

# 비예약식 접속 시스템의 딥러닝 기반 충돌 인지 다중 사용자 검출을 위한 전처리 기법

\*한민식°, \*Metasebia D. Gameda, Ameha T. Abebe, \*강충구  
\*고려대학교 전기전자공학과

## Preprocessing Scheme for Deep learning-based Collision-aware Multi-user Detection in Grant-free Access Systems

\*Min S. Han°, \*Metasebia D. Gameda, Ameha T. Abebe, \*Chung G. Kang  
\*Korea University  
{als4585, met4, ccgkang}@korea.ac.kr

### 요약

상향링크 비예약식 sparse code multiple access (SCMA) 시스템에서는 각 활성 사용자가 임의로 선택된 SCMA 코드북을 사용하여 데이터를 송신하기 때문에 두 활성 사용자가 동일한 코드북을 선택하는 코드북 충돌이 발생한다. 이 경우에도 기지국에서는 딥러닝을 이용한 충돌 인지 다중 사용자 검출기(collision-aware multi-user detection: CA-MUD)를 통해 여전히 채널 변조된 코드북을 감지할 수 있다. 하지만, 수신 데이터와 채널만을 입력으로 고려하는 기존 입력 구조를 그대로 사용하면, 비예약식 전송 특성상 활성 코드북 조합이 실시간으로 변화하기 때문에 CA-MUD의 학습이 어렵다. 본 논문에서는 이 문제를 극복하기 위해, CA-MUD를 위한 입력 전처리 방식을 제안하고, 이를 통해 낮은 사용자 활성화도에서 평균 비트 오류율 성능 이득을 확인한다.

### I. 서론

최근 수많은 기기들이 상향링크로 다중 접속하는 서비스 시나리오인 대규모 사물 통신(massive Machine Type Communication: mMTCs)을 지원하기 위해 grant-free sparse codebook multiple access (GF-SCMA) 시스템이 고려되었다. [1] GF-SCMA 시스템에서는 시간-주파수 결합 영역(contention region)에 분산된 사용자들 중 일부의 활성 사용자가, 주어진 SCMA 코드북 중 하나를 임의로 선택하여 프리엠블과 함께 데이터를 전송한다. 이때, 각 활성 사용자가 코드북을 임의적으로 선택하기 때문에 서로 다른 두 사용자가 동일한 SCMA 코드북을 고르는 코드북 충돌이 발생할 수 있다. 하지만, 코드북 충돌이 발생하더라도, 수신단에서 프리엠블을 통해 각 활성 사용자가 사용한 코드북 인덱스와 해당 코드북이 전송된 채널을 성공적으로 추정한다면, 충돌 인지 다중 사용자 검출(collision-aware multi-user detection: CA-MUD)을 통해 충돌된 코드북의 데이터를 검출할 수 있다. [1-2]

전통적인 방식의 CA-MUD는 message passing algorithm 기반 CA-MUD를 수행하였다. [2] 그러나 MPA 기반의 CA-MUD 방식은 모든 코드북 활성 조합에 대해서도 다른 CA-MUD 절차가 필요하여 구현의 복잡도가 매우 높다. 따라서 [3]과 같이 딥러닝을 이용한 CA-MUD를 고려하면, 충돌을 포함한 서로 다른 코드북 활성 조합을 하나의 네트워크 구조에 학습하여 구현 복잡도를 줄일 수 있다. 그러나, [3]은 상향링크 채널만을 고려하여 CA-MUD를 학습하기 때문에, 활성 코드북이 동적으로 변화하는 환경에서는 채널 변조 코드북 검출을 위한 CA-MUD의 학습이 어렵다. 이러한 문제를 해결하기 위해, 본 논문에서는 CA-MUD의 입력으로 채널과 코드북을 결합한 채널 변조 코드북을 고려하는 입력 전처리 방식을 제안하여 CA-MUD 학습의 효율성을 높인다.

### II. GF-SCMA 시스템 모델

수많은 사용자들이 각 결합영역에  $N$  명씩 분산되며, 각  $N$  명의 사용자 중  $N_a$  명의 활성사용자가  $J$  개의 코드북  $\bar{C} = \{C_0, C_1, \dots, C_{J-1}\}$  중 하나를 임의로 선택하여 데이터를 전송하는 GF-SCMA 시스템을 고려한다. 이때,  $j$  번째 코드북  $C_j$ 는  $\bar{c}_j = [(\mathbf{c}_1^{(j)})^T, (\mathbf{c}_2^{(j)})^T, \dots, (\mathbf{c}_M^{(j)})^T]^T \in \mathbb{C}^{K \times M}$ 와 같이 벡터로 표현될 수 있다. 이때,  $\mathbf{c}_m^{(j)} \in \mathbb{C}^K$ 은  $j$  번째  $M$ -ary 코드북의  $m$  번째 코드워드를 나타낸다.

각 사용자는 스스로 활성화될지 판단하여, 데이터와 프리엠블을 동시에 전송한다. 이 때  $n$  번째 사용자가

활성화되어 데이터를 전송하면 활성 지시자  $\delta_n$ 이 1 이고 데이터를 전송하지 않는다면  $\delta_n$ 이 0 이라고 한다. 한편,  $n$  번째 사용자가 선택한 코드북 인덱스를  $\nu(n)$  이라고 하고, 코드워드를  $\mathbf{w}^{\nu(n)}$ , 그리고 프리엠블을  $\mathbf{p}^{(n)}$  이라고 한다. 이 때, 활성 사용자들에 의한 중첩된 데이터와 프리엠블은 다음과 같이 표현된다.

$$\mathbf{y}^{(d)} = \sum_{n=0}^{N-1} \delta_n h_n \mathbf{w}^{\nu(n)} + \mathbf{n}^{(d)} \quad (1)$$

$$\mathbf{y}^{(p)} = \sum_{n=0}^{N-1} \delta_n h_n \mathbf{p}^{(n)} + \mathbf{n}^{(p)}, \quad (2)$$

이때,  $\mathbf{n}^{(d)}$ 와  $\mathbf{n}^{(p)}$ 은 가산성 가우시안 잡음이며,  $h_n$ 은 사용자  $n$ 의 채널이다.

### III. 제안 방식

본 논문에서는 CA-MUD 디자인을 위해 그림 1과 같이 프리엠블 충돌이 없고, 최대  $\lambda$  개 코드북 충돌만을 허용하는 상황을 가정한 송수신 모델을 고려한다. 이를 위해, 각 사용자에게 고유의 프리엠블이 할당되고  $n$  번째 사용자는 round-robin 형태로  $\nu(n) = \text{mod}(n, J)$  번째 코드북을 선택하는 송수신 모델을 고려한다. 이러한 모델을 통해 실제 상황에서 프리엠블 충돌 또는  $\lambda$  개 이상의 코드북 충돌이 발생하여, 수신이 불가능한 경우를 제외하여 설계 복잡도를 줄일 수 있다. 그림 1의 수신단에선  $\mathbf{y}^{(p)}$ 를 통해 활성 코드북 인덱스와 해당 코드북이 전송된 채널을 추정한다. 즉, 먼저  $N_a$  개의 활성 프리엠블 지시자가 포함된  $\hat{\delta} = [\hat{\delta}_0, \hat{\delta}_1, \dots, \hat{\delta}_{J-1}]^T$ 을 검출하면, 해당 활성 프리엠블에 연관된 활성 코드북 세트  $\mathcal{S} = \{C_{i_1}, C_{i_2}, \dots, C_{i_{N_a}}\}$ 를 알 수 있다. 한편,  $n$  번째 사용자의 추정 채널을  $\hat{\mathbf{h}}_n \in \mathbb{C}^K$ 이라고 하면, 전체 사용자의 추정 채널은  $\hat{\mathbf{h}}_{\mathcal{S}} = [\hat{\delta}_0 \hat{\mathbf{h}}_0^T, \hat{\delta}_1 \hat{\mathbf{h}}_1^T, \dots, \hat{\delta}_{J-1} \hat{\mathbf{h}}_{J-1}^T]^T$ 로 나타낸다.

이 때  $\hat{\mathbf{h}}_{\mathcal{S}}$ 는 활성 코드북 인덱스와 그 채널 정보가 포함이 되어 있기 때문에 이상적으로는  $\hat{\mathbf{h}}_{\mathcal{S}}$ 와  $\mathbf{y}^{(d)}$ 만을 입력으로 고려한 CA-MUD 학습이 가능하다. [3] 그러나  $\hat{\mathbf{h}}_{\mathcal{S}}$ 에는 실제 코드북 구조가 포함되지 않으므로  $\mathbf{y}^{(d)}$ 에 전송된 코드북 조합이 매번 바뀌는 경우엔 효과적인 학습이 어렵게 된다. 따라서, 본 논문에서는 CA-MUD 학습 시 채널과 코드북을 동시에 고려하기 위해, 채널 변조 코드북 벡터를 생성하여 CA-MUD의 입력으로 넣어주는 입력 전처리 과정을 고려한다.

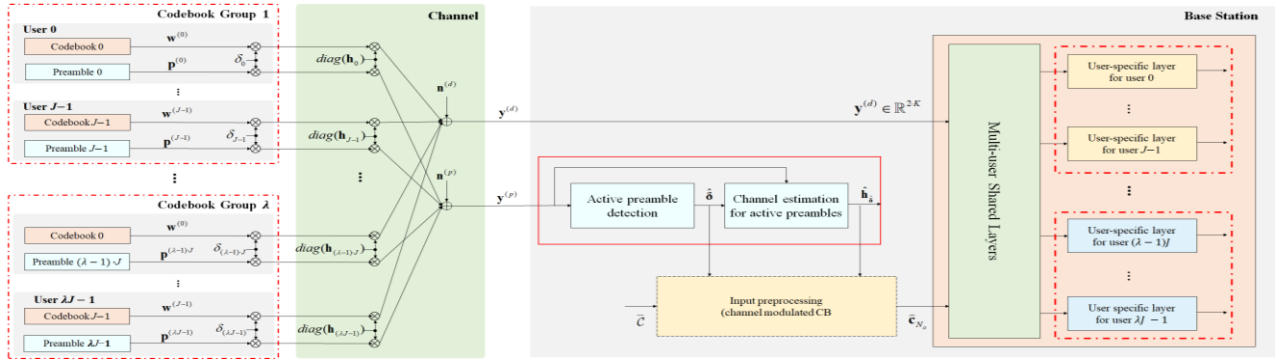


그림 1.  $\lambda$  개 충돌을 구분하는 딥러닝 기반 CA-MUD 구조와 입력 전처리 절차

입력 전처리를 위해 먼저 활성화된 코드북들을 연결한 활성 코드북 벡터  $\bar{\mathbf{c}}_{N_a} = [\bar{\mathbf{c}}_1^T, \bar{\mathbf{c}}_2^T, \dots, \bar{\mathbf{c}}_{N_a}^T]^T \in \mathbb{C}^{K \cdot M \cdot N_a}$  를 생성한다. 한편, 활성 코드북  $\mathcal{C}_i$  에 대한 추정 채널을  $\hat{\mathbf{h}}_i \in \mathbb{C}^K$  라고 할 때 이를  $M$  번 반복하여, 활성 코드북  $\mathcal{C}_i$  의 반복 채널 벡터  $\bar{\mathbf{h}}_i = [\hat{\mathbf{h}}_i^T, \hat{\mathbf{h}}_i^T, \dots, \hat{\mathbf{h}}_i^T]^T \in \mathbb{C}^{K \cdot M}$  를 생성한다. 그 후, 각 활성 코드북들에 대한  $\bar{\mathbf{h}}_i$  를 모두 연결하여 활성 채널 벡터  $\bar{\mathbf{h}}_{N_a} = [\bar{\mathbf{h}}_1^T, \bar{\mathbf{h}}_2^T, \dots, \bar{\mathbf{h}}_{N_a}^T]^T \in \mathbb{C}^{K \cdot M \cdot N_a}$  를 생성한다. 그 후,  $\bar{\mathbf{c}}_{N_a}$  와  $\bar{\mathbf{h}}_{N_a}$  의 각 요소를 곱하여 채널 변조 코드북 벡터  $\hat{\mathbf{c}}_{N_a} = \text{diag}(\bar{\mathbf{h}}_{N_a}) \cdot \bar{\mathbf{c}}_{N_a} \in \mathbb{C}^{K \cdot M \cdot N_a}$  를 생성한다. 마지막으로, CA-MUD 네트워크 입력으로 넣기 위해 실수 벡터  $\hat{\mathbf{c}}_{N_a} = [\text{Re}(\hat{\mathbf{c}}), \text{Im}(\hat{\mathbf{c}})] \in \mathbb{R}^{2K \cdot M \cdot N_a}$  로 변환한다. 이러한 입력 전처리를 통해  $\hat{\mathbf{c}}_{N_a}$  를 CA-MUD의 입력으로 고려함으로써  $\mathbf{y}^{(d)}$  에 포함된 채널과 코드북을 동시에 압축적으로 학습에 활용하게 되고, 이를 통해 채널  $\hat{\mathbf{h}}_s$  만을 입력으로 고려하는 [3] 대비 학습 효율이 증가하게 된다.

#### IV. 시뮬레이션 결과

본 시뮬레이션에서는  $K = 4$ ,  $J = 6$ , 그리고  $M = 4$  인 SCMA 코드북을 사용하는 GF-SCMA 시스템을 고려한다. 이 때 하나의 경합 영역에 활성 사용자  $N_a$  가 2 또는 3 인 상황을 가정한다. 또한 최대  $\lambda = 2$  개의 코드북 충돌까지 구분하기 위한 CA-MUD 구조로써 [3]과 같이 3 개의 계층으로 구성된 다중 사용자 공유 계층과 사용자 특정 계층을 갖는 구조를 고려한다. 또한 배치 크기 200, 훈련 epoch 4,000 번, 그리고 0.001 의 learning rate 를 고려한다. 이 외 네트워크 구조와 학습 파라미터 그리고 손실함수는 [3]과 동일하다.

그림 2(a)와 2(b)는 입력 전처리를 수행하지 않고, 채널  $\hat{\mathbf{h}}_s$  를 입력으로 고려한 [3]의 CA-MUD와 입력 전처리를 통해  $\hat{\mathbf{c}}_{N_a}$  를 입력으로 갖는 CA-MUD의 평균 비트 오류율 (bit error rate: BER) 성능을 비교한다. 이 때, 하나의 CA-MUD를 통해  $\lambda = 2$  개의 충돌을 포함한 모든 코드북 활성 조합에 대한 평균 BER을 계산한다. 그림 2에서 볼 수 있듯이 입력 전처리된  $\hat{\mathbf{c}}_{N_a}$  를 CA-MUD 입력으로 고려할 때  $N_a = 2$  와  $N_a = 3$  에서 각각 5dB와 7dB 이상의 평균 BER 증가를 확인하였다. 또한,  $\lambda = 2$  개 코드북 충돌이 있을 때 더욱 큰 성능 증가를 확인할 수 있다. 이는 코드북 충돌 시 채널 정보만 포함된  $\hat{\mathbf{h}}_s$  를 통해서 정확한 코드북 구조를 학습하기 어려운 반면, 입력 전처리된  $\hat{\mathbf{c}}_{N_a}$  에는 채널과 활성 코드북 구조에 대한 정보도 직접적으로 포함되어 있어 채널 변조 코드북 검출을 위한 더욱 효과적인 학습이 가능하기 때문이다.

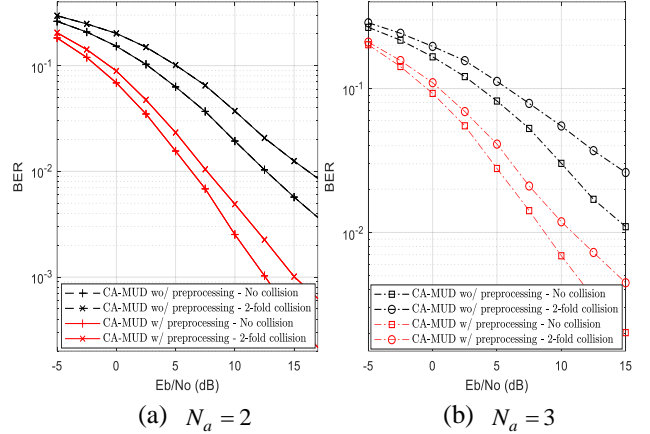


그림 2. 입력 전처리 절차 유무에 따른 CA-MUD의 평균 비트 오류율 성능

#### V. 결론

본 논문에서는 GF-SCMA 시스템의 2 개 코드북 충돌을 포함하는 여러 코드북 활성 조합을 검출하는 딥러닝 기반 CA-MUD 방식을 제안한다. 제안하는 CA-MUD의 효율적인 학습을 위해, 활성 코드북과 활성 채널 정보를 결합한 채널 변조 코드북 벡터를 생성하여 CA-MUD에 입력하여 학습하는 입력 전처리 기법을 제안하였다. 제안하는 입력 전처리 기법을 통해, 낮은 활성 사용자에서 기존의 CA-MUD 구조 대비 상당한 평균 BER 성능 이득을 확인하였다. 향후 연구에선 더 많은 활성 사용자에게 대해 효율적으로 동작하는 CA-MUD 구조와 전처리 방식, 그리고 채널 추정 오류에 대한 검출 성능 열화를 확인해야 한다.

#### ACKNOWLEDGMENT

이 논문은 2024년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원(No.2021-0-00467, 지능형 6G 무선 무선 액세스 시스템)과 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (No.2020R1A2C100998413)

#### 참고 문헌

- [1] K. Au et al., "Uplink contention based SCMA for 5G radio access," 2014 IEEE Globecom Workshops (GC Wkshps), 2014, pp. 900-905
- [2] Q. Wang and G. Ren, "A Partial Gaussian Tree Approximation (PGTA) Detector for Random Multiple Access Oriented SCMA Uplink With CB Collisions," in IEEE Transactions on Wireless Communications, vol. 20, no. 4, pp. 2295-2308, April 2021
- [3] M. Han, M. D. Gameda, A. T. Abebe and C. G. Kang, "Deep learning-based Collision-aware Multi-user Detection for Grant-free Sparse Code Multiple Access," 2023 28th Asia Pacific Conference on Communications (APCC), Sydney, Australia, 2023.