

다중 사용자 하향링크 빔포밍을 위한 장기적 채널정보 보조 특징 학습

김준범*, 이훈°, 박석환*

*전북대학교, °부경대학교

*{junbeom, seokhwan}@jbnu.ac.kr, °hlee@pknu.ac.kr

Long-Term CSI Assisted Feature Learning for Multi-User Downlink Beamforming

Junbeom Kim*, Hoon Lee°, Seok-Hwan Park*

*Jeonbuk National Univ., °Pukyong National Univ.

요 약

다중 사용자 하향링크 시스템에서 빔포밍 최적해를 찾기 위해서는 기지국에서 순시 채널 정보를 완벽하게 알아야 하며, 부최적해를 얻기 위해 weighted minimum mean squared error (WMMSE) 알고리즘이 제안된 바 있다. 그러나 순시 채널을 구성하는 소규모 페이딩은 매우 빠르게 변화하기 때문에, 기존 알고리즘을 실시간 통신시스템에 적용 및 구현이 어렵다. 본 논문에서는 장기적 채널정보 (예: 경로감쇄)를 deep neural network (DNN) 입력 정보로 활용하여, 빔포밍 전략을 구성하는 주요 특징 변수를 학습하고, 간단한 빔 회복과정을 통해서 빠르게 변화하는 소규모 페이딩에 견고한 deep learning (DL) 기법을 제안한다. 모의 실험을 통해서, 저복잡도를 갖는 제안기법의 우수성을 검증한다.

I. 서 론

다중 사용자 셀룰러 시스템에서 여러 사용자를 동일 시간 및 주파수 자원에서 지원하는 space division multiple access (SDMA) 시스템에서 기술이 활발히 연구되어왔다 [1]. 기존에 활발히 연구된 weighted minimum mean squared error (WMMSE) 알고리즘은 순시 채널을 기지국에서 완벽하게 알고 있다는 가정하에 최적의 빔포밍 전략을 도출할 수 있다. 그러나 실시간 통신에서는 무선 채널이 빠르게 변화하기 때문에 이에 견고한 빔포밍 최적화 기술이 필수적이다.

본 논문에서는 순시 채널에 견고하고, 고속으로 빔포밍 전략을 최적화 하기 위해 deep learning (DL) 기술을 제안 한다. [2]에서 불완전한 채널정보를 활용하여 DL 기술을 적용한 빔포밍 최적화 문제가 다루어졌지만, 본 논문에서는 순시 채널을 구성하는 대규모 페이딩 정보를 활용하는 DL 기술을 다룬다. 소규모 페이딩이 빠르게 변화하는 실시간 통신에서, DL 기반의 견고한 빔포밍 최적화 기법의 우수성을 확인한다.

II. 시스템 모델

본 논문에서는 N 개의 다중 안테나를 갖는 기지국과 단일 안테나를 사용하는 K 개의 사용자가 존재하는 하향링크 통신 시스템을 고려한다. 사용자 집합을 $\mathcal{K}=\{1,2,\dots,K\}$ 로 정의하고 $\mathbf{h}_k \in \mathbb{C}^N$ 을 기지국과 k 번째 사용자간의 순시 채널 벡터로 정의하면, k 번째 사용자의 전송율은 빔포밍 벡터 $\mathbf{v} \triangleq \{\mathbf{v}_k \in \mathbb{C}^N : \forall k\}$ 를 기반으로 다음과 같이 표현 할 수 있다.

$$\mathcal{R}_k(\mathbf{Q}_k, \mathbf{v}) = \log_2 \left(1 + \frac{\mathbf{v}_k^H \mathbf{Q}_k \mathbf{v}_k}{\sigma^2 + \sum_{l \neq k} \mathbf{v}_l^H \mathbf{Q}_k \mathbf{v}_l} \right). \quad (1)$$

식 (1)에서 $\mathbf{Q}_k \in \mathbb{C}^{N \times N} = \mathbf{h}_k \mathbf{h}_k^H$ 로 정의되고, 순시 채널 \mathbf{h}_k 는 $\mathbf{h}_k = \sqrt{\rho_k} \tilde{\mathbf{h}}_k$ 로 모델링할 수 있다. 여기서 $\tilde{\mathbf{h}}_k \sim \mathcal{CN}(\mathbf{0}, \mathbf{I})$ 와 ρ_k 는 각각 소규모와 대규모 페이딩을 의미하며, 각각 단기간 및 장기적 채널정보로 분류된다. 또한 σ^2 은 잡음신호의 전력을 나타낸다. 기지국에서 전체 사용자를 위한 최대 전력은 P 로 제한되므로, 송신전력 제한 조건을 $\sum_{k \in \mathcal{K}} \|\mathbf{v}_k\|^2 \leq P$ 로 기술 할 수 있다.

본 연구에서는 sum-rate 을 최대화하면서, 송신전력 제한 조건을 만족하는 빔포밍 \mathbf{v} 의 최적화를 다루고자 한다. 빔포밍 최적화 문제는 상기 수식 (1)과 송신전력 제한 조건과 함께 다음과 같이 표현 할 수 있다.

$$\begin{aligned} \max_{\mathbf{v}} \quad & \sum_{k \in \mathcal{K}} \mathcal{R}_k(\mathbf{Q}_k, \mathbf{v}) \\ \text{s.t.} \quad & \sum_{k \in \mathcal{K}} \|\mathbf{v}_k\|^2 \leq P. \end{aligned} \quad (2)$$

상기 최적화 문제는 목적함수가 non-convex 함수이며, 최적의 빔포밍 솔루션을 도출 하기 위해서는 먼저 순시 채널로 구성된 행렬 $\mathbf{Q}_k, \forall k$ 를 기지국에서 완벽히 알아야 한다. 그러나 실제 통신에서 소규모 페이딩은 빠르게 변화하며, 이에 견고한 최적의 빔포밍 벡터 \mathbf{v} 를 획득하기 쉽지 않다. 따라서, 대규모 페이딩을 DNN 입력정보로 활용하는 견고한 DL 기법을 제안한다.

III. 대규모 페이딩 보조 빔포밍 최적화

대규모 페이딩 (예: 경로감쇄 $\rho \triangleq \{\rho_k : \forall k\}$) 정보로부터 최적의 빔포밍 전략 함수를 효율적으로 찾기 위한 딥러닝 기법을 다룬다. DNN 의 입력벡터로는 대규모 페이딩 벡터 ρ 을 활용하고, DNN 은 빔포밍 벡터 회복을

위해 주요 변수인 $\mathbf{p} \triangleq \{p_k : \forall k\} \in \mathbb{R}^K$ 와 $\mathbf{q} \triangleq \{q_k : \forall k\} \in \mathbb{R}^K$ 를 출력하도록 설계 된다. 실제로, 최적의 빔포밍 벡터 구조는 주요 변수인 하향링크 송신전력 벡터 \mathbf{p} 와 가상의 상향링크 송신전력 벡터 \mathbf{q} 와 함께 다음과 같이 표현 할 수 있다.

$$\mathbf{v}_k \triangleq \sqrt{p_k} \mathbf{d}_k = \sqrt{p_k} \frac{(\sigma^2 \mathbf{I} + \sum_{l \in \mathcal{K}} q_l \mathbf{Q}_l)^{-1} \mathbf{h}_k}{\left\| (\sigma^2 \mathbf{I} + \sum_{l \in \mathcal{K}} q_l \mathbf{Q}_l)^{-1} \mathbf{h}_k \right\|}. \quad (3)$$

식 (3)에서 p_k 와 p_k 는 k 번째 사용자의 상향, 하향링크 전력을 의미한다. 또한 $\sum_{k \in \mathcal{K}} p_k = \sum_{k \in \mathcal{K}} q_k = P$ 제한조건을 만족해야 하며, \mathbf{d}_k 는 빔포밍 벡터 \mathbf{v}_k 의 방향을 결정한다.

제안기법의 DNN 입-출력 관계는 $\{\mathbf{p}, \mathbf{q}\} = \mathcal{F}(\mathbf{p}; \theta)$ 로 표현할 수 있다. 여기서 θ 는 DNN 의 학습 변수 집합으로 정의된다. 최적의 빔포밍 전략을 도출하는 함수를 $\mathcal{V}(\cdot)$ 로 정의하면, 빔포밍 벡터는 $\mathbf{v} = \mathcal{V}(\mathbf{p}, \mathbf{q}, \mathbf{h})$ 로 표현된다. 여기서 \mathbf{h} 는 $\{\mathbf{h}_k : \forall k\} \in \mathbb{C}^{N \times K}$ 로 정의 된다. 본 논문에서 DNN 학습문제는 다음과 같이 정립할 수 있다.

$$\max_{\theta} \cdot \mathbb{E}_{\mathbf{h}} \left[\mathbb{E}_{\mathbf{p}} \left[\sum_{k \in \mathcal{K}} \mathcal{R}_k(\mathbf{Q}_k, \mathcal{V}(\mathcal{F}(\mathbf{p}; \theta), \mathbf{h})) \right] \right]. \quad (4)$$

문제 (4)는 최적의 빔포밍 구조 (3)에 의해 비 제약 조건을 갖는 최적화 문제로 표현된다. 상기 문제 (4)의 최적해는 DNN 학습 파라미터 θ 를 반복적으로 업데이트 하는 mini-batch 기반의 stochastic gradient decent (SGD) 알고리즘으로 도출 할 수 있다 [3].

IV. 모의 실험 결과

이번 장에서는 대규모 페이딩 정보를 DNN 입력으로 활용하여 빔포밍 전략을 획득하는 DL 기법의 우수성을 검증한다. 기지국은 반지름 100m 원형 셀 안에 위치해 있고, 각 사용자들은 무작위로 분포된다. 이때, 기지국과 k 번째 사용자의 대규모 페이딩은 $\rho_k = 1/(1 + (d_k/d_0)^\alpha)$ 로 표현된다. 여기서 $d_k, d_0 = 30\text{m}$ 와 $\alpha = 3$ 는 기지국과 k 번째 사용자간의 거리, reference 거리와 경로손실 지수를 나타낸다. 잡음 전력을 $\sigma^2 = 1$ 로 두면, signal-to-noise ratio (SNR)은 $\frac{P}{\sigma^2}$ 로 정의할 수 있다. DNN 은

rectified linear unit (ReLU) 활성화 함수를 갖는 5 개의 은닉계층 구조를 갖으며, 각 계층의 출력차원은 80 이다. 마지막 계층에서 송신전력 제한조건을 만족하기 위해 soft-max 함수를 활용하며, $2K$ 차원을 갖는다. 비지도 학습 전략을 채택하고, DNN 파라미터 θ 를 학습하기 위해 Adam optimizer 을 사용한다. 이때 learning rate 은 0.001 그리고 mini-batch 크기는 2000 으로 설정 한다.

그림 1 은 $N = K = 4$ 에서 SNR 에 따른 평균 sum-rate 성능을 기존 빔포밍 최적화 기술들과 비교 하였다. 먼저, 소규모 페이딩을 고려하지 않은 long-term average CSI 기법 (즉, $\mathbb{E}[\mathbf{h}_k \mathbf{h}_k^H]$) 은 이상적인 WMMSE 알고리즘 대비 인접 사용자 간섭제어에 상당히 취약하다. 대규모 페이딩을 기반으로 빔포밍 전략 \mathbf{v} 를 직접 학습하는 DL 기법의 경우 빔포밍 벡터 획득 시 채널 방향을 고려할 수 없기 때문에 간섭 신호를 완벽히 제거 하지 못한다. 특히, 간섭 제어의 영향이 지배적인 높은 SNR 영역에서 성능 손실이 두드러짐을 확인하였다. 그에 반해 제안하는




그림 1. SNR 대비 평균 sum-rate 성능비교

최신 DL 기법은 DNN 최적화 결과물 \mathbf{p} 와 \mathbf{q} 를 대규모 페이딩 기반으로 획득하고, 소규모 페이딩을 활용하여 빔포밍 벡터를 회복하기 때문에 인접 사용자 간섭을 효율적으로 제어할 수 있다. 따라서, 본 제안기법은 소규모 페이딩이 순시적으로 변화하는 실제 통신에서 간단한 빔포밍 회복 과정 만으로 매우 작은 성능 손실을 유지하며 최적의 빔포밍 벡터 \mathbf{v} 를 도출 할 수 있다.

V. 결론

본 논문에서는 다중 사용자 시스템에서 장기간 채널정보만을 DNN 입력으로 받아 핵심 특징을 추출하고, 순시 채널 변화에 따라서는 간단한 빔포밍 회복 과정만을 수행하는 효율적인 빔포밍 기술을 제안하였다. DL 기술 기반 대규모 페이딩 보조 기법은 기지국에서 완벽한 채널정보 획득을 가정하는 이상적인 빔포밍 최적화 기술 대비 낮은 계산 복잡도를 달성하고, 작은 성능 손실을 유지 한다는 것을 확인하였다.

ACKNOWLEDGMENT

이 성과는 정부 (과학기술정보통신부, 교육부)의 재원으로

한국연구재단의 지원을 받아 수행된 연구임 (No. 2021R1C1C1006557, 2019R1F1A1060648, 2019R1A6A1A09031717).

참 고 문 헌

- [1] Q. H. Spencer, C. B. Peel, A. L. Swindlehurst, and M. Haardt, "An introduction to the multi-user MIMO downlink," *IEEE Commun. Mag.*, vol. 42, no. 10, pp. 60–67, Oct. 2004.
- [2] J. Kim, H. Lee, and S.-H. Park, "Learning robust beamforming for MISO downlink systems" to appear in *IEEE Commun. Lett.*
- [3] D. Kingma and J. Ba, "Adam: A method for stochastic optimization," *Proc. Int. Conf. Learn. Represent (ICLR)*, 2015, pp. 1–41.