

Massive MIMO 시스템을 위한 딥러닝 기반 비직교 파일럿 신호

임병주, 윤원준, 김중헌, 고영채
고려대학교

{limbj93, ywjoon95, joongheon, koyc}@korea.ac.kr

Deep Learning Based Non-Orthogonal Pilot Design for Massive MIMO

Byungju Lim, Won Joon Yun, Joongheon Kim, Young-Chai Ko
Korea Univ.

요약

본 논문은 다중 cell massive multiple-input multiple output (MIMO) 시스템에서 발생하는 pilot contamination에 의한 채널 예측 오류를 감소시키기 위하여 딥러닝 기반 비직교 pilot 신호를 제안한다. 최적의 기법으로 알려진 linear minimum mean square error (LMMSE) 기반 채널 예측의 성능을 향상시키기 위하여 MSE를 유도하고, MSE를 최소화하기 위한 딥러닝 기반 pilot 신호를 설계함으로써 기존 대비 성능을 향상시킬 수 있음을 보여준다.

I. 서론

차세대 이동통신 시스템에서 데이터 속도 및 신뢰성을 증가시킬 수 있는 massive MIMO 기술이 주목받고 있다 [1]. 하지만 많은 수의 안테나 사용으로 인하여 추정해야 할 채널 정보량이 증가하게 되고, 채널 추정 오류가 발생한다면 기존의 빔포밍, 신호 검출 등의 성능에 영향을 미치게 된다. 이를 해결하기 위해 pilot 기반 채널 추정 기법을 사용하고 있는데, 다수의 사용자가 존재하는 다중 cell 환경에서는 제한된 coherence time으로 인해 모든 cell이 orthogonal pilot을 할당할 수 없다. 그로 인해 같은 pilot 신호를 사용하는 인접 cell 사용자들로 인하여 pilot contamination 문제가 발생하고, 채널 추정을 어렵게 만든다. 이를 해결하기 위해, 본 논문에서는 딥러닝 기반 pilot 설계 기법을 제안한다. 설계한 pilot은 기존에 사용되고 있는 LMMSE 채널 추정 기법을 기반으로 mean square error (MSE)를 최소화한다. 시뮬레이션 결과, 사용자들에게 orthogonal 혹은 random pilot을 할당하는 것보다 딥러닝 기반 pilot 신호를 사용함으로써 채널 예측 오류를 감소시킬 수 있는 것을 확인할 수 있다.

II. 시스템 모델

N 개의 안테나를 가진 기지국으로 이루어진 L 개의 다중 cell 내에 K 명의 사용자가 존재한다고 가정한다. Time division duplexing (TDD)를 가정하여 각 사용자들은 uplink pilot 신호를 전송함으로써 uplink 및 downlink의 채널 정보를 예측하는데, coherence time으로 인하여 제한된 길이의 pilot 신호를 전송하게 되므로 인접 cell에서 같은 pilot 신호를 사용하는 pilot contamination 문제가 발생한다. 따라서 i 번째 cell에 존재하는 기지국이 수신한 신호는 다음과 같이 표현할 수 있다.

$$\begin{aligned} \mathbf{Y}_i &= \sqrt{\tau_p P_{j,k}} \sum_{j=1}^L \sum_{k=1}^K \mathbf{h}_{i,j,k} \mathbf{x}_{j,k}^H + \mathbf{n}_i \\ &= \sqrt{\tau_p} \mathbf{H}_{i,i} \left(\mathbf{P}_i^{\frac{1}{2}} \mathbf{X}_i^H + \boldsymbol{\eta}_{UE,i}^H \right) + \sqrt{\tau_p} \sum_{\substack{j=1 \\ j \neq i}}^L \mathbf{H}_{i,j} \mathbf{P}_j^{\frac{1}{2}} \mathbf{X}_j^H + \mathbf{n}_i, \end{aligned} \quad (1)$$

식 (1)에서 $\mathbf{h}_{i,j,k}$ 는 j 번째 cell에 존재하는 k 번째 사용자와 i 번째 cell의 기지국간의 채널 벡터, $\mathbf{X}_{j,k}$ 와 $P_{j,k}$ 는 j 번째 cell에 존재하는 k 번째 사용자가 전송하는 pilot 신호와 파워, τ_p 는 pilot 신호의 길이, 그리고 \mathbf{n}_i 는 σ^2 의 파워를 가지는 AWGN이다. 여기서 채널은 $\mathbf{h}_{i,j,k} = \sqrt{\beta_{i,j,k}} \mathbf{g}_{i,j,k}$ 로 모델링 가능하고 $\beta_{i,j,k}$ 와 $\mathbf{g}_{i,j,k}$ 는 각각 large-scale fading과 small-scale fading을 의미한다. i 번째 기지국이 식 (1)과 같은 신호를 수신하게 되면 LMMSE 예측 기법을 통해 채널 추정이 가능하다. LMMSE filter인 \mathbf{A}_i 를 통과하면 예측된 채널은 다음과 같이 쓸 수 있다 [2].

$$\begin{aligned} \hat{\mathbf{H}}_{i,i} &= \mathbf{Y}_i \mathbf{A}_i \\ &= \frac{1}{\sqrt{\tau_p}} \mathbf{Y}_i \left(\sum_{j=1}^L \mathbf{X}_j \mathbf{D}_{i,j} \mathbf{P}_j \mathbf{X}_j^H + \sigma^2 / \tau_p \mathbf{I} \right)^{-1} \mathbf{X}_i \mathbf{P}_i^{\frac{1}{2}} \mathbf{D}_{i,i}, \end{aligned} \quad (2)$$

여기서 $\mathbf{D}_{i,j} = \text{diag}([\beta_{i,j,1}, \dots, \beta_{i,j,K}])$ 을 나타낸다. 결과적으로 LMMSE 채널 예측 기법을 사용하게 되면 채널 추정 오류는 다음과 같이 정리할 수 있다.

$$\text{MSE}_i = N \text{Tr} \left((\mathbf{D}_{i,i}^{-1} + \bar{\mathbf{X}}_i^H \bar{\mathbf{B}}_i^{-1} \bar{\mathbf{X}}_i)^{-1} \right) \quad (3)$$

여기서 $\bar{\mathbf{X}}_i = \mathbf{X}_i \mathbf{P}_i^{1/2}$ 그리고 $\bar{\mathbf{B}}_i = \sum_{j=1, j \neq i}^L \bar{\mathbf{X}}_j \mathbf{D}_{i,j} \bar{\mathbf{X}}_j^H + \frac{\sigma^2}{\tau_p} \mathbf{I}$ 를 의미한다.

III. 딥러닝 기반 Pilot 신호 설계

식 (3)에서 구한 MSE를 최소화하기 위하여 최적의 $\bar{\mathbf{X}}_i$ 를 설계해야하지만 식 (3)은 non-convex 함수이므로 최적의 pilot 신호를 구하는 것이 어렵다. 따라서 본 논문에서는 딥러닝 기법을 이용해 MSE를 최소화하는 pilot 신호를 설계하고자 한다.






그림 2. 딥러닝 기반 Pilot 설계 모델

그림 1 과 같이 각 cell 에서 pilot 신호를 생성할 수 있는 deep neural network (DNN) 모델을 가지고 있고, 각 cell 에서 생성할 pilot 신호를 이용해 식 (3)의 MSE 를 계산한다. 결과적으로 MSE 를 최소화하기 위해 stochastic Gradient Descent (SGD) 방법을 이용하여 DNN 모델을 학습시켜 최적의 pilot 신호를 생성하도록 한다. 이때, pilot 설계의 입력 신호로 각 cell 에서 이미 알고 있는 large-scale fading 정보를 사용하여 사용자들의 path loss 에 따라서 최적의 pilot 신호를 생성할 수 있게 된다. 최적의 pilot 신호를 설계하기 위하여 neural network 는 $4\tau_p K$ 개의 hidden node 를 가지는 2 개의 layer 로 구성되어 있으며, 각 layer 마다 활성화함수로 ReLu 를 적용하였다. 또한 50%의 확률을 가지는 dropout layer 를 추가하여 학습시 overfitting 문제를 방지한다.

IV. 시뮬레이션 결과

시뮬레이션을 위해 500m 의 inter-site distance (ISD)를 가지는 7 개의 hexagonal cell 을 배치하며 각 cell 내에는 100 개의 안테나를 장착한 기지국과 10 명의 사용자들을 uniform 하게 배치하였다. 각 사용자들이 전송할 수 있는 최대 파워는 23dBm 이고, large-scale fading 은 $\beta_{i,j,k} = 128.1 + 37.6 \log_{10}(d_{i,j,k}) + \xi_{i,j,k}$ 로 모델링하며 여기서 $d_{i,j,k}$ 와 $\xi_{i,j,k}$ 는 각각 사용자와 기지국의 거리 그리고 8dB 의 표준편차를 가진 log-normal shadowing fading 을 의미한다. 오프라인 학습을 위한 데이터로 10,000 개의 샘플을 사용하며 1,000 개의 샘플을 이용해 온라인 테스트로 성능 평가를 진행한다.

그림 2 는 $\tau_p = 8, 10$ 일 때 각 cell 에서 식 (3)을 이용해 계산한 MSE 의 합에 대한 CDF 그래프이다. 성능 평가 그래프에서 각 cell 마다 orthogonal pilot 을 재사용하는 기법을 “Orthogonal”, 랜덤하게 pilot 을 생성하는 기법을 “Random”, 그리고 fractional programming 을 기법을 사용하여 최적의 pilot 을 설계한 기법을 “FP” [3]라고 명시한다. 그림에서 확인할 수 있듯이 $\tau_p = 10$ 이면 “Orthogonal”이 “Random”보다 성능이 좋은 것을 확인할 수 있는데, $K = \tau_p$ 조건으로 인해 cell 내에 존재하는 사용자들에게 orthogonal pilot 을 할당할 수 있으므로 성능이 향상되게 된다. 하지만 인접 cell 에서 같은 pilot 신호를 사용함으로 인해 간섭이 발생하기 때문에 “FP”와 제안된 기법은 이러한 간섭을 고려하여 pilot 을 설계하기 때문에 “Orthogonal”보다 성능이 좋은 것을 확인할 수 있다. 또한 제안된 기법이 “FP”보다 성능이 우월한 것을 확인할 수 있는데, 식 (3)은 non-convex 함수이므로 기존 convex 최적화 기법을 이용해 pilot 을 설계하면 global optimal solution 을 찾는 것이 어렵기 때문에 최적의 성능을 얻지 못한다. 반면, 제안한

그림 1. Pilot 설계 기법에 따른 MSE 성능 비교 ($\tau_p = 10$)그림 3. Pilot 설계 기법에 따른 MSE 성능 비교 ($\tau_p = 8$)

기법은 non-linear 특성을 가지는 neural network 로 설계하였기 때문에, 기존 대비 성능 이득이 발생하는 것을 확인할 수 있다. $\tau_p = 8$ 일 경우, $K > \tau_p$ 이기 때문에 각 cell 내에 orthogonal pilot 을 할당할 수 없으므로 “Random” 기법 대비 성능이 저하되는 것을 확인할 수 있다.

V. 결론

본 논문에서는 다중 cell massive MIMO 시스템에서 deep learning 기반 pilot 신호 설계 기법을 제안하였다. 간단한 neural network 구조로 기존 convex 최적화 방법대비 성능이 향상되는 것을 확인할 수 있으며, dropout 을 통한 overfitting 을 방지하여 온라인 pilot 설계에서도 다른 기법 대비 성능이 향상되는 것을 확인할 수 있다.

ACKNOWLEDGMENT

This work was supported by the National Research Foundation of Korea (NRF) grant funded by the Korea government(MSIT)(NRF-2020R1A4A1019628)

참고 문헌

- [1] L. Lu, G. Y. Li, A. L. Swindlehurst, A. Ashikhmin and R. Zhang, "An Overview of Massive MIMO: Benefits and Challenges," *IEEE J. Sel. Topics Signal Process.*, vol. 8, no. 5, pp. 742-758, Oct. 2014
- [2] S. M. Kay, *Fundamentals of statistical signal processing.*, Prentice Hall PTR, 1993
- [3] K. Shen, H. V. Cheng, X. Chen, Y. C. Eldar, and W. Yu, "Enhanced channel estimation in massive MIMO via coordinated pilot design", *IEEE*

Trans. Commun., vol. 68, no. 11, pp. 6872–6885, Nov
2020