

비직교 다중 접속 기반 이종 네트워크에서 딥러닝 알고리즘을 이용한 사용자 및 전력 할당 기법

김동현¹ · 이인호^{2*}

User Association and Power Allocation Scheme Using Deep Learning Algorithm in Non-Orthogonal Multiple Access Based Heterogeneous Networks

Donghyeon Kim¹ · 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 하나의 매크로 기지국과 다수의 소형 기지국들로 구성된 이종 네트워크 (Heterogeneous Network, HetNET) 시스템에서 비직교 다중 접속 (Non-Orthogonal Multiple Access, NOMA) 기술을 고려한다. 여기서, NOMA 신호에 대하여 완벽한 순차적 간섭 제거를 가정한다. 본 논문에서는 이러한 NOMA 기반의 이종 네트워크에서 데이터 전송률을 최대화하기 위하여 딥러닝 기반의 사용자 및 전력 할당 기법을 제안한다. 특히, 제안하는 기법은 부하 분산을 위한 심층신경망 (Deep Neural Network, DNN) 기반의 사용자 할당 과정과 할당된 사용자에게 대한 데이터 전송률의 최대화를 위한 DNN 기반의 전력 할당 과정을 포함한다. 기지국과 사용자간 경로 손실과 레일레이 페이딩 채널을 가정한 시뮬레이션을 통해 제안하는 기법의 성능을 평가하고, 기존의 최대 신호 대 간섭 및 잡음비 (Max-Signal-to-Interference-plus-Noise Ratio, Max-SINR) 기법의 성능과 비교한다. 성능 비교를 통해서 제안된 기법이 기존의 Max-SINR 기법보다 높은 데이터 전송률을 제공하는 것을 보여준다.

ABSTRACT

In this paper, we consider the non-orthogonal multiple access (NOMA) technique in the heterogeneous network (HetNET) consisting of a single macro base station (BS) and multiple small BSs, where the perfect successive interference cancellation is assumed for the NOMA signals. In this paper, we propose a deep learning-based user association and power allocation scheme to maximize the data rate in the NOMA-based HetNET. In particular, the proposed scheme includes the deep neural network (DNN)-based user association process for load balancing and the DNN-based power allocation process for data-rate maximization. Through the simulation assuming path loss and Rayleigh fading channels between BSs and users, the performance of the proposed scheme is evaluated, and it is compared with the conventional maximum signal-to-interference-plus-noise ratio (Max-SINR) scheme. Through the performance comparison, we show that the proposed scheme provides better sum rate performance than the conventional Max-SINR scheme.

키워드 : 딥러닝, 이종 네트워크, 비직교 다중 접속, 전력 할당, 사용자 할당

Keywords : Deep learning, Heterogeneous network, Non-orthogonal multiple access, Power allocation, User association

Received 27 December 2021, Revised 3 January 2022, Accepted 17 January 2022

* 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.2022.26.3.430>

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

비직교 다중 접속 (Non-Orthogonal Multiple Access, NOMA) 시스템은 5G 무선 통신에서 주파수 효율을 향상시킬 수 있는 다중 접속으로 주목 받고 있다[1-2]. NOMA 시스템은 송신부의 중첩 코딩(Superposition Coding)과 수신부의 순차적 간섭 제거(Successive Interference Cancellation, SIC)를 사용하고, 전력 영역에서 다중 접속을 하는 특징이 있다. NOMA 시스템의 전력 영역 다중 접속의 특성에 의해서, 무선 서비스의 품질 및 시스템의 용량을 증가시키기 위한 무선 자원 관리 기법 중 송신 전력의 제어는 반드시 필요하다. 하지만, 기존의 무선 자원 할당 문제는 많은 반복을 통한 수렴 방식으로 실시간 사용 시 어렵다는 단점이 있다 [3-5].

위와 같은 이유로, 최근 NOMA 시스템에서 기계 학습 기반의 송신 전력 제어가 활발하게 이루어지고 있다 [6-10]. 기계 학습은 학습을 통한 수렴 방식으로 실시간 사용 시 추가적인 수렴 과정이 없어 복잡성이 적다는 특징이 있다. [6-8]에서는 정답 데이터를 기반으로 학습하는 지도 학습을 통해 송신 전력을 제어했고, 학습이 수렴되면 정답 데이터와 유사한 성능을 제공하는 것이 가능하다. [9-10]에서는 현재 상태에서 행동을 수행하고 행동에 대한 보상을 통해 학습을 하는 강화 학습을 기반으로 송신 전력을 제어했다. 하지만, [6-10]과 같은 지도 학습 및 강화 학습 알고리즘은 라벨링 데이터의 수집과 행동들에 대한 보상을 얻기 위한 탐험(Exploration) 및 탐욕(Exploitation)적인 시행착오 과정이 필요하기 때문에 비교적 학습의 복잡도가 큰 편이다. 반면에, [11-14]에서 제안된 비지도 학습 기법은 주어진 학습 모델과 손실 함수만으로 학습이 되기 때문에 비교적 학습 복잡도가 낮고, 본 논문에서도 비지도 학습 기반의 딥러닝 기법으로 학습 복잡도를 감소시킨다.

본 연구는 하향링크 NOMA 기반의 이종 네트워크 (Heterogeneous Network, HetNET) 시스템에서 데이터 전송률을 최대화하는 기법을 제안한다. 특히, [6-10]에서는 한 기종의 기지국(Base Station, BS)만 고려하지만 한정된 영역에 많은 사용자가 밀집될 경우, 높은 트래픽을 효율적으로 수용할 수 있는 HetNET이 고려되어야 한다. 특히, HetNET에서는 각 사용자들이 적절한 BS에 접속할 수 있는 사용자 할당이 고려되어야 한다. 하지만, 기존 비지도 학습 기법에서는 한 기종의 BS만 고려

하기 때문에 사용자 기법을 고려하지 않고, 기존의 사용자 할당에서 고려되는 최대 신호 대 간섭 및 잡음비 (Max-Signal-to-Interference-plus-Noise Ratio, Max-SINR) 기법 같은 경우에도 효율적으로 사용자를 할당하는 것이 힘들다. 따라서, 본 논문에서는 이 문제를 해결할 수 있는 딥러닝 기반 사용자 및 전력 할당 기법을 제안하고, 제안된 사용자 할당 기법이 전체 사용자의 데이터 전송률의 합을 향상시킬 수 있음을 보여준다.

II. 시스템 모델

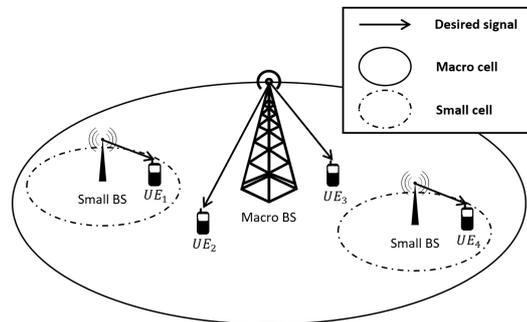


Fig. 1 HetNET system model for user association and transmit power allocation

본 연구에서는 그림 1과 같이 매크로 셀 내부에 소형 BS들이 랜덤하게 분포되어 있는 다운링크 NOMA 기반 HetNET 시스템을 가정한다. 여기서 BS와 모든 단말기는 단일 송수신 안테나를 이용한다. 본 연구에서는 사용자 할당과 전력 할당의 문제를 고려하고, 매크로 BS와 소형 BS들의 집합이 $\mathcal{B} = \{1, 2, \dots, b, \dots, B\}$ 이고, 사용자들의 집합이 $\mathcal{M} = \{1, 2, \dots, m, \dots, M\}$ 라고 정의할 때, 기지국과 사용자 사이의 사용자 할당 색인의 집합은 $\mathbf{X} = \{x_{1,1}, x_{1,2}, \dots, x_{b,m}, \dots, x_{B,M}\}$ 로 정의된다. 여기서 사용자 m 이 기지국 b 에게 할당될 경우, $x_{b,m} = 1$ 이고, 반대일 경우, $x_{b,m} = 0$ 이다. 이 때, 기지국과 사용자 사이의 채널은 0의 평균과 1의 분산을 갖는 레일레이 페이딩과 경로 손실로 구성되고, 기지국 b 와 사용자 m 사이의 채널 전력은 다음과 같이 표현된다.

$$h_{b,m} = |g_{b,m}|^2 d_{b,m}^{-\alpha}, \quad (1)$$

여기서, $g_{b,m}$ 는 레일레이 채널의 복소 계수이고, α 와

$d_{b,m}$ 는 각각 경로 손실 지수와 기지국 b 와 사용자 m 사이의 거리이다.

본 논문의 NOMA기반 HetNET 시스템에서 고려하는 전력할당을 위해, 기지국 b 의 각 사용자의 채널 전력은 $h_{b,1} < h_{b,2} < \dots < h_{b,M}$ 을 따르고, 완벽한 SIC가 가정된 기지국 b 와 사용자 m 사이의 데이터 전송률은 다음과 같다.

$$R_{b,m} = \log_2 \left(1 + \frac{x_{b,m} h_{b,m} a_{b,m} \rho_{\max}^b}{h_{b,m} \sum_{k=1}^{m-1} x_{b,k} a_{b,k} \rho_{\max}^b + \sum_{i=1, i \neq b}^B h_{i,m} \sum_{j=1}^M x_{i,j} a_{i,j} \rho_{\max}^j + 1} \right), \quad (2)$$

여기서, ρ_{\max}^b 는 기지국 b 의 송신 신호 대 잡음 비 (Signal to Noise Ratio)이고 각 기지국의 최대 송신 전력 P_{\max}^b 와 각 단말기의 잡음 전력 σ^2 으로 이뤄진다. 각 단말기의 잡음 전력은 같다고 가정하고, $\rho_{\max}^b = P_{\max}^b / \sigma^2$ 이다. 또한, 기지국 b 와 사용자 m 의 전력 할당 계수 $a_{b,m}$ 은 $0 \leq a_{b,m} \leq 1$ 과 $\sum_{m=1}^M a_{b,m} = 1$ 의 조건을 따르고, SIC를 기반으로 자신의 신호를 얻기 위해, $a_{b,1} < a_{b,2} < \dots < a_{b,M}$ 의 전력 할당 계수의 조건을 만족해야 한다.

본 논문에서는 각 사용자가 하나의 BS에게만 접속하고, 데이터 전송률의 합계를 최대화하는 최적화 문제를 고려하고 다음과 같이 표현된다.

$$\begin{aligned} & \max \sum_{b=1}^B \sum_{m=1}^M R_{b,m}, \\ & \text{s.t. } \sum_{b=1}^B x_{b,m} = 1, \forall m \in \mathcal{M}, \\ & \sum_{m=1}^M a_{b,m} = 1, \forall b \in \mathcal{B}, \\ & a_{b,1} < a_{b,2} < \dots < a_{b,M}, \forall b \in \mathcal{B}. \end{aligned} \quad (3)$$

III. 심층신경망 구조 및 학습과정

본 연구는 그림 2와 같은 심층신경망(Deep Neural Network, DNN)을 기반으로 사용자 할당 색인 및 전력 할당 계수를 도출한다. 고려된 심층신경망은 사용자 할당 및 전력 할당의 두 과정으로 분리되고, 두 과정 모두

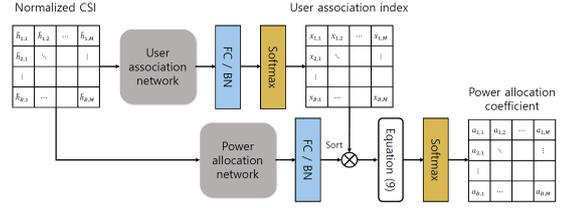


Fig. 2 Proposed DNN model for user association and power allocation processes

입력을 정규화된 채널 상태 정보 (Channel State Information, CSI)를 사용하고, CSI 정규화 과정은 다음과 같다.

$$\hat{h}_{b,m} = \frac{\log_{10} h_{b,m} - E[\log_{10} h_{b,m}]}{\sqrt{E[(\log_{10} h_{b,m} - E[\log_{10} h_{b,m}])^2]}}. \quad (4)$$

식 (4)의 정규화된 CSI는 사용자 및 전력 할당 네트워크의 입력으로 사용되고, 각 네트워크는 완전 연결 (Fully Connected, FC) 신경망을 기반으로 구성된다. 사용자 할당 네트워크는 128의 크기를 갖는 1개의 FC 신경망을 갖고, 배치 정규화 (Batch Normalization, BN) 과정 [15]을 통해 신경망 내부를 정규화 시키고, 활성화 함수는 음의 값을 제한하는 rectified linear unit (ReLU) 함수를 사용한다. 여기서, FC 신경망은 $F(\mathbf{X}) = \mathbf{W}\mathbf{A} + \mathbf{s}$ 연산을 수행하고, \mathbf{A} 는 신경망의 입력, \mathbf{W} 와 \mathbf{s} 는 각 층의 가중치 행렬 및 기준값 벡터다. 그 이후 한 번 더 FC와 BN 과정을 수행하고, FC 과정은 출력 크기를 BM 으로 제한한다. FC와 BN 과정의 출력을 $B \times M$ 의 크기로 변환한 행렬이 \mathbf{T} 일 때, 각 사용자의 할당을 확률의 형태로 전환하기 위해 Softmax 연산을 수행하고 다음과 같다.

$$x_{b,m} = \frac{e^{T_{b,m}}}{\sum_{k=1}^B e^{T_{k,m}}}, \forall m \in \mathcal{M}, \quad (5)$$

여기서, $T_{b,m}$ 은 \mathbf{T} 의 (b,m) 번째 원소이고, Softmax 함수의 특성상 $\sum_{b=1}^B x_{b,m} = 1$ 이 되기 때문에 m 번째 사용자가 할당할 BS를 확률적으로 표현하는 것이 가능하다.

식 (5)를 통해 얻어진 사용자 선택 색인의 확률은 식 (3)의 최적화 문제를 해결하기 위해 각 신경망의 \mathbf{W} 와 \mathbf{s} 를 학습하고, 학습을 위한 비용 함수는 다음과 같이 표현된다.

$$L^U = - \sum_{b=1}^B \sum_{m=1}^M R_{b,m}, \quad (6)$$

여기서, $R_{b,m}$ 의 전력 할당 계수 $a_{b,m}$ 은 모두 $a_0 = 1/M$ 으로 고정된 값을 사용한다. 본 논문에서는 Adam 최적화 방식[16]을 통해서 학습을 진행하고, 학습 후 수렴된 $x_{b,m}$ 은 m 사용자가 할당될 수 있는 BS들 중 데이터 전송률을 최대화 할 수 있는 사용자 할당 색인 확률 중 가장 높은 값만 1로 색인하고, 나머지는 0으로 색인되고, 다음과 같이 표현된다.

$$x_{b,m} = \begin{cases} 1 & \text{if } b = \arg \max_b(x_{b,m}), \\ 0 & \text{otherwise,} \end{cases} \quad (7)$$

사용자 할당 학습 과정이 종료된 후, 식 (4)의 정규화된 CSI를 기반으로 전력 할당 학습 과정을 수행한다. 여기서, 그림 2의 전력 할당 네트워크는 2개의 128의 크기를 갖는 FC층을 갖고, 각 층에서 BN 과정을 수행하고, ReLU 함수를 사용한다. 그 후 BM 크기를 갖도록 하는 FC 과정과 BN 과정의 출력은 $B \times M$ 의 크기로 변환되고, $a_{b,1} < a_{b,2} < \dots < a_{b,M}$ 을 만족하기 위해 오름차순으로 정렬되고, 학습이 종료된 사용자 할당 네트워크의 출력인 \mathbf{X} 와 곱해진다. 이 때, 사용자 할당이 곱해진 행렬을 \mathbf{Y} 라고 정의하고, 식 (5)와 같은 Softmax 함수의 입력이 된다. 이 때, \mathbf{Y} 가 0으로 색인된 부분이 Softmax 함수의 출력도 0이 되도록 추가적인 연산이 필요하고 다음과 같다.

$$Z_{b,m} = \begin{cases} -\infty & \text{if } Y_{b,m} = 0, \\ Y_{b,m} & \text{otherwise,} \end{cases} \quad (8)$$

여기서, $Y_{b,m}$ 은 행렬 \mathbf{Y} 의 (b,m) 번째 원소이고, $Z_{b,m}$ 은 그림 2의 전력 할당 과정의 Softmax 함수 입력 행렬 \mathbf{Z} 의 (b,m) 번째 원소이다. \mathbf{Z} 를 이용한 Softmax 함수 과정은 다음과 같다.

$$a_{b,m} = \frac{e^{Z_{b,m}}}{\sum_{k=1}^M e^{Z_{b,k}}}, \quad \forall b \in \mathcal{B}, \quad (9)$$

여기서, Softmax의 함수 특성 때문에 전력 할당 계수 $a_{b,m}$ 은 $0 \leq a_{b,m} \leq 1$ 과 $\sum_{m=1}^M a_{b,m} = 1$ 을 만족하고, 오름차순으로 정렬된 \mathbf{Y} 에 의해서 $a_{b,1} < a_{b,2} < \dots < a_{b,M}$ 또

한 만족한다. 또한, 식 (8)에서 \mathbf{Y} 가 0으로 색인된 값은 $-\infty$ 로 설정되고, 식 (9)의 Softmax 함수 특성상 $-\infty$ 로 설정된 사용자의 전력 할당 계수는 값이 0이 된다. 즉, 사용자 m 이 기지국 b 에게 할당될 경우에만 전력이 할당되고, 할당이 안 될 경우 전력이 할당이 안 된다.

그림 2에서 제안된 DNN 구조를 기반으로 식 (3)의 전력 할당 계수의 제약조건을 해결할 수 있고, 데이터 전송률을 최대화하기 위한 비용함수는 다음과 같다.

$$L^P = - \sum_{b=1}^B \sum_{m=1}^M R_{b,m}, \quad (10)$$

여기서, $R_{b,m}$ 의 $x_{b,m}$ 은 학습이 수렴된 사용자 할당 과정을 통해서 얻어진 사용자 할당 색인값을 사용한다. 또한, 식 (6)과 같이 Adam 최적화 방식을 통해서 학습을 진행한다. 오프라인 학습을 가정했을 때, 충분히 수집된 CSI를 기반으로 식 (6)과 (10)의 학습 과정이 종료되면 수렴된 DNN 구조는 추가적인 수렴 과정 없이 사용자 할당 색인 및 전력 할당 계수를 도출하는 것이 가능하다.

IV. 수치적 결과

본 장에서는 제안한 딥러닝 기반의 사용자 및 전력 할당 기법의 성능을 분석한다. 여기서, 매크로 BS의 직경은 100m이고 α 는 3이며 매크로 BS의 최대 송신전력은 45dBm이고 소형 BS의 최대 송신전력은 40dBm이고 σ^2 은 0dBm이고 B 는 4이고 M 은 50이다. 학습 데이터 및 테스트 데이터는 각각 100000, 10000개를 각각 생성하고, 배치 데이터 및 학습률은 각각 10000, 0.0001이다.

그림 3에서는 제안된 DNN 기반의 기법과 Max-SINR 기법의 사용자 할당 과정을 비교한다. 두 기법을 비교했을 때, DNN 기반의 기법은 매크로 BS에 35명의 사용자가 할당되고, 소형 BS들에 각각 5명의 사용자가 할당되

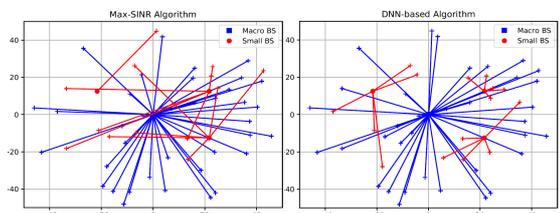


Fig. 3 Relationship between user and BS by Max-SINR and DNN-based algorithm.

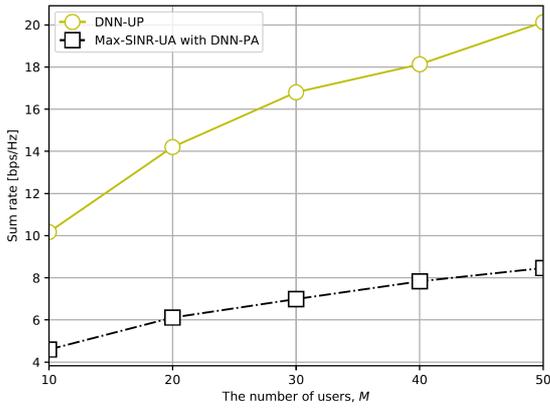


Fig. 4 Sum-rate of Max-SINR and DNN schemes with $B=4$.

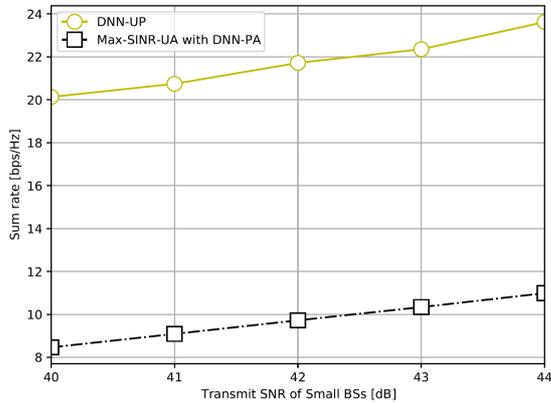


Fig. 6 Sum-rate of Max-SINR and DNN schemes with $B=4$ and $M=50$.

었다. 반면에, Max-SINR 기법은 매크로 BS에 37명의 사용자, 그리고 하나의 소형 BS에 1명 그리고 나머지 소형 BS에 6명이 할당되었다. 그림 3을 통해서 Max-SINR 기법이 DNN 기반의 기법에 비해서 매크로 BS에 많은 트래픽이 부담되기 때문에 부하 분산이 적절하게 이뤄지지 않은 것을 알 수 있다.

그림 4부터 6에서는 제안된 DNN 기반의 사용자 할당 및 전력 할당 (DNN-Based User Association and Power Allocation, DNN-UP) 기법과 Max-SINR 기반의 사용자 할당 및 DNN 기반 전력 할당 (Max-SINR-Based User Association with DNN-Based Power Allocation, Max-SINR-UA with DNN-PA) 기법의 성능을 비교한다. 그림 4는 매크로 BS 1개와 소형 BS 3개가 있을 때 사용자의 수 M 에 따른 데이터 전송률의 합계율

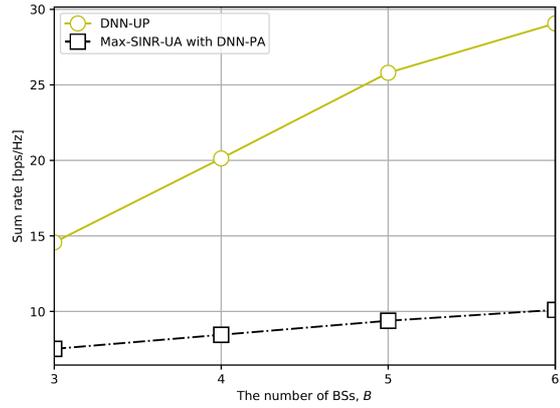


Fig. 5 Sum-rate of Max-SINR and DNN schemes with $M=50$.

의 변화를 보여준다. 그리고, 그림 5와 6은 각각 M 이 50 일 때 BS의 수에 따른 합계율의 변화, B 는 4이고 M 은 50이며 매크로 BS의 송신 전력이 45dBm일 때, 소형 BS의 송신 전력에 따른 합계율의 변화를 보여준다. 각각의 그림들을 통해서 제안된 DNN 기반의 사용자 할당 기법이 합계율을 크게 향상시킬 수 있는 것을 알 수 있다.

V. 결론

본 연구에서는 NOMA 기반 HetNET 시스템에서 딥러닝 기반의 사용자 및 전력 할당 기법을 제안했다. 제안된 기법은 제안된 사용자 할당 및 송신 전력 할당 과정을 손실 함수를 통해서 학습시켜 데이터 전송률을 최대화 한다. 또한 제안된 DNN 구조는 사용자 할당을 하고, 할당된 사용자에게만 송신 전력을 할당을 하는 것이 가능하다. 시뮬레이션을 통해서 제안된 사용자 할당 기법이 Max-SINR 기법보다 높은 합계율을 갖는 것을 확인하고, 부하 분산을 적절히 한 것을 알 수 있다.

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] V. W. S. Wong, R. Schober, D. W. K. Ng, and L. -C. Wang, *Key Technologies for 5G Wireless Systems*. U.K.: Cambridge Univ. Press, 2017.

[2] O. Maraqa, A. S. Rajasekaran, S. Al-Ahmadi, H. Yanikomeroglu and S. M. Sait, "A Survey of Rate-Optimal Power Domain NOMA With Enabling Technologies of Future Wireless Networks," *IEEE Communications Surveys & Tutorials*, vol. 22, no. 4, pp. 2192-2235, Aug. 2020.

[3] W. Lu, M. Liu, S. Lin, and L. Li, "Fully Decentralized Optimal Power Flow of Multi-Area Interconnected Power Systems Based on Distributed Interior Point Method," *IEEE Transactions on Power Systems*, vol. 33, no. 1, pp. 901-910, Jan. 2018.

[4] 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.

[5] K. Shen and W. Yu, "Fractional Programming for Communication Systems—Part I: Power Control and Beamforming," *IEEE Transactions on Signal Processing*, vol. 66, no. 10, pp. 2616-2630, May. 2018.

[6] N. Yang, H. Zhang, K. Long, H. -Y. Hsieh, and, J. Liu, "Deep Neural Network for Resource Management in NOMA Networks," *IEEE Transactions on Vehicular Technology*, vol. 69, no. 1, pp. 876-886, Jan. 2020.

[7] W. Saetan and S. Thipchaksurat, "Power Allocation for Sum Rate Maximization in 5G NOMA System with Imperfect SIC: A Deep Learning Approach," in *Proceedings of the 2019 4th International Conference on Information Technology (InCIT)*, pp. 195-198, 2019.

[8] J. Luo, J. Tang, D. K. C. So, G. Chen, K. Cumanan, and J. A. Chambers, "A Deep Learning-Based Approach to Power Minimization in Multi-Carrier NOMA With SWIPT," *IEEE Access*, vol. 7, pp. 17450-17460, Jan. 2019.

[9] L. Xiao, Y. Li, C. Dai, H. Dai, and H. V. Poor, "Reinforcement Learning-Based NOMA Power Allocation in the Presence of Smart Jamming," *IEEE Transactions on Vehicular Technology*, vol. 67, no. 4, pp. 3377-3389, Apr. 2018.

[10] K. N. Doan, M. Vaezi, W. Shin, H. V. Poor, H. Shin, and T. Q. S. Quek, "Power Allocation in Cache-Aided NOMA Systems: Optimization and Deep Reinforcement Learning Approaches," *IEEE Transactions on Communications*, vol. 68, no. 1, pp. 630-644, Jan. 2020.

[11] W. Lee, M. Kim, and D. -H. 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.

[12] W. Lee, M. Kim, and D. -H. Cho, "Transmit Power Control Using Deep Neural Network for Underlay Device-to-Device Communication," *IEEE Wireless Communications Letters*, vol. 8, no. 1, pp. 141-144, Feb. 2019.

[13] D. Kim and I. -H. Lee, "Deep Learning-Based Power Control Scheme for Perfect Fairness in Device-to-Device Communication Systems," *Electronics*, vol. 9, no. 10, pp. 1606, Oct. 2020.

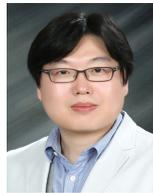
[14] D. Kim, H. Jung, and I.-H. Lee, "Deep Learning-Based Power Control Scheme With Partial Channel Information in Overlay Device-to-Device Communication Systems," *IEEE Access*, vol. 9, pp. 122125-122137, Sep. 2021.

[15] S. Ioffe, and C. Szegedy, "Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift," in *Proceedings of the 32nd International Conference on Machine Learning*, Lille: France, vol. 37, pp. 448-456, 2015.

[16] D. P. Kingma and J. Ba, "Adam: A Method for Stochastic Optimization," Dec. 2014. [Internet] Available: <https://arxiv.org/abs/1412.6980>.



김동현(Donghyeon Kim)
 2020년 2월 : 국립환경대학교 전기전자제어공학과 학사
 2020년 3월 ~ 현재 : 국립환경대학교 전자전기공학부 석사과정
 ※관심분야 : 무선 통신 시스템, 딥러닝, 송신 전력 제어



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 ERIKA 부설 연구소 공학기술연구소 박사후과정
 2011년 3월 ~ 현재 : 국립환경대학교 전자전기공학부 교수
 ※관심분야 : 무선 협력 통신 시스템, MIMO 전송 기술, 무선자원관리 기술, 비직교 다중 접속 기술, 딥러닝 기술