

차량 네트워크를 위한 Q-learning 기반의 하향링크 MIMO-NOMA 기법

이 재 희*, 최 기 옥*, 소 재 우^o

Q-learning Based Downlink MIMO-NOMA Scheme for Vehicle Networks

Jaehye Lee*, Giwook Choi*, Jaewoo So^o

요 약

차량 통신에 다양한 서비스가 등장하면서 차량에서 멀티미디어 스트리밍과 같은 높은 전송 용량을 요구하는 서비스가 증가하고 있다. 이를 해결하기 위해 MIMO (Multiple-Input Multiple-Output) - NOMA (Non-Orthogonal Multiple Access) 기법이 필요하다. 차량 통신에서 기지국 역할을 하는 RSU (Road Side Unit)는 접속된 차량의 무선 채널 환경에 따라 송신 전력을 할당한다. 종래 NOMA 기법에서는 전체 시스템의 수율을 최대화하는 것을 목적으로 송신 전력을 할당하였다. 그러나 종래의 송신 전력 할당 기법들은 RSU가 무선 채널 정보를 완벽히 알고 있다고 가정하여, 실제 환경의 불완전한 채널에 적용하기 어렵다는 문제점이 있다. 본 논문은 MIMO-NOMA 기반의 V2I (Vehicle to Infrastructure) 통신과 OMA (Orthogonal Multiple Access) 기반의 V2V (Vehicle to Vehicle) 통신이 혼재되어 있는 환경에서 RSU가 채널 정보를 완벽히 알 수 없을 때의 전력 할당을 모델링하였다. 그리고 기계 학습 방식의 Q-learning 알고리즘을 MIMO-NOMA에 적용하여 송신 전력 할당을 수행하였으며, 그 결과 빠른 시간 내에 전체 시스템 수율이 수렴할 수 있음을 확인하였다.

Key Words : NOMA, Q-learning, Power allocation, Vehicle communication, Reinforcement learning

ABSTRACT

As various services such as multimedia streaming are increasing in the vehicle networks, the demand for high-capacity of wireless communications is increasing. The multiple-input and multiple-output (MIMO) - non-orthogonal multiple access (NOMA) scheme is one of candidates that solve the problem. The road side unit (RSU), which operates as a base station in the vehicle network, allocates the transmission power to the vehicles according to the channel state of the vehicles. The conventional NOMA schemes have allocated the transmission power to the vehicles under the assumption that the RSU perfectly knows all the channel state of the vehicles. However, in the practical environments, it is impossible for the RSU to know all the channel state without error. In this paper, we develop a power allocation scheme under the assumption that a RSU imperfectly knows the channel state of the vehicles in the heterogeneous vehicle networks with the MIMO-NOMA based V2I

* 이 논문은 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (No. 2019R1F1A1058716) 그리고 2016년도 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (No. 2016R1D1A1B03934150).

♦ First Author : Department of Electronic Engineering, Sogang University, jaeheele@sogang.ac.kr, 웹회원

° Corresponding Author : Department of Electronic Engineering, Sogang University, jwso@sogang.ac.kr, 종신회원

* Ericsson-LG, giwook.choi@ericsson.com

논문번호 : 201902-461-B-RN, Received February 14, 2019; Revised May 24, 2019; Accepted June 11, 2019

communications and the orthogonal multiple access (OMA) based V2V communications. Moreover, we apply the Q-learning algorithm of the machine learning to the MIMO-NOMA scheme in order to allocate the transmit power. The proposed Q-learning based power allocation shows that the overall system throughput can converge within a short time.

I. 서 론

최근 ICT 기술의 발전에 따라 차량과 외부 네트워크를 연결하여 양방향 통신이 가능하도록 하는 커넥티드 카와 자율주행 차량에 대한 관심이 상용 자동차 업체를 중심으로 크게 증가하고 있다. 미국, 유럽, 일본 등 여러 국가에서 협력 지능형 교통 시스템 (Cooperative Intelligent Transportation system; C-ITS)에 대한 프로젝트가 활발히 진행되고 있다^[1]. 그리고 차량의 충돌 방지, 커브길 안전 서비스 등 차량의 안전성 향상을 위한 교통 정보 전달 서비스와 인터넷 접속, 인포테인먼트 서비스, 멀티미디어 스트리밍과 같은 사용자 편의 서비스 등 5G를 이용한 다양한 서비스가 등장하고 있다. 교통 정보 전달 서비스는 네트워크 안정성 확보가 중요하고, 사용자 편의를 위한 서비스는 다양한 정보를 제공하게 되면서 높은 전송량과 서비스 시간을 필요로 한다^[2].

차량 통신은 크게 두 가지 방식으로 나뉠 수 있다. 하나는 도로 혹은 도로 옆에 설치된 기지국을 통하여 다른 차량의 정보 혹은 백홀 망의 연결을 구축하는 V2I (Vehicle to Infrastructure) 통신이며, 다른 방식은 차량 간의 통신을 이용하여 차량 간 충돌방지 및 위급상황 알람 등의 차량 안전 서비스를 받을 수 있는 V2V (Vehicle to Vehicle) 통신이다. V2I 통신에서는 시스템 전체 수율 증가를 위해 MIMO (Multiple-Input Multiple-Output)를 도입한 연구가 많이 진행되었다^[3]. MIMO는 여러 개의 안테나를 이용하여 주파수 효율을 향상시킬 수 있는 기술이다. 그러나 MIMO 기술만으로는 차량 통신의 QoS를 만족시키기에는 부족하다^[4]. 따라서 5G 통신 시스템에서 높은 전송 용량 증대를 위한 다중 접속 기술로 NOMA (Non-Orthogonal Multiple Access)에 대한 연구가 함께 주목을 받고 있다. NOMA는 기지국에서는 중첩 코딩으로 신호를 전송하고, 수신자는 SIC (Successive Interference Cancellation) 기반으로 자신의 신호만을 추출한다. NOMA는 동일한 주파수 대역을 여러 사용자가 동시 접속을 가능하게 하는 기술로 기존 OMA (Orthogonal Multiple Access) 보다 높은 주파수 효율을 가진다. OMA는 시간이나 주파수 영역에서 다중화

되지만, NOMA는 시간, 주파수, 전력 영역에서 다중화 된다. 그렇기 때문에 여러 사용자가 동일한 시간과 주파수 영역을 동시에 사용 가능하다^[5].

차량 통신의 수율 증가를 위해 MIMO-NOMA 기반의 V2I 통신에 대한 연구가 다양하게 이루어지고 있다. 그러나 기존의 연구들은 대부분 기지국이 채널 정보를 완벽히 알고 있다고 가정하고 시스템 모델을 수립하였다. NOMA 기반의 V2I 통신과 OMA 기반의 V2V 통신이 혼재된 환경의 경우 기지국은 채널 정보를 완벽히 알기 어렵기 때문에, 기존의 연구들은 실제 환경에서 적용하기 어려운 문제점이 있다.

본 논문에서는 NOMA 기반의 V2I 통신과 OMA 기반의 V2V 통신이 혼재된 차량 통신 환경을 고려하여, 불완전한 채널 정보로 발생하는 프리코딩 행렬의 오류를 수학적으로 모델링하고, 시스템 수율을 최적화하는 전력 할당 방식을 제안하였다. 그러나 NOMA 기반의 V2I와 OMA 기반의 V2V가 혼재되어 있는 네트워크 환경에서 불완전한 채널 정보를 고려한 전력 할당 방식은 NP hard 문제이다. 본 논문은 NP hard 문제를 풀기 위해 기계 학습 중 강화 학습 (Reinforcement learning) 방식의 Q-learning 알고리즘을 적용하였다. Q-learning은 주어진 환경과 상태에서부터 비지도 학습을 통해 최적값을 찾아가는 알고리즘으로 본 논문에서는 Q-learning 기반 전력 할당 기법을 제안한다.

본 논문의 구성은 다음과 같다. II장에서 관련 연구와 기존 연구들의 한계를 분석하고, III장에서는 차량 통신의 일반적인 모델과 불완전한 채널 추정 방식의 시스템 모델을 제시한다. IV장에서는 Q-learning 기반의 전력 할당 기법을 제시하며, V장에서는 모의실험 환경과 결과를 제시한다. 마지막으로 VI장에서 결론을 맺고 논문을 마친다.

II. 관련 연구

본 장에서는 기존에 연구된 다중 사용자 MIMO, NOMA 전력 할당 기법, Q-learning 기반 무선 통신 기법에 대해 소개한다.

2.1 다중 사용자 (Multi-user) MIMO

다중 사용자 MIMO 시스템에서 수신 SINR (Signal to Interference Noise Ratio)을 증가시키거나 오류 확률을 줄이는 방법에 관한 연구가 진행되었다^[3]. 간단한 선형 수신기의 위상 정보를 사용하여 오류 확률을 부분적으로 개선하거나, 오류 확률을 최소화하기 위한 기법에 대한 연구들이 진행되었다. 그리고 다수의 사용자가 존재할 때 사용자간 간섭을 제거하기 위한 ZF (Zero Forcing) 방식의 프리코딩 기법이나 MMSE (Minimum Mean Square Error) 기반 프리코딩 기법들도 연구되었다^[6]. 차량통신과 관련된 MIMO 기반 기법으로는 방향성을 가지는 안테나를 사용하여 V2I 통신의 SINR을 최대화 하는 연구가 진행되었다^[7]. 그러나 MIMO 기반의 시스템만으로는 차량 통신에서 요구하는 높은 QoS를 만족하기 어렵다는 한계가 있다^[4].

2.2 NOMA 기반 전력 할당 기법

NOMA는 동일 무선 자원으로 동시에 여러 명의 사용자를 서비스하여 기존의 OMA 기법 대비 높은 성능을 낼 수 있는 기술이다. NOMA의 핵심은 사용자가 성공적으로 SIC를 수행할 수 있도록, 전력 할당 다중화를 수행하여야 한다^[5]. 그림 1은 두 명의 사용자에게 NOMA를 적용하는 과정을 도식화 하였다. NOMA의 전력 할당 기법에 대한 연구도 활발히 진행되었다. 그러나 NOMA의 전력 할당은 사용자 쌍 구성, 프리코더 구성 등과 관련한 고려사항이 많고, non-convex이기 때문에 최적의 전력 할당 값이 closed form으로 나타나지 않는 문제점이 있다^[8]. 따라서 위와 같은 사항들을 해결하기 위해, MIMO-NOMA 시스템에서 ZF 빔포밍 및 사용자 페어링을 적용하여 간섭을 감소시키고 수율을 현저히

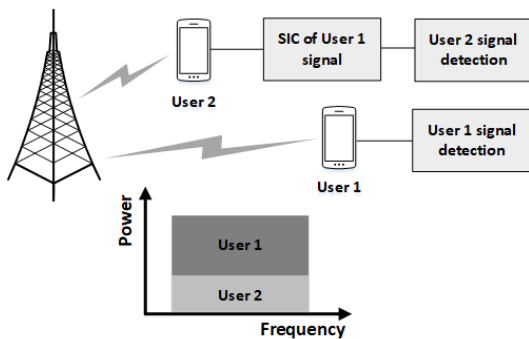


그림 1. 일반적인 NOMA 기법
Fig. 1. Conventional NOMA scheme

증가시키거나^[9], 상향링크의 NOMA 시스템에서 공정성 (fairness)을 고려하여 사용자를 선택하는 기법이 연구되었다^[10]. 또한 사전에 정의된 사용자의 QoS를 만족시키면서 협력적 전송 방식을 사용한 전력 할당 기법이 제안되기도 했다^[11].

2.3 Q-learning 기반 무선 통신 기법

강화 학습은 동적인 환경에서 시행착오를 거쳐 환경으로부터 주어지는 보상 (reward)을 최대화하기 위한 학습 방법이다. Q-learning은 강화 학습 방법들 중 대표적으로 쓰이는 알고리즘으로서 에이전트 (agent)가 환경 (environment)에 대한 사전 정보를 알지 못해도 적용할 수 있는 학습 방식이다. 주어진 유한 Markov Decision Process (MDP)의 최적의 정책 (policy)을 찾기 위해 사용할 수 있다. Q-learning은 학습 환경 내에서 행동의 주체인 에이전트가 특정 상태 (state)에서 가능한 행동 (action)들 중 하나를 취하고, 다음 상태로 이동한다. 이때 에이전트는 행동에 대한 보상을 받게 되며, 보상의 총합을 최대화 하는 것이 Q-learning의 목표이다^[12]. 에이전트는 각 상태에서 어떤 행동을 취하는 것이 최적인지 학습해야 한다. 알고리즘이 시작되기 전에 Q-function은 고정된 임의의 값을 가진다. 각 시간 t 에서 에이전트는 어떠한 상태 s^t 에서 행동 a^t 를 취하고 새로운 상태 s^{t+1} 로 전이된다. 이때 보상 r^t 가 얻어지며 Q-function이 업데이트 된다. Q-function을 학습하게 되면 각 상태에서 최고의 Q-value를 주는 행동을 수행함으로써 최적의 정책을 유도 할 수 있다. 이를 식 (1)에 나타내었다.

$$Q(s^t, a^t) \leftarrow (1 - \alpha) Q(s^t, a^t) + \alpha [r^t + \gamma \max_{a'} Q(s^{t+1}, a')] \quad (1)$$

여기서 α 는 learning rate로 Q-value에 대한 새로운 정보가 이전 정보 보다 어느 정도 비중이 있는지 나타내며, γ 는 discount factor로서 보상에 대한 중요성을 나타낸다. α 와 γ 는 각각 0보다 크고 1보다 작거나 같은 값을 가진다^[13].

최근 무선 통신 분야에 기계 학습을 활용한 연구도 진행 되고 있다. 인지 네트워크 (cognitive network)에서 일차 사용자의 에너지 효율과 주파수 효율을 고려한 전력 할당을 하는 연구가 기계 학습을 적용하여 진행되었다^[14]. 또한 서포트 벡터 머신 (Support Vector Machine, SVM)을 이용한 안테나 선택 기법에 대한 연구, HetNet (Heterogeneous Network) 환경에서 셀 간 간섭 (Inter-cell interference)을 제어하기 위한 기

법, CSI (Channel State Information) 피드백 수립을 위한 기법 등도 기계 학습을 활용하여 연구되었다^[15-17]. 그러나 차량 통신에서 NOMA 기반 V2I 통신과 OMA 기반 V2V 통신을 모두 고려한 기계 학습 기반의 기법은 아직 연구된 바가 없다.

III. 시스템 모델

본 장에서는 일반적인 차량 통신 네트워크 모델과 불완전한 채널 정보 기반의 시스템 모델을 설명한다.

3.1 차량 통신 네트워크 모델

본 논문에서는 MIMO-NOMA 기반의 하향링크 V2I 통신 네트워크와 SISO (Single-Input Single-Output) OMA 기반의 V2V 통신 네트워크가 혼재된 그림 2와 같은 차량 통신 네트워크를 고려한다. N 개의 송신 안테나를 가진 1개의 RSU는 최대 N 개의 빔포밍 벡터를 형성할 수 있다. 각각의 빔은 동시에 1개의 NOMA 쌍을 서비스 할 수 있다. 각각의 NOMA 쌍은 K 대의 차량을 서비스 할 수 있다. 따라서 N 개의 송신 안테나를 가진 RSU는 최대 NK 대의 NOMA 차량을 동시에 서비스 할 수 있다. 또한 1개의 안테나를 가진 OMA 기반의 V2V 차량은 ROI (Region of Interesting) 내에 최대 V 대가 존재할 수 있다. V2V 차량들은 2대씩 임의의 그룹을 형성하여 통신이 이루어진다. 따라서 ROI 내의 V2V 차량이 v 대 존재한다면 V2V를 서비스하는 그룹은 $v/2$ 개 존재하게 된다.

RSU의 n 번째 빔은 $\{N_{n,1}, N_{n,2}, \dots, N_{n,K}\}$ 으로 구성된 NOMA 차량들을 동일한 무선 자원으로 동시에 서비스한다. 여기서 $N_{n,k}$ 는 n 번째 NOMA 쌍에서 k 번째

차량을 의미한다. x_n 을 n 번째 빔의 전송 신호이라고 가정하면 K 대 NOMA 차량의 중첩 신호는 식 (2)와 같다.

$$x_n = \sum_{k=1}^K \sqrt{P_n \alpha_{N_{n,k}}} s_{N_{n,k}} \quad (2)$$

여기서 $s_{N_{n,k}}$ 는 NOMA 차량 $N_{n,k}$ 의 전송 신호이고 $E(|s_{N_{n,k}}|^2) = 1$ 을 만족한다. $E(\cdot)$ 는 기대 함수(expectation function)이다. $\alpha_{N_{n,k}}$ 는 $N_{n,k}$ 차량의 전력 할당 계수이고 $\sum_{k=1}^K \alpha_{N_{n,k}} = 1$ 을 만족한다. P_n 은 n 번째 빔의 총 전송 전력이고 $P_n = P_{RSU}/N$ 을 만족한다. 여기서 P_{RSU} 는 RSU의 총 전송 전력을 의미한다.

MU-MIMO에서 다수의 사용자로 인한 간섭을 최소화하기 위하여 프리코딩 기법이 적용되는데 N 개의 벡터로 구성되는 프리코딩 행렬 \mathbf{W} 는 식 (3)과 같다^[9].

$$\mathbf{W} = [\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_N] \quad (3)$$

여기서 $\mathbf{w}_n \in \mathbb{C}^{N_t \times 1}$ 은 n 번째 빔을 위한 빔포밍 벡터이다. NOMA 차량 $N_{n,k}$ 의 수신 신호 $y_{N_{n,k}}$ 와 V2V 차량 $V_{v,RX}$ 의 수신 신호 $y_{V_{v,RX}}$ 는 각각 식 (4), (5)와 같다.

$$y_{N_{n,k}} = \mathbf{h}_{RSU, N_{n,k}} \sum_{n'=1}^N \mathbf{w}_{n'} x_{n'} + \sum_{v'=1}^V \sqrt{P_{v'}} g_{V_{v',TX}, N_{n,k}} s_{v'} + n_{N_{n,k}} \quad (4)$$

$$y_{V_{v,RX}} = \sum_{v'=1}^V \sqrt{P_{v'}} g_{V_{v',TX}, V_{v,RX}} s_{v'} + \mathbf{h}_{RSU, N_{n,k}} \sum_{n'=1}^N \mathbf{w}_{n'} x_{n'} + n_{V_{v,RX}} \quad (5)$$

여기서 s_v 는 V2V 차량 $V_{v,RX}$ 의 전송 신호이고 $E(|s_{N_{n,k}}|^2) = 1$ 을 만족한다. $P_{v'}$ 는 $V_{v',TX}$ 의 전송 전력이다. $\mathbf{h}_{RSU,a}$ 와 $g_{V_{v',TX},b}$ 는 각각 RSU와 어떠한 차량 a 와의 채널 이득(channel gain), v 번째 V2V 그룹의 TX 차량과 어떠한 차량 b 와의 채널 이득을 의미한다. 각각의 채널은 independent identically distributed




그림 2. 차량 통신 네트워크 모델
Fig. 2. Vehicle communication network model

(i.i.d.) complex Gaussian 분포를 따르며, $\mathbf{h}_{RSU, N_{n,k}} \sim \mathcal{CN}(0, \sigma_{RSU, N_{n,k}} \mathbf{I})$, $g_{V_v, TX, V_v, RX} \sim \mathcal{CN}(0, \sigma_{V_v, RX, V_v, RX} \mathbf{I})$ 와 같다^[18]. $n_{N_{n,k}}$ 와 $n_{V_v, RX}$ 는 각각 $N_{n,k}$ 과 V_v, RX 의 AWGN (Additive White Gaussian Noise)을 의미한다. 수신 신호 및 간섭에 대한 채널 모델을 그림 3에 나타내었다.

n 번째 NOMA 빔의 채널 이득은 $|h_{N_{n,1}}|^2 < |h_{N_{n,2}}|^2 < \dots < |h_{N_{n,K}}|^2$ 를 따른다. SIC가 성공적으로 이루어진다고 가정하면, 식 (4)는 식 (6)으로 나타낼 수 있다^[9].

$$y'_{N_{n,k}} = \mathbf{h}_{RSU, N_{n,k}} \mathbf{w}_n \sqrt{P_n \alpha_{N_{n,k}}} s_{N_{n,k}} + \mathbf{h}_{RSU, N_{n,k}} \mathbf{w}_n \sum_{k'=k+1}^K \sqrt{P_n \alpha_{n,k'}} s_{N_{n,k'}} + \mathbf{h}_{RSU, N_{n,k}} \sum_{n'=1, n' \neq n}^N \mathbf{w}_{n'} x_{n'} + \sum_{v'=1}^V \sqrt{P_{v'}} g_{V_{v'}, TX, N_{n,k}} s_{v'} + n_{N_{n,k}} \quad (6)$$

여기서 우측의 첫 번째 항은 $N_{n,k}$ 의 신호 (desired signal), 두 번째 항은 같은 빔 내의 간섭 (intra-beam interference), 세 번째 항은 다른 빔 간의 간섭 (inter-beam interference), 네 번째 항은 V2V 차량으로 부터의 간섭과 AWGN을 의미한다.

본 논문에서는 빔 간 간섭을 줄이기 위하여 ZF 빔포밍을 적용한다. 한 개의 NOMA 빔 내에 2대의 차량이 있다고 가정하면 식 (7)을 만족하는 빔포밍 벡터를 형성할 수 있다^[9].

$$|\hat{\mathbf{h}}_{N_{n,2}} \mathbf{w}_n| = 0, \text{ for } \forall n' \neq n \quad (7)$$

식 (7)을 식 (6)에 적용하면 NOMA 빔 내의 차량 2대

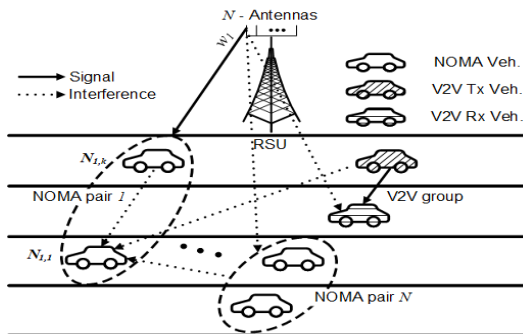


그림 3. 신호 및 간섭 채널 모델
Fig. 3. Desired signal and interference channel model

의 수신 신호를 식 (8), (9)로 나타낼 수 있다.

$$y'_{N_{n,1}} = \mathbf{h}_{RSU, N_{n,1}} \mathbf{w}_n \sqrt{P_n \alpha_{N_{n,1}}} s_{N_{n,1}} + \mathbf{h}_{RSU, N_{n,1}} \mathbf{w}_n \sqrt{P_n \alpha_{N_{n,2}}} s_{N_{n,2}} + \mathbf{h}_{RSU, N_{n,1}} \sum_{n'=1, n' \neq n}^N \mathbf{w}_{n'} x_{n'} + \sum_{v'=1}^V \sqrt{P_{v'}} g_{V_{v'}, TX, N_{n,1}} s_{v'} + n_{N_{n,1}} \quad (8)$$

$$y'_{N_{n,2}} = \mathbf{h}_{RSU, N_{n,2}} \mathbf{w}_n \sqrt{P_n \alpha_{N_{n,2}}} s_{N_{n,2}} + \mathbf{h}_{RSU, N_{n,2}} \sum_{n'=1, n' \neq n}^N \mathbf{w}_{n'} x_{n'} + \sum_{v'=1}^V \sqrt{P_{v'}} g_{V_{v'}, TX, N_{n,2}} s_{v'} + n_{N_{n,2}} \quad (9)$$

여기서 ZF 빔포밍으로 식 (9)는 식 (8)에 비하여 빔 간 간섭이 존재하지 않는 것을 확인할 수 있다.

3.2 불완전한 채널 정보 기반 모델

차량 통신에서는 차량 이동에 따라 무선 채널 환경이 급격하게 변하므로 RSU는 채널 정보를 완벽하게 알 수 없다. 따라서 RSU와 NOMA 차량 $N_{n,k}$ 사이에 채널 오류가 생긴다. 추정된 채널과 실제 채널과의 차이를 식 (10)과 같이 나타낼 수 있다^[19].

$$\hat{\mathbf{h}}_{RSU, N_{n,k}} = \mathbf{h}_{RSU, N_{n,k}} + \epsilon_{RSU, N_{n,k}}, \forall n, k \quad (10)$$

여기서 $\epsilon_{RSU, N_{n,k}} \in \mathbb{C}^{1 \times N}$ 는 채널 오류를 의미한다. 식 (10)과 같은 채널 정보 오류에 따라 식 (7)의 ZF 빔포밍은 빔 간 간섭 제거를 성공적으로 수행하지 못하고 식 (11)과 같이 잔여 항 (residual term)이 남게 된다.

$$|\mathbf{h}_{RSU, N_{n,2}} \mathbf{w}_n| = |\epsilon_{n,2} \mathbf{w}_n| \neq 0, \forall n' \neq n \quad (11)$$

따라서 식 (8), (9)의 n 번째 빔의 NOMA 차량 $N_{n,k}$ 의 수신 신호에 식 (11)을 적용하여 다시 쓰면 식 (12), (13)과 같다.

$$y'_{N_{n,1}} = \mathbf{h}_{RSU, N_{n,1}} \mathbf{w}_n \sqrt{P_n \alpha_{N_{n,1}}} s_{N_{n,1}} + \mathbf{h}_{RSU, N_{n,1}} \mathbf{w}_n \sqrt{P_n \alpha_{N_{n,2}}} s_{N_{n,2}} + \mathbf{h}_{RSU, N_{n,1}} \sum_{n'=1, n' \neq n}^N \mathbf{w}_{n'} x_{n'} + \sum_{v'=1}^V \sqrt{P_{v'}} g_{V_{v'}, TX, N_{n,1}} s_{v'} + n_{N_{n,1}} + r_{N_{n,1}} \quad (12)$$

$$y'_{N_{n,2}} = \mathbf{h}_{RSU, N_{n,2}} \mathbf{w}_n \sqrt{P_n \alpha_{N_{n,2}}} s_{N_{n,2}} + \sum_{v'=1}^V \sqrt{P_{v'}} g_{V_{v', TX}, N_{n,2}} s_{v'} + n_{N_{n,2}} + r_{N_{n,2}} \quad (13)$$

여기서 $r_{N_{n1}} = \epsilon_{RSU, N_{n1}} \sum_{n'=1}^N \mathbf{w}_{n'} x_{n'}$, $r_{N_{n2}} = \epsilon_{RSU, N_{n2}} \mathbf{w}_n$

for $\forall n$ 을 만족한다. 식 (12)를 이용하여 NOMA 빔의 첫 번째 차량의 SINR을 나타내면 식 (14) 와 같다.

$$\gamma_{N_{n,1}} = \frac{P_n \alpha_{N_{n,1}} |\mathbf{h}_{RSU, N_{n,1}} \mathbf{w}_n|^2}{I_{N_{n,1}}^{Intra} + I_{N_{n,1}}^{Inter} + I_{N_{n,1}}^{V2V} + E_{N_{n,1}}^{Inter} + \sigma_{N_{n,1}}^2} \quad (14)$$

여기서

$$I_{N_{n,1}}^{Intra} = |\mathbf{h}_{RSU, N_{n,1}} \mathbf{w}_n|^2 P_n \alpha_{N_{n,2}} \quad (15)$$

$$I_{N_{n,1}}^{Inter} = \sum_{n'=1, n' \neq n}^N P_{n'} |\mathbf{h}_{RSU, N_{n,1}} \mathbf{w}_{n'}|^2 \quad (16)$$

$$I_{N_{n,1}}^{V2V} = \sum_{v'=1}^V P_{v'} |g_{V_{v', TX}, N_{n,1}}|^2 \quad (17)$$

$$E_{N_{n,1}}^{Inter} = \sum_{n'=1}^N P_{n'} |\epsilon_{RSU, N_{n,1}} \mathbf{w}_{n'}|^2 \quad (18)$$

을 의미한다. 식 (15)는 n 번째 빔 내의 차량 간 간섭 이고, 식 (16)은 n 번째 빔을 제외한 다른 빔들의 간섭 을 의미한다. 식 (17)은 모든 V2V 링크에서 오는 간 섭을 의미하고, 식 (18)은 RSU의 불완전한 채널 정보 에 의한 ZF 빔포밍의 오류를 의미한다. 식 (13)을 이 용하여 두 번째 차량의 SINR을 나타내면 식 (19) 와 같다.

$$\gamma_{N_{n,2}} = \frac{P_n \alpha_{N_{n,2}} |\mathbf{h}_{RSU, N_{n,2}} \mathbf{w}_n|^2}{E_{N_{n,2}}^{Inter} + I_{N_{n,2}}^{V2V} + \sigma_{N_{n,2}}^2} \quad (19)$$

여기서

$$E_{N_{n,2}}^{Inter} = \sum_{n'=1, n' \neq n}^N P_{n'} |\epsilon_{RSU, N_{n,2}} \mathbf{w}_{n'}|^2 \quad (20)$$

$$I_{N_{n,2}}^{V2V} = \sum_{v'=1}^V P_{v'} |g_{V_{v', TX}, N_{n,2}}|^2 \quad (21)$$

을 의미한다. 식 (20)은 빔 간 간섭에서 RSU의 불완 전한 채널에 의한 ZF 빔포밍의 오류를 의미하고 식 (21)은 모든 V2V 링크에서 오는 간섭을 의미한다. 다 음으로 식 (5)을 이용하여 v 번째 V2V 그룹의 SINR 을 구하면 식 (22)와 같다.

$$\gamma_{V_{v, RX}} = \frac{P_v |g_{V_{v, TX}, V_{v, RX}}|^2}{I_{V_{v, RX}}^{V2V} + I_{V_{v, RX}}^{NOMA} + \sigma_{V_{v, RX}}^2} \quad (22)$$

여기서

$$I_{V_{v, RX}}^{V2V} = \sum_{v'=1, v' \neq v}^V P_{v'} |g_{V_{v', TX}, V_{v, RX}}|^2 \quad (23)$$

$$I_{V_{v, RX}}^{NOMA} = \sum_{n=1}^N P_n |\mathbf{h}_{RSU, V_{v, RX}} \mathbf{w}_n|^2 \quad (24)$$

을 의미한다. 식 (23)은 v 번째 V2V 링크를 제외한 모 든 V2V 링크 링크에서 오는 간섭을 의미하고 식 (24) 는 모든 NOMA 빔의 신호 간섭을 의미한다. 식 (14), (19), (22)를 이용하여 시스템 전체의 Shannon capacity R^{all} 을 나타내면 식 (25)와 같다.

$$R^{all} = \sum_{n=1}^N \sum_{k=1}^2 \log_2(1 + \gamma_{N_{n,k}}) + \sum_{v=1}^V \log_2(1 + \gamma_{V_{v, RX}}) \quad (25)$$

전체 시스템 수율의 총합에 대한 최적화 문제를 나타 내면 다음과 같다.

$$\text{Maximize } R^{all} \quad (26a)$$

$$\text{s.t. } \sum_{k=1}^2 \alpha_{N_{n,k}} = 1, \alpha_{N_{n,k}} \in \mathbb{R}, n = 1, 2, \dots, N \quad (26b)$$

$$\log_2(1 + \gamma_{N_{n,k}}) \geq R_{0, NV} \quad (26c)$$

$$\log_2(1 + \gamma_{V_{v, RX}}) \geq R_{0, VV} \quad (26d)$$

$$|\hat{\mathbf{h}}_{N_{n'}, 2} \mathbf{w}_n| = 0, \text{ for } \forall n' \neq n \quad (26e)$$

여기서 식 (26b)는 각 빔 내 전력 할당 계수의 합이 1이 됨을 의미한다. 식 (26c), (26d)는 각각 NOMA 차량과 V2V 차량의 최소 QoS를 의미한다. 식 (26e)

는 ZF 빔포밍 벡터의 형성 조건을 의미한다.

IV. 제안하는 MIMO-NOMA 기법

본 논문은 차량 통신의 실제 무선 채널 환경에서 Q-learning 기반 전력 할당을 수행하는 MIMO-NOMA 기법을 제안한다.

무선 채널 환경에서 기지국 전력 할당은 RSU와 이동하는 차량 사이의 반복되는 상호작용으로 모델링할 수 있다. 최적의 전력 할당 기법은 RSU의 매 타임 슬롯에서 정확한 무선 채널 상태 정보로 결정된다. 하지만 실제 무선 채널 환경에서는 채널 오류로 인하여 완벽한 추정이 어렵다. 본 논문은 식 (26)의 NP hard 문제를 해결하기 위해 기계 학습을 이용한다.

기계 학습은 지도 학습, 비지도 학습, 강화 학습이 있다. 지도 학습을 수행하기 위해서는 사전에 많은 학습 데이터가 있어야 하는데, 본 시스템 모델에서는 사전에 학습 데이터를 구축하기 어려울 뿐만 아니라, 채널 오류가 있는 무선 채널 환경에서는 최적의 전력 할당 값을 알기 어려우므로 정확한 학습 데이터를 구축하기 어려워 지도 학습을 수행하기 어렵다. 또한 종래의 비지도 학습은 데이터들을 구분 짓거나 통계 분포를 추정하는 학습으로 전력 할당을 수행하기 어렵다. 본 논문에서 고려하는 MIMO-NOMA 시스템 모델에서 RSU의 전력 할당은 MDP로 모델링할 수 있다. 따라서 그림 2의 MIMO-NOMA 시스템에서 전력 할당은 Q-learning 기반의 강화 학습을 이용할 수 있다^[18].

제안하는 기법에서 RSU는 강화 학습 기반 전력 할당을 수행하고, 이때 전력 할당 값은 Q-function에 의해 결정된다. 에이전트는 RSU, 상태 s^t 는 차량의 수신 SINR인 $\gamma_{N_{n,k}}$, 행동 θ^t 는 각 차량의 전력 할당 계수인 α , 보상은 시스템 전체의 수율인 R^{all} 로 정의할 수 있다. 매시간 t 마다 직전 타임 슬롯인 $t-1$ 때의 차량의 수신 SINR인 $\gamma_{N_{n,k}}$ 을 $s^t = [\gamma_{N_{n,k}^{t-1}}]_{n,k} \in \xi$ 으로 설정한다. ξ 는 SINR의 모든 가능한 집합이다. 각 유저의 수신 SINR을 단순화하기 위하여 L level중에 하나로 샘플링 하여 다음 타임 슬롯에서 RSU에게 전송한다. 따라서 각 NOMA 빔 내에 K 대의 차량이 존재하므로 총 KL 개의 상태를 갖는다. RSU의 행동 집합 (action set)은 각 차량의 전송 전력 할당 계수인 α 를 L level 중에 하나로 샘플링 한 값으로 설정한다. 즉, $\theta^t = [\alpha_{N_{n,k}^t}]_{n,k} \in \Omega$ 으로 설정하고, 이때 Ω 는 전력 할당 계수의 가능한 모든 집합이다. 이에 따라 K 대의

```

1: Set  $Q(s^t, \theta^t) = 0, u(s^t, \theta^t) = 0, \theta^t = 0, \forall t, s^0 = 0$ 
2: for  $t = 1$  to  $T$  do
3:   for  $k = 1$  to  $K$  do
4:     Choose action  $\theta_k^t$  via (28)
5:     Allocation power  $\theta_k^t P_T$  for the signal to User  $k$ 
6:   end for
7:   Send the superimposed signal  $x^t$  over  $N_T$  antennas
8:   Obtain the utility  $u(s^t, \theta^t)$  and
   the received SINR of each user  $\gamma_{N_{n,k}}^{t-1}$ 
9:    $s^{t+1} = [\gamma_{N_{n,k}}^t]_{1 \leq n \leq N}$ 
10:   $Q(s^t, \theta^t) \leftarrow (1 - \alpha) \cdot Q(s^t, \theta^t) + \alpha \cdot [u(s^t, \theta^t) + d \cdot \max_{\theta'} Q(s^{t+1}, \theta')]$ 
11: end for
    
```

그림 4. 제안 기법 알고리즘
Fig. 4. Proposed algorithm

NOMA 차량은 $P_n \theta^t$ 만큼의 전력 할당을 받게 된다.

제안하는 기법의 전체 동작 알고리즘을 그림 4에 나타내었다. 각각의 타임 슬롯에서 RSU는 주어진 상태에서 k 대의 차량에 대한 송신 전력을 무작위로 선택하고 그 결과로 수신된 유틸리티를 관찰하면서 시작된다. $Q(s^t, \theta^t)$ 는 시스템 상태에 대한 Q-function을 나타내며, RSU에 의해 관찰된 동작 θ^t 를 선택하여 전력을 할당한다. 그 후 RSU는 각 타임 슬롯에서 Q-function의 값을 식 (27)과 같이 업데이트 한다.

$$Q(s^t, \theta^t) \leftarrow (1 - \beta) Q(s^t, \theta^t) + \beta [u(s^t, \theta^t) + d \max_{\theta'} Q(s^{t+1}, \theta)] \quad (27)$$

여기서 $\beta \in (0, 1]$ 는 learning rate이고, d 는 discount factor이다. 행동 선택은 ϵ -greedy 방식으로 식 (28)에 나타내었다.

$$\theta_k^t = \begin{cases} \operatorname{argmax}(Q(s^t, \theta^t)), & \text{with probability } 1 - \epsilon \\ \text{random action}, & \text{with probability } \epsilon \end{cases} \quad (28)$$

여기서 ϵ 에 따라 Q-function의 최대의 값을 선택하거나 임의의 행동 (random action)을 취한다^[18]. 식 (28)에 의해 각 상태에서 행동이 선택되면 이에 따라 각 차량에게 전력을 할당하는데, 이에 따른 유틸리티 함수를 식 (29)에 나타내었고, 이 유틸리티 값은 각 상태에서의 보상으로 설정된다.

$$u = \mathbf{I}(\min_{n,k} \log_2(1 + \gamma_{N_{n,k}}) \geq R_{0,NV}) \times \mathbf{I}(\min_v \log_2(1 + \gamma_{V_{v,RX}}) \geq R_{0,VV})(R^{all}) \quad (29)$$

여기서 $\mathbf{I}(A)$ 는 지시 함수로서 사건 A 가 true면 1, false면 0을 취한다. 즉 각 차량의 최소 QoS를 만족할 때, 시스템 전체의 수율 R^{all} 이 보상으로 설정된다.

V. 모의실험

본 장에서는 먼저 제안하는 기법의 성능을 평가하기 위한 모의실험 환경에 대해서 설명하고, 이어서 모의실험 결과를 제시하고 분석한다.

5.1 모의실험 환경

Q-learning 기반 MIMO-NOMA 기법의 성능을 평가하기 위해서 차량은 모두 같은 방향으로 이동하고, 차선의 폭이 4 m, 4차선 도로의 모의실험 환경을 고려한다. 도로의 전체 길이는 3 km이고, RSU의 통달

표 1. 모의실험 파라미터
Table 1. Simulation parameters

Parameter	Value
Arrival distribution of the NOMA vehicle in l th lane, λ_l^{NOMA}	0.1 vehicles/sec
Arrival distribution of the V2V vehicle in l th lane, λ_l^{V2V}	0.2 vehicles/sec
Vehicle speed distribution, v_l^{NOMA}, v_l^{V2V}	Uni(60,80) km/h
Maximum transmitted power of V2I, P_n	40 dBm
Maximum transmitted power of V2V, P_v	20 dBm
Width of lane	4 m
Number of lanes	4
Thermal noise density	-174 dBm
RSU coverage	1.5 km
learning rate, β	0.8
discount factor, d	0.1
max TTI, T	3000 sec
Number of maximum V2V link, V	12
Number of vehicles in a beam, K	2
Number of NOMA beam, N	2
Standard deviation of channel information error, $\sigma_{RSU, N_{nk}}$	0.1, 0.2, 0.5 dBm
Standard deviation of channel, $\sigma_{RSU, N_{nk}}, \sigma_{V_n, TX}, \sigma_{V_n, RX}$	8 dB
discrete level, L	10

범위 (coverage)는 1.5 km로 가정한다. V2I 차량의 최대 전송 전력은 40 dBm, V2V 차량의 최대 전송 전력은 20 dBm으로 가정한다⁹⁾. 첫 번째 차선에서 각 차량의 도착은 $\lambda_1^{NOMA} = 0.1$ [vehicles/sec], $\lambda_1^{V2V} = 0.2$ [vehicles/sec]의 포아송 과정으로 가정하고, 차량의 차선 이동은 없으며 차선에 도착하는 속도는 $Uniform(60,80)$ [km]의 분포를 통해서 선택되며 차량 이동 중에 속도 변화는 없다고 가정한다. RSU에서 동시에 발생할 수 있는 V2I 빔의 최대 개수 $N=2$ 이다. 각 NOMA 빔 내에는 $K=2$ 대의 차량이 서비스된다고 가정한다. ROI내의 V2V 차량은 랜덤하게 V2V 링크를 형성한다. learning rate $\beta = 0.8$, discount factor $d = 0.1$ 을 적용하였다¹⁸⁾. 모의실험 파라미터의 세부사항은 표 1에 나타내었다.

5.2 모의실험 결과

시간이 경과함에 따라 차량들의 평균 SINR, 수율의 합을 성능 지표로 고려하였으며, 전수 조사 방식인 완전 탐색 (Exhaustive search) 알고리즘을 적용한 NOMA, Q-learning을 기반으로 한 OMA를 비교 대상으로 선정하였다. 매 타임 슬롯에서 가능한 전력 할당 계수를 전수 조사하여 가장 높은 성능을 찾는 방식이 완전 탐색 알고리즘이다. 그러나 가능한 값 전체를 조사하기 때문에 그만큼 계산 복잡도가 증가하는 단점이 있다²⁰⁾. OMA는 현재 LTE 시스템에서 사용되고 있는 다중 접속 방식이므로 NOMA의 성능을 비교하기 위해 많이 활용되는 기법이다.

그림 5는 타임 슬롯의 변화에 따른 차량들의 평균 SINR을 보여 주고, 그림 6은 타임 슬롯의 변화에 따른 수율의 합을 보여 준다. 그림 5와 그림 6에서 확인할 수 있듯이, 제안하는 기법은 학습이 진행될수록 성능이 좋아진다. 타임 슬롯 1000 sec부터 제안 기법이 완전 검색 알고리즘의 96% 성능으로 수렴하는 것을 알 수 있다. 완전 검색 알고리즘은 가능한 전력 할당 경우를 전수 조사하는 방식으로 복잡도가 매우 크다. 제안하는 Q-learning 기반 NOMA 기법이 Q-learning 기반 OMA 기법 보다 약 12.0% 높은 성능을 보인다.

그림 7은 제안 기법의 성능을 채널 정보 오류의 변화에 따른 차량들의 평균 SINR을 보여 준다. 채널 추정 오류의 표준 편차가 각각 0.05, 0.1, 0.5dB가 발생하여도 전체적인 성능은 크게 변화하지 않음을 확인하였다. 이는 차량 통신에서 채널 오류가 발생하여도 제안하는 Q-learning 기반 전력 할당 기법이 오류에 강인한 성능을 제공할 수 있음을 보여준다.

VI. 결론

본 논문은 MIMO-NOMA 기반 V2I 통신에서 Q-learning 기반 전력 할당 기법을 제안하였다. 종래의 NOMA 기법은 채널 정보를 완벽히 안다고 가정하여 실제 환경의 불완전한 채널에서는 적용하기 어렵다. 본 논문에서는 NOMA 기반의 V2I 통신과 OMA 기반의 V2V 통신이 혼재된 환경에서 불완전한 채널을 모델링하였다. 모의실험을 통해 제안한 시스템 환경에서 OMA 대비 12.0% 만큼의 성능 향상을 보였다. 또한 타임 슬롯 1000sec 이후에는 전수 조사 방식인 완전 탐색 알고리즘의 96% 성능까지 빠른 시간에 수렴하고 있음을 확인하였다. 제안하는 Q-learning 기반 MIMO-NOMA 기법은 RSU에서 수신하는 SINR을 기반으로 한 동적 전력 할당으로 무선 채널 정보 오류에 강인한 성능을 낼 수 있음을 확인하였다. 그러나 본 논문에서는 MIMO-NOMA의 빔 개수를 2개, 빔 당 차량은 2대로 한정지었다. 이는 Q-learning 알고리즘의 한계로 상태의 수가 차량의 수에 비례해 $K \times \Omega$ 만큼 기하급수적으로 커지기 때문이다^[18]. 따라서 상태의 수를 조절하여 더 많은 빔과 차량에 적용할 수 있는 알고리즘에 대한 추가 연구가 진행될 필요가 있다.

References

- [1] X. Cheng, L. Yang, and X. Shen, "D2D for intelligent transportation systems: A feasibility study," *IEEE Trans. Intell. Transp. Syst.*, vol. 16, no. 4, pp. 1784-1793, Aug. 2015.
- [2] J. Kim and S. Lee, "Reliable routing protocol for vehicle to infrastructure communications in VANET," *J. KICS*, vol. 34, no. 8, pp. 839-845, Aug. 2009.
- [3] Y. Nam, J. So, and J. Kim, "Interference mitigation scheme for device-to-device MIMO communications underlying a cellular network," *KSII. Trans. Internet and Inf. Syst.*, vol. 11, no. 4, pp. 1841-1865, Apr. 2017.
- [4] J. Cui, Y. Liu, Z. Ding, P. Fan, and A. Nallanathan, "Optimal user scheduling and power allocation for millimeter wave NOMA systems," *IEEE Trans. Wireless. Commun.*, vol. 17, no. 3, pp. 1502-1517, Mar. 2018.
- [5] S. Islam, J. Kim, and K. Kwak, "On non-

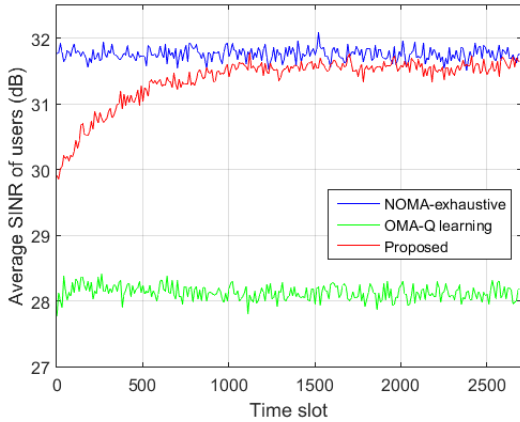


그림 5. 타임 슬롯 시간 경과에 따른 차량들의 평균 SINR
Fig. 5. Average SINR of vehicles vs. time slot

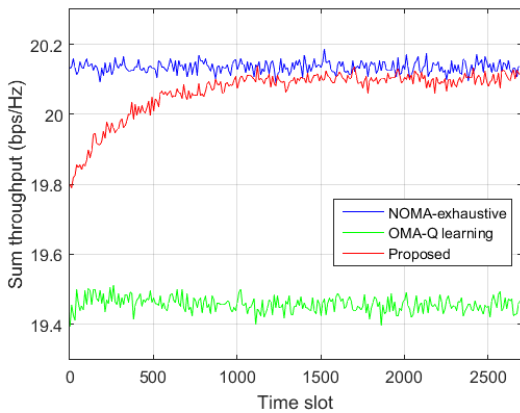


그림 6. 타임 슬롯 시간 경과에 따른 차량들의 수율 합
Fig. 6. Sum throughput of vehicles vs. time slot

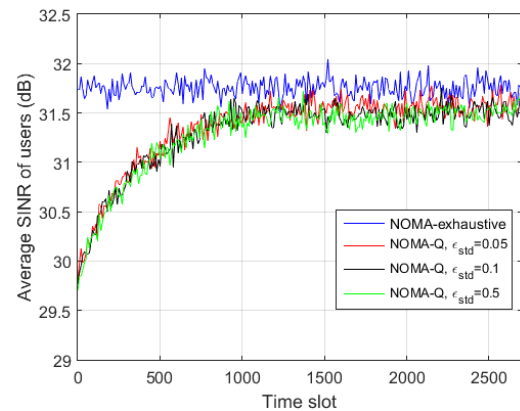


그림 7. 채널 추정 오류에 따른 평균 SINR
Fig. 7. Average SINR vs. channel estimation error

- orthogonal multiple access (NOMA) in 5G systems,” *J. KICS*, vol. 40, no. 12, pp. 2549-2558, Dec. 2015.
- [6] T. Lyu, “Capacity of multi-user MIMO systems with MMSE and ZF precoding,” in *Proc. IEEE INFOCOM WKSHPS*, pp. 1084-1084, San Francisco, USA, Apr. 2016.
- [7] S. Pyun, W. Lee, and D. Cho, “Resource allocation for vehicle-to-infrastructure communication using directional transmission,” *IEEE Trans. Intell. Transp. Syst.*, vol. 17, no. 4, pp. 1183-1188, Apr. 2016.
- [8] M. Al-Imari, P. Xiao, M. A. Imran, and R. Tafazolli, “Uplink non-orthogonal multiple access for 5G wireless networks,” in *Proc. 11th ISWCS*, pp. 781-785, Barcelona, Spain, Aug. 2014.
- [9] H. Sun, Y. Xu, and R. Q. Hu, “A NOMA and MU-MIMO supported cellular network with underlaid D2D communications,” in *Proc. IEEE VTC Spring*, pp. 1-5, Nanjing, China, May 2016.
- [10] Z. Ding, P. Fan, and H. V. Poor, “Impact of user pairing on 5G nonorthogonal multiple-access downlink transmissions,” *IEEE Trans. Veh. Technol.* vol. 65, no. 8, pp. 6010-6023, Aug. 2016.
- [11] X. Chen, A. Benjebbour, Y. Lan, A. Li, and H. Jiang, “Impact of rank optimization on downlink non-orthogonal multiple access (NOMA) with SU-MIMO,” in *Proc. IEEE ICCS*, pp. 233-237, Macau, China, Nov. 2014.
- [12] Y. Choi, Y. Lim, and J. Park, “Reinforcement learning approach for resource allocation in cloud computing,” *J. KICS*, vol. 40, no. 04, pp. 653-658, Apr. 2015.
- [13] R. Amiri, H. Mehrpouyan, L. Fridman, R. K. Mallik, A. Nallanathan, and D. Matolak, “A machine learning approach for power allocation in HetNets considering QoS,” in *Proc. IEEE ICC*, pp. 1-7, Kansas City, USA, May 2018.
- [14] P. V. Ferreira, R. Paffenroth, A. M. Wyglinski, T. M. Hackett, S. G. Bilien, R. C. Reinhart, and D. J. Mortensen, “Multi-objective reinforcement learning-based deep neural networks for cognitive space communications,” in *Proc. IEEE CCAA*, pp. 1-8, Cleveland, USA, Jun. 2017.
- [15] J. Joung, “Machine learning-based antenna selection in wireless communications,” *IEEE Commun. Lett.*, vol. 20, no. 11, pp. 2241-2244, Jul. 2016.
- [16] A. Asheralieva and Y. Miyanaga, “An autonomous learning-based algorithm for joint channel and power level selection by D2D pairs in heterogeneous cellular networks,” *IEEE Trans. Commun.*, vol. 64, no. 9, pp. 3996-4012, Sep. 2016.
- [17] A. Chiumento, C. Desset, S. Pollon, L. V. Perre, and R. Lauwereins, “Impact of CSI feedback strategies on LTE downlink and reinforcement learning solutions for optimal allocation,” *IEEE Trans. Veh. Technol.*, vol. 66, no. 1, pp. 550-562, Jan. 2017.
- [18] 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 Trans. Veh. Technol.*, vol. 67, no. 4, pp. 3377-3389, Apr. 2018.
- [19] S. Guo and X. Zhou, “Robust power allocation for NOMA in heterogeneous vehicular communications with imperfect channel estimation,” in *Proc. IEEE Int. Symp. PIMRC*, pp. 1-5, Montreal, Canada, Oct. 2017.
- [20] D. Lee, J. So, and S. Lee, “Power allocation and subcarrier assignment for joint delivery of unicast and broadcast transmissions in OFDM systems,” *J. Commun. and Networks*, vol. 18, no. 3, pp. 375-386, Jun. 2016.

이 재 희 (Jaehye Lee)



2005년 3월 : 공군사관학교 전
자공학과 졸업
2010년 2월 : 서울대학교 전기·
컴퓨터공학부 석사
2017년 3월~현재 : 서강대학교
전자공학과 박사과정
2005년~현재 : 대한민국 공군,
장교

<관심분야> 5G 이동통신, 차량통신, 머신러닝, 무선
자원할당, NOMA

[ORCID:0000-0002-7162-6911]

소 재 우 (Jaewoo So)



1997년 2월 : 연세대학교 전자공
학과 학사
1999년 2월 : 한국과학기술원 전
기 및 전자공학과 석사
2002년 8월 : 한국과학기술원 전
기 및 전자공학과 박사
2001년~2005년 : 아이피원, 수
석연구원

2005년~2007년 : 삼성전자, 책임연구원

2007년~2008년 : Stanford University, 전기공학과 박
사후연구원

2014년~2015년, 2018년 : UIUC, ECE 방문교수

2008년~현재 : 서강대학교 전자공학과 교수

<관심분야> 5G/IoT 무선 커넥티비티, V2X 차량통신,
머신러닝

[ORCID:0000-0001-6782-0212]

최 기 욱 (Giwook Choi)



2017년 2월 : 서강대학교 전자
공학과 학사

2019년 2월 : 서강대학교 전자
공학과 석사

2019년 3월~현재 : 에릭슨엘지,
연구원

<관심분야> 무선자원관리, 5G
이동통신, 머신러닝

[ORCID:0000-0001-5216-8233]