

거대 다중 안테나 시스템의 복잡도와 피드백 오버헤드 감소를 위한 심화 강화학습 기반 안테나 선택 기법

김륜우¹ · 정무웅² · 반태원^{3*}

Deep Reinforcement Learning based Antenna Selection Scheme For Reducing Complexity and Feedback Overhead of Massive Antenna Systems

Ryun-Woo Kim¹ · Moo-Woong Jeong² · Tae-Won Ban^{3*}

¹Graduate Student, Department of Information and Communication Engineering, Gyeongsang National University, Gyeongnam, 53064 Korea

²Researcher, Smart Ship ICT-Convergence Research Center, Research Institute of Medium & Small Shipbuilding, Busan, 46757 Korea

^{3*}Professor, Department of Information and Communication Engineering, Gyeongsang National University, Gyeongnam, 53064 Korea

요 약

본 논문에서는 다중 사용자 거대 다중 안테나 시스템에서 안테나 선택 기법을 제안한다. 제안된 안테나 선택 기법은 심화 강화학습 네트워크를 활용함으로써 피드백 오버헤드를 획기적으로 낮추면서 기존 방식과 거의 같은 성능을 얻을 수 있다. 각 사용자는 기지국의 거대 안테나들과 형성된 채널의 이득 값을 L 번째 큰 채널 이득과 비교하여 대소 관계에 따라서 단일 비트의 이진수로 변환하여 피드백함으로써 기존 피드백 방식보다 오버헤드를 낮출 수 있다. 제안 방식에서는 감소한 피드백 정보로 인한 성능 저하를 방지하기 위해서 심화 강화학습 네트워크를 활용하였다. 제안 방식의 성능을 분석하기 위하여 다양한 환경에서 시뮬레이션을 수행하였으며, 제안 방식이 최적 방식에 가까운 기존 방식과 유사한 평균 전송률을 얻을 수 있음을 확인하였다.

ABSTRACT

In this paper, an antenna selection scheme is proposed in massive multi-user multiple input multiple output (MU-MIMO) systems. The proposed antenna selection scheme can achieve almost the same performance as a conventional scheme while significantly reducing the overhead of feedback by using deep reinforcement learning (DRL). Each user compares the channel gains of massive antennas in base station (BS) to the L -largest channel gain, converts them to one-bit binary numbers, and feed them back to BS. Thus, the feedback overhead can be significantly reduced. In the proposed scheme, DRL is adopted to prevent the performance loss that might be caused by the reduced feedback information. We carried out extensive Monte-Carlo simulations to analyze the performance of the proposed scheme and it was shown that the proposed scheme can achieve almost the same average sum-rates as a conventional scheme that is almost optimal.

키워드 : MIMO, 대규모 MIMO 네트워크, 안테나 선택, 강화학습, 이진 피드백

Keywords : MIMO, Massive MIMO networks, Antenna selection, Reinforcement learning, BinaryFeedback

Received 9 September 2021, Revised 9 September 2021, Accepted 16 September 2021

* Corresponding Author Tae-Won Ban(E-mail:twban35@gnu.ac.kr, Tel:+82-55-772-9177)

Professor, Department of Information and Communication Engineering, Gyeongsang National University, Tongyeong, 53064 Korea

Open Access <http://doi.org/10.6109/jkiice.2021.25.11.1559>

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 다양한 모바일 기기들의 급격한 보급과 멀티미디어와 소셜미디어와 같은 서비스의 확산으로 모바일 데이터 트래픽이 급증하고 있다. 특히, 스마트폰용 데이터 트래픽이 전체 모바일 데이터 트래픽의 약 95%를 차지하고, 비디오 트래픽이 전체 트래픽의 66%를 차지하고 있다[1,2]. 이러한 모바일 트래픽의 급격한 증가에 대응하기 위해서는 광대역 서비스를 통한 모바일 네트워크 용량의 획기적인 개선이 필요하며 이를 위해서 밀리미터파를 적극적으로 활용할 필요가 있다. 밀리미터파들은 전파 특성이 열악하며, 이러한 단점을 극복하기 위하여 수백 또는 수천 개의 거대한 (massive) 수의 다중 안테나를 활용하기 위한 연구가 활발히 이루어지고 있다 [3~5]. 그러나, 많은 수의 안테나는 시스템의 복잡도를 증가시키고, 안테나별로 기저 대역 (baseband) 신호 처리부와 무선주파수 (radio frequency) 신호 처리부와 같은 별도의 하드웨어 장치를 필요하므로 안테나 수가 증가할수록 비용이 기하급수적으로 증가한다 [6,7]. 이러한 문제점을 해결하기 위해서 전체 안테나 수보다 적은 신호 처리부를 기저국에 구현한 뒤 안테나 선택 기술을 활용하여 신호 처리부 개수에 해당하는 안테나만을 선택적으로 활용하는 방안이 고려되고 있다 [8,9]. 이러한 안테나 선택 기법을 통해서 같은 다이버시티 이득을 얻으면서 기저국의 복잡도와 비용을 획기적으로 절감할 수 있다. 그리고, 주파수 분할 이중화 기반의 거대 다중 안테나 시스템에서는 각 사용자가 수 많은 안테나의 채널 정보를 기저국으로 피드백해야 하므로 오버헤드가 증가하는 문제점이 존재한다.

본 논문에서는 거대 다중 안테나 시스템의 이러한 두 가지 문제점을 동시에 해결하기 위해서 정보량이 감소한 피드백 정보를 활용하는 심화 강화학습 기반의 안테나 선택 기법을 제안한다. 각 채널 이득을 16비트 또는 32비트 길이의 부동소수점형식으로 표현하여 피드백하는 기존 방식과 달리, 제안 방식에서 각 사용자는 각 채널 이득을 한 비트 정보로 표시하여 피드백하며, 이를 통해서 피드백 정보의 양을 1/16 또는 1/32로 감소시킬 수 있다. 반면에, 심화 강화학습 기법을 활용함으로써 감소한 피드백 정보에도 불구하고, 기존 방식과 같은 성능을 얻을 수 있음을 확인하였다.

본 논문의 구성은 다음과 같다. II장에서는 본 논문에서

고려하는 시스템 모델과 채널 모델에 대하여 설명한다. III장에서는 제안하는 심화 강화학습 기반의 안테나 선택 기법과 피드백 감소 기법을 설명한다. IV장에서는 다양한 시뮬레이션을 통해서 제안 방식의 성능을 분석하고, 이를 기존 방식과 비교하여 제안 방식의 우수성을 입증한다. 마지막으로, V장에서 본 논문의 결론을 맺는다.

II. 시스템 모델 및 채널 모델

본 논문에서는 그림 1과 같이 복수의 사용자들에게 동시에 데이터를 전송함으로써 주파수 효율성을 높일 수 있는 거대 다중 안테나 시스템의 하향 링크를 고려한다. 기저국은 N 개의 안테나를 가지고 있으며 최대 K 명의 사용자를 대상으로 서비스를 제공한다. 이때, $N \gg K$ 를 만족한다. 기저국은 복잡도와 비용에 따른 제약으로 N 개보다 작은 S 개의 기저 대역 신호 처리부와 RF 신호 처리부만을 탑재하고 있다. 따라서, $N \geq S \geq K$ 을 만족한다. x_k 는 기저국이 사용자 k 에게 전송할 신호를 나타내며 $1 \leq k \leq K$ 이다. \mathbf{v}_k 는 신호 x_k 에 곱해지는 $S \times 1$ 크기의 빔포밍 벡터이며, $\|\mathbf{v}_k\|^2 = 1 \forall k$ 을 만족한다. I_n 는 안테나 n 이 데이터 전송에 대한 사용 여부를 나타내는 지시자이며, 안테나 n 이 데이터 전송을 위해서 선택되어 지면 $I_n = 1$ 이며, 그렇지 않으면 $I_n = 0$ 이다. $\mathbf{I} = [I_1 \ I_2 \ \dots \ I_N]^T$ 이다. $\|\cdot\|$ 을 임의의 벡터에 대한 $norm$ 으로 정의하고 \odot 을 두 벡터 간의 Hardamard 곱으로 정의하면, $\|x_k\|^2 = 1$ 와 $\|\mathbf{v}_k \odot \mathbf{I}\|^2 = 1$ 을 만족한다. h_{kn} 은 사용자 k 와 안테나 n 사이의 채널 지수를 나타낸다. 모든 $k(1 \leq k \leq K)$ 와 $n(1 \leq n \leq N)$ 에 대하여 h_{kn} 평균이 0, 분산이 1인 복소 정규 분포를 따르고 independent and identically distributed (i.i.d.)이다. 또한, 시분할 이중화 (time division duplex) 기법을 고려한다. Quasi-static block fading을 가정하므로, 모든 채널 지수들은 데이터를 전송할 때마다 랜덤하게 변하지만, 데이터를 전송하는 동안에는 일정한 값을 유지한다. 사용자 k 가 수신하는 신호 y_k 는 식 (1)과 같이 주어진다.

$$\begin{aligned} y_k &= \mathbf{h}_k \sum_{j=1}^K \sqrt{p_j} x_j \mathbf{v}_j \odot \mathbf{I} + n_k \\ &= \sqrt{p_k} \mathbf{h}_k \mathbf{v}_k \odot \mathbf{I} + \mathbf{h}_k \sum_{j=1, j \neq k}^K \sqrt{p_j} x_j \mathbf{v}_j \odot \mathbf{I} + n_k \end{aligned} \quad (1)$$

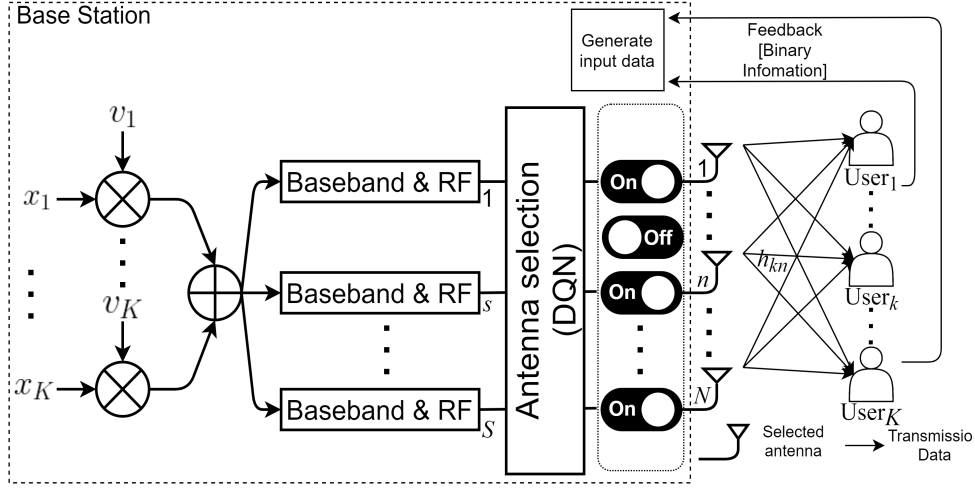


Fig. 1 Proposed antenna selection scheme for massive MIMO communication systems

식 (2)에서 p_k 는 기지국이 사용자 k 에게 할당하는 전송전력으로 본 논문에서는 모든 사용자에게 같은 전송전력을 할당하는 것으로 가정하므로 $p_k = P \forall k$ 이다. \mathbf{h}_k 는 사용자 k 가 N 개의 안테나로부터 수신하는 채널의 지수들로 구성된 $1 \times N$ 크기의 벡터를 나타내며 $\mathbf{h}_k = [h_{k1} h_{k2} \dots h_{kN}]$ 이다. n_k 는 Additive White Gaussian Noise (AWGN)을 나타내며 평균이 0이고 분산이 N_0 인 복소 정규 분포를 따른다. 사용자 k 의 수신 signal-to-interference-plus-noise-ratio (SINR)은 다음과 같이 계산된다.

$$\begin{aligned} SINR_k &= \frac{P \|\mathbf{h}_k \mathbf{v}_k \odot \mathbf{I}\|^2}{N_0 + P \sum_{j=1, j \neq k}^K \|\mathbf{h}_j \mathbf{v}_j \odot \mathbf{I}\|^2} \\ &= \frac{\gamma \|\mathbf{h}_k \mathbf{v}_k \odot \mathbf{I}\|^2}{1 + \gamma \sum_{j=1, j \neq k}^K \|\mathbf{h}_j \mathbf{v}_j \odot \mathbf{I}\|^2} \end{aligned} \quad (2)$$

식 (2)에서 $\gamma = \frac{P}{N_0}$ 이며, signal-to-noise ratio (SNR)를 나타낸다. $SINR_k$ 를 이용하여 사용자 k 가 얻을 수 있는 데이터 전송률 R_k 는 식 (3)과 같이 계산된다.

$$R_k = \log_2(1 + SINR_k) \quad (3)$$

그리고 전체 전송률의 합 C 는 아래와 같이 계산된다.

$$C = \sum_{k=1}^K R_k \quad (4)$$

그리고, 식 (4)에서 정의된 전체 전송률의 합을 최대화할 수 있는 식 (5)와 같이 안테나들의 조합을 선택해야 한다.

$$\mathcal{I}^* = \operatorname{argmax}_{\mathcal{I}} C \quad (5)$$

III. DQN을 이용한 안테나 선택 및 피드백 기법

주어진 채널 이득에서 \mathcal{I}^* 의 수학적 해답을 찾기는 불가능하다 [10]. 본 논문에서는 그림 2에서 볼 수 있듯이, deep Q network (DQN) 기반의 심화 강화학습을 활용하여 안테나 선택 기법을 고려했다. DQN은 입력 계층, 세 개의 은닉계층, 그리고 출력 계층으로 구성된다. 각 은닉계층은 Rectified Linear Unit (ReLU) 함수에 의해서 활성화되며, 마지막 출력 계층은 softmax 함수에 의해서 활성화된다. 은닉계층의 크기는 각각 $4N$, $8N$, 그리고 $2N$ 으로 설정하였다. s^t 와 r_t 는 특정 시간 t 에서 DQN의 입력과 보상을 각각 나타낸다. s^t 는 사용자들로부터 받는 피드백 정보를 활용하여 식 (6)과 같이 생성된다.




Fig. 2 The architecture of DQN for selecting S antennas

$$s^t = [f_1^t \dots f_k^t \dots f_K^t]^T \quad (6)$$

식 (6)에서 f_k^t 는 시간 t 에 사용자 k 로부터 피드백 받은 정보를 나타내며 $1 \times N$ 크기의 벡터이다. 따라서, s^t 는 $N \times K$ 크기의 2차원 행렬이 된다. r_t 는 식 (4)에 정의된 전체 전송률의 합을 나타낸다. 이때, r_t 는 선택된 안테나를 통해서 데이터 전송이 이루어진 후에 관측되는 보상에 해당한다. DQN의 파라미터들을 θ_t 라고 할 때, DQN의 출력은 $Q(s^t; \theta^t)$ 로 표시된다. $Q(s^t; \theta^t)$ 중에서 그 값이 큰 순서대로 S 개를 선택하고, 선택된 인덱스에 해당하는 안테나만 데이터 전송을 위해 사용된다. DQN의 목표 Q 값은 식 (7)과 같이 전송률의 합으로 정의된다.

$$\hat{Q}^t = C \quad (7)$$

본 논문에서 고려하고 있는 시스템 모델에서는 현재의 행동이 미래의 상태 s^{t+1} 에 영향을 미치지 않으므로, 미래 보상에 대한 discounting factor를 0으로 가정하였다. DQN의 출력이 \hat{Q}^t 와 가까워지도록 평균 제곱 오차 (mean square error) $\|Q(s^t; \theta^t) - \hat{Q}^t\|$ 를 최소화하기 위해서 DQN의 파라미터들을 경사 하강법에 따라서 다음과 같이 갱신된다.

$$\theta^t \leftarrow \theta^t - \nu \nabla \theta^t \quad (8)$$

여기서 ν 는 학습률을 나타내며, $\nabla \theta^t$ 는 시간 t 에서 θ 의 gradient를 나타낸다. 사용자 k 는 N 개의 기지국 안테나로부터 수신하는 참조 신호 (reference signal)을 측정함으로써 $[|h_{k1}|, |h_{k2}|, \dots, |h_{kN}|]$ 와 같은 N 개의 채널 이득을 추정하고, 채널 이득의 크기에 따라서 다음과 같이 내림차순으로 정렬한다.

$$|h_{k\hat{1}}| \geq |h_{k\hat{2}}| \geq \dots \geq |h_{k\hat{N}}| \quad (9)$$

이때, $|h_{k\hat{L}}|$ 은 L 번째 큰 채널 이득의 값을 나타낸다.

$f_k^t[n]$ 을 f_k^t 의 n 번째 요소로 정의하면, 제안 방식에서 $f_k^t[n]$ 은 다음과 같이 결정된다.

$$f_k^t[n] = \begin{cases} 1, & \text{if } h_{kn} \geq h_{k\hat{L}}, 1 \leq n \leq N, 1 \leq k \leq K \\ 0, & \text{otherwise} \end{cases} \quad (10)$$

제안 방식은 그림 3에서 보듯이 f_k^t 를 이용하여 DQN의 출력 값 Q 를 먼저 계산한다. 그리고, N 개의 출력 중에서 큰 순서대로 S 개의 인덱스를 선택하며 이에 해당하는 안테나들만을 이용할 데이터를 전송한다.




Fig. 3 Antenna select scheme using DQN

IV. 성능 분석

본 장에서는 III장에서 제안한 피드백 기법을 활용하는 DQN 기반의 안테나 선택 기법의 성능을 분석한다. 실제 환경에서 DQN의 학습을 위한 훈련용 데이터를 확보하기 어려운 점을 고려하여, II장에서 가정한 채널 모델에 따라서 Monte-Carlo 시뮬레이션을 진행하였다. Experience replay를 위해서 버퍼를 사용하였으며, 미니 배치 크기는 10으로 설정하였다. 학습률 ν 는 0.001로 설정하였으며, DQN 파라미터의 학습은 Adam optimizer를 사용하였다. 성능 분석을 위하여 Block-Diagonalization 기반의 빔포밍 방식을 가정하고 각 사용자는 같은 전송 전력을 할당받는 환경을 고려한다 [11]. 그리고, 제안 방식은 동일 이득 결합 (equal gain combining) 등 다양한

빔포밍 방식에 적용될 수 있다. 그리고, 제안 방식의 성능을 [10]에서 제안된 기존 방식과 비교한다. 기존 방식은 채널 이득의 2-norm을 내림차순으로 정렬한 후 연속된 S 개의 안테나 조합들을 대상으로 데이터 전송률을 확인 후 가장 큰 데이터 전송률에 해당하는 조합을 선택하며 낮은 복잡도에도 불구하고, 최대 데이터 전송률에 근접하는 성능을 얻을 수 있다[10].

그림 4는 N , K , 그리고 γ 는 각각 100, 20, 그리고 10dB일 때, S 의 다양한 값들에 대하여 제안 방식과 기존 방식의 평균 전송률의 합을 나타낸다. $S \leq 50$ 일 경우, L 값과 관계없이 제안 방식이 기존 방식보다 성능이 우수하다. 제안 방식 중에서는 L 이 20인 경우에 가장 높은 성능을 나타내지만, 다른 L 값들의 경우와 차이가 크

지 않다. $S > 50$ 인 경우에는 제안 방식보다 기존 방식의 성능이 우수하지만, 제안 방식에서는 각 사용자가 채널 이득 값 자체를 피드백하지 않고 N 비트의 이진수만을 피드백한다. 반면에, 채널 이득을 부동소수점 방식으로 표현하기 위해서는 각 채널 이득별로 약 16비트 또는 32비트가 필요하며 [12], 사용자당 $16N$ 또는 $32N$ 비트가 필요하다. 그림 5는 N , K , 그리고 γ 는 각각 200, 40, 그리고 10dB일 때, S 의 다양한 값들에 대하여 제안 방식과 기존 방식의 평균 전송률의 합을 나타낸다. 제안 방식은 S 값과 관계없이 제안 방식과 같은 성능을 나타내며, 제안 방식의 성능은 L 값에 영향을 받지 않는 것을 알 수 있다.

그림 6과 7은 다양한 L 의 값들에 대하여 제안 방식과

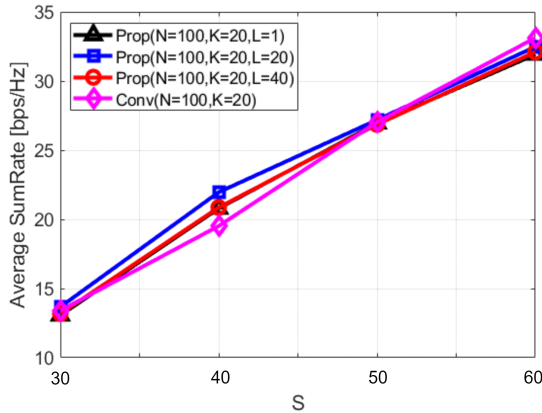


Fig. 4 Average sum rates of conventional and proposed schemes for various values of S . $N=100$, $K=20$, and $\gamma=10$ dB.




Fig. 6 Average sum rates of proposed schemes for various values of L . $N=100$, $K=20$, and $\gamma=10$ dB.

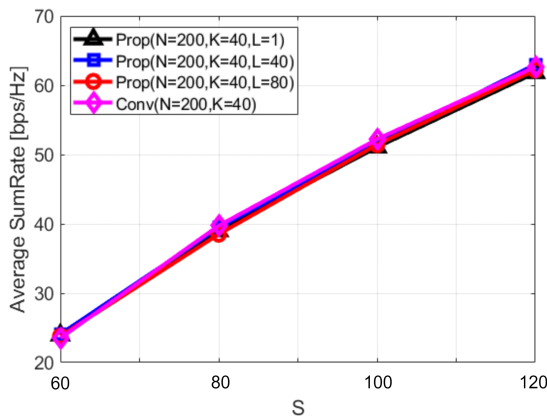


Fig. 5 Average sum rates of conventional and proposed schemes for various values of S . $N=200$, $K=40$, and $\gamma=10$ dB.




Fig. 7 Average sum rates of proposed schemes for various values of L . $N=200$, $K=40$, and $\gamma=10$ dB.

기존 방식의 평균 전송률의 합을 나타낸다. 그림 7에서는 N , K , 그리고 γ 가 각각 100, 20, 그리고 10dB로 설정하였다. S 는 30, 40, 50, 또는 60이다. 그림 6에서는 N , K , 그리고 γ 가 각각 200, 40, 그리고 10dB로 설정하였다. S 는 60, 80, 100, 또는 120이다. 먼저, S 가 커질수록 다중 안테나 이득으로 인해 평균 전송률의 합이 증가함을 알 수 있다. 그리고, 특정 S 에 대해서 L 값에 따른 성능 차이는 미미하며, 이는 DQN의 학습 데이터의 양 및 학습 시간 등과 같은 시뮬레이션 환경에 따른 차이로 판단된다.

V. 결론

무선주파수 자원의 부족으로 차세대 이동통신 네트워크에서는 밀리미터파의 폭넓은 활용이 필수적으로 요구된다. 본 논문에서는 차세대 이동통신 네트워크에서 밀리미터파의 전파 특성상 단점을 극복하기 위한 핵심 요소 기술 중의 하나인 거대 다중 안테나 시스템을 연구하였다. 거대다중 안테나 시스템의 문제점 중의 하나인 기지국의 높은 복잡도와 비용 문제를 해결하기 위해서 심화 강화학습을 이용한 안테나 선택 기법을 제안하고 피드백 오버헤드를 줄이기 위해서 새로운 피드백 기법도 제안하였다. 각 사용자는 다중 안테나로부터 수신한 정보를 이용하여 측정된 채널 이득을 특정 값과 비교하여 대소관계에 따라서 이진수로 변환한 후에 피드백한다. 기지국에 탑재된 전체 안테나 수를 N 으로 가정하면, 제안된 피드백 기법에서 각 사용자가 피드백하는 정보는 N 비트만으로 구성된다. 감소한 피드백 정보를 활용하여 안테나를 효과적으로 선택하기 위해서 본 논문에서는 심화 강화학습을 활용하였다. 다양한 환경에서 제안 방식의 평균 전송률의 합을 분석하였으며, 이를 기존 방식과 비교하였다. 200개의 안테나, 40명의 사용자, 그리고 SNR이 10dB일 때, 제안된 안테나 선택 기법은 기존 방식과 성능이 같으면서 피드백 오버헤드를 약 1/16 또는 1/32로 줄일 수 있음을 확인하였다. 그리고, 제안 방식은 피드백 정보에서 1의 개수를 나타내는 L 값에 따라서 성능 차이가 크지 않음을 확인하였다. 따라서, 실제 환경에서는 L 을 1로 설정하는 것이 타당하다.

ACKNOWLEDGEMENT

This work was supported by the National Research Foundation of Korea(NRF) grant funded by the Korea government(Ministry of Education) (No. 2020R111A3061195, Development Of Wired and Wireless Integrated Multimedia-Streaming System Using Exclusive OR-based Coding).

REFERENCES

- [1] Mobile data traffic outlook [Internet]. Available: <https://www.ericsson.com/en/mobility-report/dataforecasts/mobile-traffic-forecast>.
- [2] Cisco White Paper, *Cisco Visual Networking Index: Global Mobile Data Traffic Forecast Update*, Feb. 2019.
- [3] K. S. Kim, Y. H. Kang, and C. K. Kim, "Research Trend in 5G-TSN for Industrial IoT," *Electronics and Telecommunications Trends*, vol. 35, no. 5, pp. 43-45, Oct. 2020.
- [4] C. M. Chen, V. Volski, L. Van der Perre, G. A. Vandenbosch, and S. Pollin, "Finite large antenna arrays for massive MIMO: Characterization and system impact," *IEEE Transactions on Antennas and Propagation*, vol. 65, no. 12, Dec. 2017.
- [5] R. Chataut and R. Akl, "Massive MIMO systems for 5G and beyond Networks—Overview, Recent Trends, Challenges, and Future Research Direction," *Sensors*, vol. 20, no. 10, May. 2020.
- [6] S. Jacobsson, U. Gustavsson, G. Durisi, and C. Studer, "Massive MU-MIMO-OFDM uplink with hardware impairments: Modeling and analysis," *2018 52nd Asilomar Conference on Signals, Systems, and Computers*, pp. 1829-1835, 2018.
- [7] U. Gustavsson, C. Sánchez-Perez, T. Eriksson, F. Athley, G. Durisi, P. Landin, and L. Svensson, "On the impact of hardware impairments on massive MIMO," in *IEEE Globecom Workshops (GC Wkshps)*, Austin, pp. 294-300, 2014.
- [8] H. Nosrati, E. Aboutanios, and D. Smith, "Multi-Stage Antenna Selection for Adaptive Beamforming in MIMO Radar," in *IEEE Transactions on Signal Processing*, vol. 68, pp. 1374-1389, 2020.
- [9] G. Jin, C. Zhao, Z. Fan, and J. Jin, "Antenna selection in TDD massive MIMO systems," *Mobile Networks and*

- Applications*, pp. 1-7, 2019.
- [10] T. W. Ban, M. W. Jeong, and B. C. Jung, "User and Antenna Joint Selection Scheme in Multiple User Massive MIMO Networks," *Journal of the Korea Institute of Information and Communication Engineering*, vol. 19, no. 1, pp. 77-82, Jan. 2015.
- [11] S. Shim, J. S. Kwak, R. W. Heath, and J. G. Andrews, "Block diagonalization for multi-user MIMO with other-cell interference," *IEEE Trans. Wireless Comm.*, vol. 7, no. 7, pp. 2671-2681, Jul. 2008.
- [12] IEEE Std. 754-2019, *IEEE Standard for Floating-Point Arithmetic*, IEEE, Piscataway, N.J., 1995.



김륜우(Ryun-Woo Kim)

2021년 2월 경상국립대학교 정보통신공학과 학사
2021년 3월~현재 경상국립대학교 석사과정
※관심분야 : Drone security, Reinforcement Learning, 차세대 이동통신



정무웅(Moo-Woong Jeong)

2014년 2월 경상국립대학교 정보통신공학과 학사
2014년 3월~2020년 8월 경상국립대학교 정보통신공학과 박사
2020년 9월~2021년 4월 경상국립대학교 정보통신공학과 박사 후 연구원
2021년 4월~현재 중소조선 연구원 연구원
※관심분야 : 차세대 이동통신, MIMO, D2D, Reinforcement Learning



반태원(Tae-Won Ban)

1998년 2월 경북대학교 전자공학과 학사
2000년 2월 경북대학교 전자공학과 석사
2010년 2월 KAIST 전기및전자공학과 박사
2000년 2월~2012년 8월 KT 네트워크부문
2012년 9월~현재 경상대학교 정보통신공학과 부교수
※관심분야 : 이동통신, 자원관리, 간섭관리, 협력 및 중계통신, 인지통신, 주파수 공유, 차세대 이동통신 시스템