

## 이기종 이동통신 네트워크에서 에너지 효율화를 위한 DNN 기반 동적 셀 선택과 송신 전력 할당 기법

김동현<sup>1</sup> · 이인호<sup>2\*</sup>

### DNN-Based Dynamic Cell Selection and Transmit Power Allocation Scheme for Energy Efficiency Heterogeneous Mobile Communication Networks

Donghyeon Kim<sup>1</sup> · In-Ho Lee<sup>2\*</sup>

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

<sup>2\*</sup>Professor, School of Electronic and Electrical Engineering, and Research Center for Hyper-Connected Convergence Technology, Hankyong National University, Anseong, 17579 Korea

#### 요 약

본 논문에서는 하나의 매크로 기지국과 다수의 소형 기지국들로 구성된 이기종 네트워크를 고려하고, 그 기지국들간 협력적 다중 포인트 전송을 가정한다. 또한, 기지국과 단말간 채널은 경로 손실과 레일레이 페이딩으로 구성된다고 가정한다. 이러한 가정에서 주어진 기지국에 대해 단말이 달성할 수 있는 에너지 효율을 제시하고, 이기종 네트워크의 총 에너지 효율을 최대화하기 위한 동적 셀 선택과 송신 전력 할당의 최적화 문제를 공식화한다. 본 논문에서는 최적화 문제를 해결하기 위하여 비지도 딥러닝 기법을 제안한다. 제안된 딥러닝 기법은 기존의 반복적 수렴 방식의 기법들에 비해서 낮은 복잡도를 갖는 동시에 높은 에너지 효율을 제공하는 것이 가능하다. 시뮬레이션을 통해서 제안된 동적 셀 선택 기법이 최대 신호 대 간섭 및 잡음비 기법과 Lagrangian dual decomposition 기법 보다 높은 에너지 효율 성능을 제공함을 보여주고, 제안된 송신 전력 할당 기법은 최대 에너지 효율을 달성할 수 있는 trust region interior point 기법과 유사한 성능을 제공함을 보여준다.

#### ABSTRACT

In this paper, we consider a heterogeneous network (HetNet) consisting of one macro base station and multiple small base stations, and assume the coordinated multi-point transmission between the base stations. In addition, we assume that the channel between the base station and the user consists of path loss and Rayleigh fading. Under these assumptions, we present the energy efficiency (EE) achievable by the user for a given base station and we formulate an optimization problem of dynamic cell selection and transmit power allocation to maximize the total EE of the HetNet. In this paper, we propose an unsupervised deep learning method to solve the optimization problem. The proposed deep learning-based scheme can provide high EE while having low complexity compared to the conventional iterative convergence methods. Through the simulation, we show that the proposed dynamic cell selection scheme provides higher EE performance than the maximum signal-to-interference-plus-noise ratio scheme and the Lagrangian dual decomposition scheme, and the proposed transmit power allocation scheme provides the similar performance to the trust region interior point method which can achieve the maximum EE.

**키워드** : 동적 셀 선택, 딥러닝, 송신 전력 할당, 이기종 네트워크, 에너지 효율

**Keywords** : Dynamic cell selection, Deep learning, Energy efficiency, Heterogeneous network, Transmit power allocation

Received 25 August 2022, Revised 4 September 2022, Accepted 9 September 2022

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

Professor, School of Electronic and Electrical Engineering, and Research Center for Hyper-Connected Convergence Technology, Hankyong National University, Anseong, 17579 Korea

**Open Access** <http://doi.org/10.6109/jkiice.2022.26.10.1517>

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 기계 학습 기반의 자원 할당 기법의 연구가 다양하게 연구되고 있다[1-6]. 기계 학습 기반의 자원 할당은 기존의 반복적 수렴 최적화 방식에서 발생하는 복잡도를 심층신경망(Deep Neural Network, DNN) 기반의 학습 방식으로 해결한다는 장점을 갖고 있다. 하지만, [1,2]에서 소개된 라벨링 데이터를 통해서 학습하는 지도 학습이나, [3,4]에서 소개된 보상을 통해 학습하는 강화 학습 방식의 자원 할당 기법들은 각각 라벨링 데이터 생성에 대한 복잡성 혹은 많은 시행착오를 통해서 정확한 보상을 찾아내는 학습 복잡성이 존재한다. 이와 같은 이유로 기계 학습 방식 중 하나인 비지도 학습을 통한 자원 할당 기법이 다양하게 연구되고 있다[5,6]. 비지도 학습은 비용함수만을 이용해서 학습하는 방식 때문에 앞 선 기계학습들의 단점을 해결할 수 있어 학습 복잡도를 감소시킬 수 있다.

기존의 비지도 학습 기반의 연구들은 자원 할당 중 송신 전력 할당을 중점적으로 연구해왔다. 특히, [6] 연구에서는 비지도 딥러닝 학습 방식을 통해서 최적에 유사한 송신 전력 기법을 제안했다. 하지만, 기존의 비지도 학습 기반의 연구들은 시스템 모델을 복잡성이 크지 않은 단일셀 시나리오만을 가정하고, 전력 할당의 문제만 해결하는데 집중했다. 송신 전력 제어는 간섭 완화나 주파수 및 에너지 효율 향상에 필수적인 요소지만, 단일셀이 아닌 이기종 네트워크 (Heterogeneous Network, HetNet)에서는 사용자 할당이나 협력적 다중 포인트 (Coordinated Multi-Point, CoMP) 전송 또한 고려되어야 한다[7,8]. 이러한 문제를 해결하기 위해서 [9]에서는 여러 종류의 기지국(Base Station, BS)이 있는 HetNet에서 비지도 학습 기반의 사용자 할당 및 전력 할당 기법을 제안했다. 하지만, 사용자 할당 시 모든 사용자와 BS 사이의 채널 상태 정보(Channel State Information, CSI)가 요구되기 때문에, 다중셀에서 사용자의 수가 늘어나면 늘어날수록 증가되는 트래픽의 부하가 커질 수 있는 단점을 해결하지 못했다.

본 연구에서는 HetNet 시스템에서 트래픽의 부하를 조절할 수 있으면서 에너지 효율(Energy Efficiency, EE)을 최대화할 수 있는 딥러닝 기반의 자원 할당 기법을 연구한다. 제안된 연구에서는 시스템 트래픽의 부하를 감소시키기 위해 CoMP 전송을 하는 BS들의 수와 EE

성능의 trade-off 관계를 고려해 적절한 협력 BS 수를 조절할 수 있는 비지도 학습 기반의 동적 셀 선택 기법을 제안한다. 또한, 동적 셀 선택이 된 사용자에게만 송신 전력이 할당될 수 있도록 하는 비지도 학습 방식의 송신 전력 할당 기법도 제안한다. 제안된 비지도 기반 학습 기법은 한 번의 학습 과정을 통해서 EE와 트래픽의 성능의 trade-off 관계를 쉽게 파악할 수 있고, 제안된 동적 셀 선택 기법은 HetNet 시스템에서 기존의 사용자가 BS에게 접속을 할 때 사용되는 최대 신호 대 간섭 및 잡음 비 (Signal-to-Interference-plus-Noise Ratio, SINR) 기법이나, [10]에서 소개된 반복적 수렴을 통해서 HetNet의 각 BS에게 부하를 적절히 분산시켜 EE의 성능이 향상이 가능한 Lagrangian dual decomposition 기법에 비해서 높은 성능을 제공하는 것이 가능하다. 또한, 제안된 전력 할당 기법은 HetNet의 송신 전력 할당과 같이 non-convex로 알려진 문제에서 최적의 성능을 제공하는 trust region interior point method (IPM) 기법[11]과 유사한 성능을 제공하는 것이 가능하다. 시뮬레이션 결과를 통해서 이를 입증하고, 제안된 DNN 기반 동적 셀 선택 및 송신 전력 할당 기법이 기존의 기법에 비해서 높은 EE 성능을 갖는 동시에 CoMP 전송을 하는 BS들의 수를 적절하게 조절할 수 있는 기법임을 보여준다.

본 연구에서는 HetNet에서 비지도 딥러닝 기반으로 EE를 최대화 할 수 있는 동적 셀 선택과 송신 전력 할당 기법을 제안한다. 제안된 기법은 기존의 사용자 할당과 비교했을 때 높은 성능을 보이는 것이 가능하고, DNN 기반의 학습 방식으로 EE와 CoMP 협력셀 수의 trade-off 관계를 쉽게 분석하는 것이 가능하고, 이는 III장에서 자세하게 설명된다. 그리고, 본 논문의 나머지는 다음과 같이 구성된다. II 장에서는 시스템 모델에 대한 설명 및 기존의 자원 할당 기법에 대해서 설명되고, III 장에서는 제안된 기법에 대한 설명, IV장에서는 시뮬레이션 결과에 대한 분석, 그리고 마지막으로 V장에서 본 논문의 결론을 맺는다.

## II. 시스템 모델 및 기존의 자원 할당 기법

### 2.1. 시스템 모델

본 연구에서는 그림 1과 같이 매크로 셀 내부에 소형 BS와 사용자들이 분포되어 있는 HetNet시스템 모델을




Fig. 1 HetNet system model for dynamic cell selection and power allocation

가정한다. 여기서 BS와 모든 단말기는 단일 송수신 안테나를 이용한다. 매크로 BS와 소형 BS들의 집합이  $\mathbb{B} = \{1, 2, \dots, b, \dots, B\}$  이고, 사용자들의 집합이  $\mathbb{M} = \{1, 2, \dots, m, \dots, M\}$  라고 정의할 때, BS  $b$ 와 사용자  $m$  사이의 채널 이득은 다음과 같다.

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

여기서,  $g_{b,m}$ 는 Rayleigh fading의 복소 채널 계수이고,  $\alpha$ 와  $d_{b,m}$ 는 각각 경로 손실 지수와 BS  $b$ 와 사용자  $m$  사이의 거리이다.

각 사용자들은 경로 손실 기반의 가장 큰 SINR을 갖는 BS를 서빙 BS로 갖고, 사용자  $m$ 의 서빙 BS를  $b^*$ 는 다음과 같이 구해진다.

$$b^* = \max_{b \in \mathbb{B}} \frac{d_{b,m}^{-\alpha} p_{b,m}}{\sum_{i \in \mathbb{B} \setminus \{i\}} d_{i,m}^{-\alpha} p_{i,m}} = \max_{b \in \mathbb{B}} \Gamma_{b,m} \quad (2)$$

여기서,  $p_{b,m}$ 와  $\Gamma_{b,m}$ 은 각각 BS  $b$ 와 사용자  $m$  사이의 송신 전력 및 경로 손실 기반 SINR을 의미한다. 본 연구에서  $\Phi \leq 10 \log_{10}(\Gamma_{b^*,m} / \Gamma_{b,m})$ 를 만족하는 BS들만 CoMP 협력 전송지표 값  $x_{b,m}^C$ 가 1이 되고, 반대일 경우  $x_{b,m}^C = 0$ 이 된다. 또한,  $\Phi$ 는 CoMP 협력셋의 수를 조정할 수 있는 임계값이고,  $\Phi$ 의 값이 작을수록 CoMP 협력 전송을 수행하는 BS의 수가 감소하고,  $\Phi$ 의 값이 클수록 증가한다.

HetNet 시스템 모델에서 BS  $b$ 와 사용자  $m$  사이의 데이터 전송률  $R_{b,m}$ 은 다음과 같이 표현된다.

$$R_{b,m} = x_{b,m} \frac{W}{\sum_{j \in \mathbb{M}} x_{b,j}} \log_2 \left( 1 + \frac{h_{b,m} p_{b,m}}{\sum_{i \in \mathbb{B} \setminus \{b\}} h_{i,m} p_{i,m} + N_0 W / \sum_{j \in \mathbb{M}} x_{b,j}} \right), \quad (3)$$

여기서,  $W$ 는 대역폭,  $N_0$ 는 잡음 전력이고,  $x_{b,m}$ 은 사용자 할당 지표로 사용자  $m$ 이 BS  $b$ 에게 동적 셀 선택을 통해서 접속할 경우  $x_{b,m} = 1$ 이고, 반대일 경우  $x_{b,m} = 0$ 이다. 식 (3)의 데이터 전송률 식을 이용해서 BS  $b$ 와 사용자  $m$  사이의 EE는 다음과 같이 계산된다.

$$EE_{b,m} = \frac{R_{b,m}}{p_{b,m} + p_c}. \quad (4)$$

본 논문에서는 CoMP 전송을 지원하는 BS들이 있는 HetNet 시스템에서 EE를 최대화하는 최적화 문제를 고려한다. 이 때, 각 사용자는 각 CoMP 협력셋 중에서 하나의 BS에 접속한다. 또한, BS들이 사용자들에게 보내는 송신 전력은 최소 송신 전력  $p_{\min}$  값을 보장해야 하고, BS  $b$ 가 사용자들에게 전송할 수 있는 최대 송신 전력은  $P_{\max}^b$ 이다. 마지막으로, 각 사용자의 데이터 전송률은 최소 데이터 전송률  $R_{\min}$ 을 만족해야 하고, 고려된 최적화 문제는 다음과 같이 표현된다.

$$\begin{aligned} & \max \sum_{b \in \mathbb{B}} \sum_{m \in \mathbb{M}} EE_{b,m}, \\ & \text{s.t.} \sum_{b \in \mathbb{B}} x_{b,m} = 1, \forall m \in \mathbb{M}, \\ & p_{b,m} \geq p_{\min}, \forall b \in \mathbb{B}, \forall m \in \mathbb{M}, \\ & \sum_{m \in \mathbb{M}} p_{b,m} \leq P_{\max}^b, \forall b \in \mathbb{B}, \\ & \sum_{b \in \mathbb{B}} R_{b,m} \geq R_{\min}, \forall m \in \mathbb{M}. \end{aligned} \quad (5)$$

## 2.2. 기존의 사용자 할당 기법

이번 장에서는 HetNet에서 EE를 최대화 시킬 수 있는 [8]에서 소개된 Lagrangian dual decomposition 기법에 대해서 설명한다. Lagrangian dual decomposition 기법은 사용자 할당 지수인  $x_{m,n}$ 으로 이뤄진 최적화 문제 (5)의 복잡성과 변수의 이진 특성을 완화 할 수 있다. HetNet의 각 사용자들은 식 (5)의 완화된 함수를 최대화 시킬 수 있는 BS  $b_m^*$ 을 선택할 수 있고, 다음과 같이 표현된다.

$$b_m^* = \arg \max_b \left( \frac{\log(R_{b,m})}{p_{b,m} + p_c} - \mu_b(t) - \lambda_b(t)p_{b,m} - \nu_m(t)R_{b,m} \right), \quad (6)$$

여기서,  $t$  번째 Lagrangian multiplier들은 각각  $\mu_b(t) = \mu_b(t-1) - \delta_1(t-1)(K_b(t-1) - \sum_{m \in \mathbb{M}} x_{b,m}(t-1))$ ,  $\lambda_b(t) = \lambda_b(t-1) - \delta_2(t-1)(p_{\max} - \sum_{m \in \mathbb{M}} x_{b,m}(t-1)p_{b,m}(t-1))$ , 그리고  $\nu_m(t) = \nu_m(t-1) - \delta_3(\sum_{b \in \mathbb{B}} x_{b,m}(t-1)R_{b,m} - R_{\min})$ 을 의미한다. 또한,  $\delta_1(t)$ ,  $\delta_2(t)$ , 그리고  $\delta_3(t)$ 들은 Lagrangian multiplier 들의 step size이고,  $K_b(t) = e^{\lfloor \mu_b(t-1)(p_{b,m} + p_c) - 1 \rfloor}$ 으로 BS  $b$ 가 할당할 수 있는 최대의 사용자 수이다.

식 (6)의 Lagrangian multiplier들을 반복적으로 수렴 시키게 되면 HetNet의 사용자들이 식 (5)의 제약조건을 만족시키면서 EE를 최대화 시킬 수 있는 BS에 접속하는 것이 가능하다. 하지만, 식 (5)를 완화시켜 문제를 해결하기 때문에 최적의 값을 찾기가 어렵고 모든 BS가 CoMP 전송을 한다고 가정하기 때문에 네트워크 복잡도가 커질 수 있는 단점이 있다.

### 2.3. 기존의 송신 전력 할당 기법

이번 장에서는 [12]와 [13]에서 송신 전력 할당 최적화를 하기 위해 사용한 trust region IPM 기법 [11]에 대해서 설명된다. trust region IPM 기법은 기존의 convex 문제만 해결할 수 있는 IPM과 다르게 경사 하강과 trust region 단계를 맞춰 이를 조정하는 부분을 찾아 non-convex 문제의 전역 최적 해를 찾을 수 있는 방법이다. 하지만, trust region IPM 기법의 경우 전역 최적 솔루션을 찾기 위해서 line-search 과정을 반복하면서 수행하기 때문에 사용자가 늘어나면 늘어날수록 이에 대한 복잡도가 증가된다는 단점이 있다.

## III. 딥러닝 기반 동적 셀 선택 기법 및 전력 할당 기법

본 연구는 그림 2와 같은 DNN 구조를 기반으로 동적 셀 선택과 전력 할당 학습을 수행한다. 여기서, 제안된 학습과정의 입력은 각 BS와 사용자들의 CSI와 CoMP

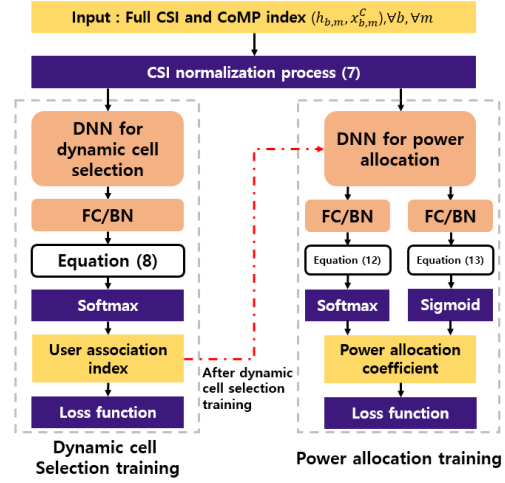


Fig. 2 Proposed DNN-based training process for dynamic cell selection and power allocation processes

전송 지표이고, 학습 과정에서는 모든 BS가 모든 사용자들에게 CoMP 전송을 한다고 가정하고, 모든 CoMP 전송지표를 1로 설정하고 학습을 진행한다. 이 때, CSI의 정규화 과정을 수행하기 위해 dB 단위로 변환한 후 L2 정규화 [14] 방법을 사용하고, 정규화된 CSI  $\hat{h}_{b,m}$ 은 다음과 같이 계산된다.

$$\hat{h}_{b,m} = \frac{10 \log_{10}(h_{b,m} x_{b,m}^C + \epsilon)}{\sqrt{\sum_{b \in \mathbb{B}_m} \sum_{m \in \mathbb{M}} (10 \log_{10}(h_{b,m} x_{b,m}^C + \epsilon))^2}}, \quad (7)$$

여기서,  $\epsilon$ 은 CoMP 전송지표가 0일 때 log함수의 입력이 0이 되는 것을 방지하는 값이다. 식 (7)의 정규화된 CSI는 동적 셀 선택 및 전력 할당에 사용되는 DNN의 입력이 되고, 각 네트워크는 완전 연결 (Fully Connected, FC) 신경망을 기반으로 구성된다. 동적 셀 선택 및 전력 할당의 DNN들은 모두 512의 크기를 갖는 2개의 FC 신경망을 갖고, 배치 정규화(Batch Normalization, BN) 과정 [15]을 통해 신경망 내부를 정규화 시키고, 활성화 함수는  $\max(\cdot, 0)$  연산을 수행하는 rectified linear unit (ReLU) 함수를 사용한다.

본 연구에서 고려되는 학습 과정은 그림 2와 같이 동적 셀 선택 학습 과정이 먼저 수행되고 그 이후에 전력 할당 학습 과정이 수행된다. 그림 2의 동적 셀 선택 과정에서 DNN의 출력은 FC와 BN 과정을 통해서  $BM$  크기를 갖는 출력 벡터가 되고, 이를  $B \times M$  행렬로 변환하고

이를  $\mathbf{Y}^A$ 라고 정의할 때,  $\mathbf{Y}^A$ 는 CoMP 협력지표에 의해서 다음과 같이 변환된다.

$$Z_{b,m}^A = \begin{cases} -\infty & \text{if } x_{b,m}^C = 0, \\ Y_{b,m}^A & \text{if } x_{b,m}^C = 1, \end{cases} \quad (8)$$

여기서,  $Y_{b,m}^A$ 는  $\mathbf{Y}^A$ 의  $(b,m)$ 번째 원소이다. 식 (8)을 통해서 얻어진 행렬은 Softmax 함수의 입력이 되고 Softmax 함수의 과정은 다음과 같이 수행된다.

$$x_{b,m} = \frac{Z_{b,m}^A}{\sum_{i \in \mathbb{B}} Z_{i,m}^A}, \forall m \in \mathbb{M}, \quad (9)$$

식 (9)을 통해서 얻어진 사용자 할당 지표  $x_{b,m}$ 은 Softmax 함수의 특성에 의해서  $\sum_{b \in \mathbb{B}} x_{b,m} = 1$ 을 만족한다.

또한, 식 (8) 과정에 의해서 CoMP 전송을 하지 않는 BS의 사용자 할당 지표값은 항상 0이 된다. DNN의 학습 가능한 weight와 bias들은 사용자 할당 지표  $x_{b,m}$ 을 식 (5)의 최적화 문제를 해결하기 위해 다음과 같은 비용 함수로 학습이 된다.

$$L^D = - \sum_{b \in \mathbb{B}} \sum_{m \in \mathbb{M}} EE_{b,m} + \lambda^D \sum_{m \in \mathbb{M}} \tanh \left( \left[ \frac{R_{\min} - \sum_{i \in \mathbb{B}} R_{i,m}}{R_{\min}} \right]^+ \right), \quad (10)$$

여기서,  $[\cdot]^+$ 는 ReLU 연산을 의미하고,  $\lambda$ 는 EE의 최대화와 outage rate을 최소화의 학습 우선 순위를 결정하는 가중치 값이다. 또한, 식 (9)의 비용 함수에서 모든 송신 전력들은  $p_{b,m} = P_{\max}^b / M$ 값으로 고정시킨다. [5,6]에서 소개된 방식과 같이 outage rate을 최소화 시키면서 EE를 최대화 시킬 수 있는 적절한  $\lambda^D$ 값을 찾고, 식 (10)의 비용 함수를 기반으로 DNN 학습 파라미터 weight와 bias를 Adam 최적화 방식[16]으로 학습해서 수렴하게 되면 다음과 같은 사용자 할당 지표를 얻을 수 있다.

$$x_{b,m} = \begin{cases} 1 & \text{if } b = \arg \max_b (x_{b,m}), \\ 0 & \text{otherwise,} \end{cases} \quad (11)$$

식 (8)부터 식 (11)까지의 동적 셀 선택 학습과정이 종료되고, 식 (7)의 정규화된 CSI와 식 (11)의 사용자 할당 지표를 통해서 전력 할당 학습 과정을 수행한다. 그림 2의 전력 할당을 위한 DNN의 출력 벡터는 두 개의 FC와

BN 과정의 입력이 되고, FC와 BN의  $BM$ 크기를 갖는 출력 벡터들은  $B \times M$  행렬로 변환되고, 이들을 각각  $\mathbf{Y}^B$ 와  $\mathbf{Y}^C$ 라고 정의한다.  $\mathbf{Y}^B$ 와  $\mathbf{Y}^C$ 는 CoMP 협력지표와 식 (11)을 통해서 얻어진 사용자 할당 지표에 의해서 다음과 같이 표현된다.

$$Z_{b,m}^B = \begin{cases} -\infty & \text{if } x_{b,m}^C = 0 \text{ or } x_{b,m} = 0, \\ Y_{b,m}^B & \text{if } x_{b,m}^C = 1 \text{ or } x_{b,m} = 1, \end{cases} \quad (12)$$

$$Z_{b,m}^C = \begin{cases} -\infty & \text{if } x_{b,m}^C = 0 \text{ or } x_{b,m} = 0, \\ Y_{b,m}^C & \text{if } x_{b,m}^C = 1 \text{ or } x_{b,m} = 1, \end{cases} \quad (13)$$

여기서,  $Y_{b,m}^B$ 와  $Y_{b,m}^C$ 는 각각  $\mathbf{Y}^B$ 와  $\mathbf{Y}^C$   $(b,m)$ 번째 원소인 것을 의미한다.  $Z_{b,m}^B$ 와  $Z_{b,m}^C$ 는 각각 Softmax 함수와 Sigmoid 함수의 입력이 되고, 각 함수들은 다음과 같이 표현된다.

$$a_{b,m}^B = \frac{e^{Z_{b,m}^B}}{\sum_{j \in \mathbb{M}} e^{Z_{b,j}^B}}, \forall b \in \mathbb{B}, \quad (14)$$

$$a_{b,m}^C = \frac{1}{1 + e^{-Z_{b,m}^C}}, \forall b \in \mathbb{B}, \forall m \in \mathbb{M}, \quad (15)$$

식 (14)에서 얻어진  $a_{b,m}^B$ 는 Softmax 함수의 특성상  $\sum_{m \in \mathbb{M}} a_{b,m}^B = 1$ 을 만족하고, 식 (15)의  $a_{b,m}^C$ 는 Sigmoid 함수의 특성상  $0 \leq a_{b,m}^C \leq 1$ 을 만족한다. 또한, 식 (12)와 (13)을 통해서 CoMP 전송을 하지 않거나 사용자 할당이 되지 않을 경우에는 출력값들이 모두 0이 된다. 식 (14)과 (15)를 이용해서 식 (5)의 2 번째와 3 번째의 제약조건을 만족하는 DNN 기반의 송신 전력을 유도할 수 있다.

$$p_{b,m} = \max(a_{b,m}^B a_{b,m}^C P_{\max}^b, p_{\min}), \forall b \in \mathbb{B}, \forall m \in \mathbb{M}, \quad (16)$$

여기서, 식 (16)를 통해서 얻어진  $p_{b,m}$ 은 식 (12)과 (13)의 과정을 통해서 CoMP 전송을 하지 않거나 동적 셀 선택이 되지 않은 경우에 송신 전력을 할당하지 않는다. 또한, 전력 할당 학습 과정에서  $p_{b,m}$ 은 동적 셀 선택과 동일하게 학습 가능한 파라미터를 데이터 전송률 최소 조건을 만족하면서 EE를 최대화하기 위해 다음과 같은 비용 함수로 학습을 진행한다.

$$L^P = - \sum_{b \in \mathbb{B}} \sum_{m \in \mathbb{M}} EE_{b,m} + \lambda^P \sum_{m \in \mathbb{M}} \tanh \left( \left[ \frac{R_{\min} - \sum_{i \in \mathbb{B}} R_{i,m}}{R_{\min}} \right]^+ \right), \quad (17)$$

동적 셀 선택 학습과정과 동일하게 적절한  $\lambda^P$ 를 찾고 학습 가능한 파라미터들을 동적 셀 선택 학습 방식과 동일하게 Adam 최적화 방식으로 학습하면 전력 할당 학습 과정도 종료된다.

식 (7)부터 (17)까지의 과정을 통해서 제안된 DNN들은 BS들과 사용자들 사이의 CSI를 기반으로 최소 데이터 전송률을 만족하면서 EE를 최대화 시킬 수 있는  $x_{b,m}$ 과  $p_{b,m}$ 을 도출하는 것이 가능하다. 그림 3에서는 학습이 완료된 이후 학습된 DNN 구조를 통해서 사용자 할당 지표와 송신 전력 계수를 도출하는 과정을 보여준다. 학습된 DNN은 CoMP 전송지표가 모두 1일 때를 기준으로 학습했으나, 실시간으로 사용될 때는 CoMP 전송지표는  $\Phi$ 값을 통해서 정해진다. 제안된 DNN의 학습된 파라미터 weight와 bias들은  $\Phi$ 의 변경에 있어서도 높은 최소 데이터 전송률을 유지하면서 EE를 최대화 시킬 수 있는  $x_{b,m}$ 과  $p_{b,m}$ 을 추가적인 반복 연산 없이 도출하는 것이 가능하다. 즉, 기존의 기법들 같은 경우  $\Phi$ 의 변경에 따른 EE를 반복적으로 계산해서 CoMP 협력셋의 수와 EE 성능의 trade-off 관계를 파악해야 하지만, 제안된 DNN 기법의 경우 한 번의 학습을 통해서 이를 쉽게 파악하는 것이 가능하다.

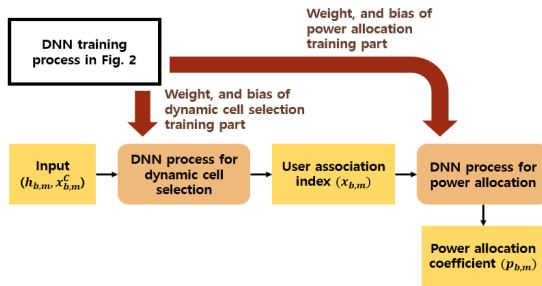


Fig. 3 Proposed DNN-based user association and power allocation process

#### IV. 수치적 결과

본 장에서는 표 1과 같은 시뮬레이션 환경에서 제안

Table. 1 Summarization of simulation parameter

Parameter	Value
The number of BSs ( $B$ )	4
The number of users ( $M$ )	10
Path loss exponent ( $\alpha$ )	3.0
The number of channel samples	10,000
Noise spectral density ( $N_0$ )	-174 [dBm/Hz]
Circuit consumed power ( $p_c$ )	7 [dBm]
Minimum transmit power ( $p_{\min}$ )	0 [dBm]
Bandwidth ( $W$ )	5 [Mhz]
Macro BS total transmit power	30 [dBm]
Small BS total transmit power	27 [dBm]
Radius of macro cell	500 [m]
Data rate threshold ( $R_{\min}$ )	1.0 [Mbps]

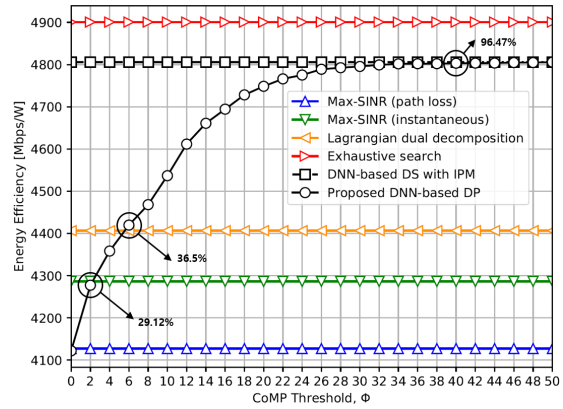


Fig. 4 Energy efficiency performances according to the CoMP threshold,  $\Phi$

한 딥러닝 기반의 동적 셀 선택 및 전력 할당 알고리즘의 성능을 평가한다. 여기서, 매크로 BS의 경우 셀 중심에 있고 3개의 소형 BS들은 셀 중심으로부터 250m 떨어져 위치한다. 또한, 10,000개의 채널 샘플은 식 (1)을 기반으로 생성이 되었다.

그림 4의 범례에서 Max-SINR (path loss) 기법은 모든 사용자가 식 (2)와 같이 경로 손실 기반의 SINR을 통해서 구해진 서빙 BS에만 접속하는 기법이다. 또한, Max-SINR (instantaneous) 기법은 사용자들이 식 (1) 기반의 순시적인 채널들로 SINR을 구했을 때 최대 SINR을 갖는 BS를 선택하는 기법이다. 그리고, Lagrangian dual decomposition 기법은 [10]에서 소개된 사용자 할

당 기법이고, Exhaustive search 기법은 완전 탐색 방식으로 찾은 최적의 동적 셀 선택 기법이다. 여기서, 소개된 Max-SINR 기법들과 Lagrangian dual decomposition 기법 그리고 Exhaustive search 기법에서 전력 할당은 [11]에서 소개된 IPM 기법을 사용했다. 또한, DNN-based dynamic cell selection (DS) with IPM 기법과 Proposed DNN-based dynamic cell selection and power allocation (DP) 기법은 3장에서 소개된 DNN 기반의 동적 셀 선택 기법을 동일하게 사용하고 전력 할당 기법을 각각 IPM 및 제안된 전력할당 알고리즘을 사용한 기법이다. 여기서, Proposed DNN-based DP 기법의  $\phi$  값의 변화에 따른 EE의 성능을 보여주고, 제안된 DNN 기반의 학습 방식에 의해서 추가적 수렴 과정 없이 CoMP 전송 BS 수의 변화에 따른 EE의 성능을 보여주는 것이 가능하다. 또한, 그 이외의 기법들은  $\phi = \infty$  으로 모든 BS가 CoMP 전송을 지원하는 것을 가정한다. 즉, Proposed DNN-based DP 기법만  $\phi$  에 따른 성능의 변화를 보이고 나머지는 모든 BS가 모든 사용자에게 CoMP 전송을 하기 때문에  $\phi$  에 따른 성능의 변화가 없다.

그림 4에서 Proposed DNN-based DP 기법은  $\phi$  값이 증가할수록 EE가 증가하는 것을 확인할 수 있다. 특히,  $\phi$  가 0일 때는 CoMP 전송으로 가용할 수 있는 BS가 서빙 BS만 있기 때문에 Max-SINR (path loss) 기법과 동일한 성능을 갖지만,  $\phi$  값이 2가 되어 전체 BS 중 29.12%만이 CoMP 전송이 가능해도 Max-SINR (instantaneous)와 유사한 성능을 갖는다. 또한, CoMP 협력 전송 BS가 전체 BS의 36.5%인  $\phi = 6$  일 때에는 Lagrangian dual decomposition으로 동적 셀 선택을 한 기법보다 높은 EE를 갖는 것을 알 수 있다. 또한, CoMP BS가 전체 BS의 96.47%인  $\phi = 40$  일 때 부터는 Max-SINR 기법들 및 Lagrangian dual decomposition 기법들보다 크게 높은 EE를 갖고, DNN-based DS with IPM 기법과 유사한 성능을 갖는 것을 알 수 있다. 또한 제안된 동적 셀 선택 기반의 알고리즘들은 높은  $\phi$  에서 최적의 Exhaustive search 기반 동적 셀 선택과 가장 근접한 EE 성능을 보여준다. 즉, 그림 4를 통해서 제안된 동적 셀 선택 및 전력 할당 기법이 기존의 사용자 할당 기법들보다 높은 EE 성능을 가지고, IPM 기반 전력 할당 기법과도 유사한 성능을 제공하는 것을 알 수 있다.

또한, 기존의 Lagrangian dual decomposition과 같이 반복적 수렴을 통해서 사용자 할당지표를 도출하는 방

식은 Max-SINR 기법에 비해서 높은 성능을 도출할 수는 있으나, 성능의 한계와 반복적 수렴 방식 때문에 BS들이 CoMP 전송을 할 때 EE 성능과 트래픽의 trade-off 관계를 찾아내기가 어렵다. 하지만, 제안된 DNN 기법은 학습을 통한 방식으로 쉽게 이를 쉽게 분석할 수 있기 때문에, 실시간 시스템에서 트래픽의 부하와 EE 성능을 쉽게 제어하는 것이 가능한 것을 알 수 있다.

## V. 결론

본 연구에서는 BS들이 CoMP 전송이 가능한 HetNet 시스템에서 딥러닝 기반의 동적 셀 선택 및 전력 할당 기법을 제안했다. 제안된 기법은 EE를 최대화 할 수 있도록 사용자 할당지표와 송신 전력을 도출하는 것이 가능하다. 또한, 기존의 Max-SINR 및 Lagrangian dual decomposition 기법의 사용자 할당 기법에 비해 높은 EE 성능을 보이고, IPM 기반의 전력 할당 기법과도 유사한 성능을 보인다. 그리고, 비지도 기반의 DNN 학습 방식을 통해서 CoMP 전송에 사용되는 BS의 수에 따른 트래픽의 양과 EE 성능과의 비교가 쉽게 가능하다. 시뮬레이션 결과를 통해서, 시스템 트래픽과 EE 성능의 trade-off 관계 분석을 진행하고, 제안된 기법이 비교적 적은 CoMP 협력셋만 사용해도 기존의 반복적 수렴 방식의 기법보다 높은 EE 성능을 제공하는 것을 알 수 있다. 하지만, 제안된 연구는 다수의 부채널을 가정하지 않아 사용자가 급격하게 증가될 경우 EE 성능 및 데이터 전송률에 대한 최소 조건을 만족하지 못할 수 있다. 따라서, 추후 연구에서는 부채널 할당을 통해서 사용자들이 할당되는 채널을 적절히 조절하거나, 비직교 다중 접속과 같이 사용자들이 자원을 공유하는 방식 등이 고려되어야 한다.

## ACKNOWLEDGEMENT

This research was supported by the National Research Foundation of Korea(NRF) grant funded by the Korea government(MSIT) (Grant number: NRF-2022R1A2C1003388).



References

[ 1 ] N. Yang, H. Zhang, K. Long, H. 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.

[ 2 ] 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.

[ 3 ] 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.

[ 4 ] Y. S. Nasir and D. Guo, "Multi-Agent Deep Reinforcement Learning for Dynamic Power Allocation in Wireless Networks," *IEEE Journal on Selected Areas in Communications*, vol. 37, no. 10, pp. 2239-2250, Oct. 2019.

[ 5 ] 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.

[ 6 ] W. Lee and R. Schober, "Deep Learning-Based Resource Allocation for Device-to-Device Communication," *IEEE Transactions on Wireless Communications*, vol. 21, no. 7, pp. 5235-5250, Jul. 2022.

[ 7 ] Q. Ye, B. Rong, Y. Chen, M. Al-Shalash, C. Caramanis, and J. G. Andrews, "User Association for Load Balancing in Heterogeneous Cellular Networks," *IEEE Transactions on Wireless Communications*, vol. 12, no. 6, pp. 2706-2716, Jun. 2013.

[ 8 ] K. M. S. Huq, S. Mumtaz, J. Bachmatiuk, J. Rodriguez, X. Wang, and R. L. Aguiar, "Green HetNet CoMP: Energy Efficiency Analysis and Optimization," *IEEE Transactions on Vehicular Technology*, vol. 64, no. 10, pp. 4670-4683, Oct. 2015.

[ 9 ] D. Kim and I. -H. Lee, "User Association and Power Allocation Scheme Using Deep Learning Algorithm in Non-Orthogonal Multiple Access Based Heterogeneous Networks," *Journal of the Korea Institute of Information and Communication Engineering*, vol. 26, no. 3, pp. 430 - 435, Mar. 2022.

[10] H. Zhang, S. Huang, C. Jiang, K. Long, V. C. M. Leung, and H. V. Poor, "Energy Efficient User Association and Power Allocation in Millimeter-Wave-Based Ultra Dense Networks With Energy Harvesting Base Stations," *IEEE Journal on Selected Areas in Communications*, vol. 35, no. 9, pp. 1936-1947, Sep. 2017.

[11] R. H. Byrd, M. E. Hribar, and J. Nocedal, "An Interior Point Algorithm for Large-Scale Nonlinear Programming," *SIAM Journal on Optimization*, vol. 9, no. 4, pp. 877-900, Sep. 1999.

[12] U. F. Siddiqi, S. M. Sait, and M. Uysal, "Deep Reinforcement Based Power Allocation for the Max-Min Optimization in Non-Orthogonal Multiple Access," *IEEE Access*, vol. 8, pp. 211235 - 211247, Nov. 2020.

[13] X. Huang, S. Liu, Y. Li, F. Zhu, and Q. Chen, "Dynamic cell selection and resource allocation in cognitive small cell networks," in *Proceedings of the 2016 IEEE 27th Annual International Symposium on Personal, Indoor, and Mobile Radio Communications (PIMRC)*, Valencia, Spain, pp. 1 - 6, 2016.

[14] A. Kroah and J. A. Hertz, "A simple weight decay can improve generalization," in *Proceedings of the Advances in Neural Information Processing*, Denver: CO, USA, pp. 951-957, 1991.


[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, pp. 448-456, 2015.

[16] D. P. Kingma and J. Ba. (2014, December). Adam: a method for stochastic optimization [Internet]. Available: <http://arxiv.org/abs/1412.6980>.



김동현(Donghyeon Kim)

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



이인호(In-Ho Lee)

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