, B. Mao, N. Kato, O. Akashi, T. Inoue, and K. Mizutani, "State-of-the-Art Deep Learning :Evolving Machine Intelligence Toward Tomorrow's Intelligent Network Traffic Control Systems," *IEEE Communications Surveys & Tutorials*, vol. 19, no. 4, pp. 2432-2455, Fourthquarter 2017.

[9] H. Ye, G. Y. Li, and B. Juang, "Power of Deep Learning for Channel Estimation and Signal Detection in OFDM Systems," *IEEE Wireless Communications Letters*, vol. 7, no. 1, pp. 114-117, Feb. 2018.

[10] H. Huang, Y. Song, J. Yang, G. Gui, and F. Adachi, "Deep-Learning- Based Millimeter-Wave Massive MIMO for Hybrid Precoding," *IEEE Transactions on Vehicular Technology*, vol. 68, no. 3, pp. 3027-3032, Mar. 2019.

[11] P. V. R. Ferreira, R. Paffenroth, A. M. Wyglinski, T. M. Hackett, S. G. Bilen, R. C. Reinhart, and D. J. Mortensen, "Multiobjective Reinforcement Learning for Cognitive Satellite Communications Using Deep Neural Network Ensembles," *IEEE Journal on Selected Areas in Communications*, vol. 36, no. 5, pp. 1030-1041, May 2018.

[12] C. H. Liu, Z. Chen, J. Tang, J. Xu, and C. Piao, "Energy-Efficient UAV Control for Effective and Fair Communication Coverage: A Deep Reinforcement Learning Approach," *IEEE Journal on Selected Areas in Communications*, vol. 36, no. 9, pp. 2059-2070, Sep. 2018.

[13] B. Hanin and D. Rolnick, "How to Start Training: The Effect of Initialization and Architecture," *Advances in Neural Information Processing Systems*, 2018.

[14] S. Shim, J. S. Kwak, R. W. Heath, and J. G. Andrews, "Block diagonalization for multi-user MIMO with other-cell interference," *IEEE Transactions Wireless Communications*, vol. 7, no. 7, pp. 2671-2681, July 2008.

반태원(Tae-Won Ban)

2010년 2월 KAIST 전기전자공학과 박사
2000년 2월~2012년 8월 KT 네트워크부문
2012년 9월~현재 경상대학교 정보통신공학과 부교수
※ 관심분야 : 이동통신, 자원관리, 간섭관리, 협력 및 중계통신, 인지통신, 주파수 공유

이웅섭(Woongsup Lee)

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