

거대 다중 안테나 통신 시스템에서 기계 학습 기반 채널 예측의 시간 오버헤드 감소 기법

고범수, 김환진, 최준일
한국과학기술원 (KAIST)

{kobs0318, jin0903, junil}@kaist.ac.kr

요약

본 논문은 거대 다중 안테나 통신 시스템에서 기계 학습 기반의 채널 예측을 할 시에 발생하는 시간 오버헤드를 감소시키기 위한 기법을 제안한다. 특히 학습 데이터의 형태를 변환하여 시간 오버헤드를 감소시키면서도 채널 예측 성능을 유지하는 기법을 제안한다.

I. 서론

거대 다중 안테나 (massive multiple-input multiple-output, massive MIMO) 시스템에서는 정확한 채널 상태 정보(channel state information, CSI)를 얻는 것이 필수적이다 [1]. 하지만 기지국과 단말 간 피드백 시 발생하는 시간 지연(time delay)이나 단말의 이동 속도로 인하여 기존 채널 추정 기법을 통해 얻는 채널은 시간적으로 뒤쳐진(outdated) 채널이 되며 이는 통신 시스템의 성능을 저하시킨다. 채널 예측 기법은 추가적인 파일럿(pilot) 자원을 사용하지 않고 미래의 CSI를 예측하는 방식으로 이 문제를 해결할 수 있다.

최근에는 다양한 신경망(neural network, NN)을 이용한 기계 학습 기반 채널 예측 기법(machine learning-based channel prediction, ML-based CP)이 연구되고 있지만 학습 데이터(training data)를 수집할 때 발생하는 시간 오버헤드(time overhead)를 고려하지 않고 있다. 본 논문은 ML-based CP의 시간 오버헤드를 감소시키기 위한 기법을 제시한다.

II. 본론

II-1. 시스템 모델

본 논문은 광대역 massive MIMO 시스템과 함께 직교 주파수 분할 다중 방식(orthogonal frequency-division multiplexing, OFDM)을 고려하여 총 L 개의 부 반송파(subcarrier) 협대역(narrowband) 채널을 가정한다. 기지국 안테나를 M 개로 가정할 때 ℓ 번째 subcarrier와 n 번째 상관 시간 블록(coherence time block)에서의 채널은 $\mathbf{h}_n^\ell \in \mathbb{C}^{M \times 1}$ 로 표현된다. 실제 통신 상황에서는 실제 채널 \mathbf{h}_n^ℓ 를 알 수 없기 때문에 추정된 채널을 NN 학습 시에 사용한다. 추정된 채널 \mathbf{g}_n^ℓ 은 다음과 같이 표현된다.

$$\mathbf{g}_n^\ell = \mathbf{h}_n^\ell + \frac{\mathbf{z}_n^\ell}{\sqrt{\rho}}$$

여기서 ρ 는 채널 추정 시 사용된 파일럿 신호의 신호 대 잡음 비(signal-to-noise ratio, SNR), 그리고 $\mathbf{z}_n^\ell \sim \mathcal{CN}(\mathbf{0}, \mathbf{I})$ 는 복소 가우시안 잡음(complex Gaussian noise)이다. 본 논문에서 고려하고 있는 통신 상황에서는 실제 채널 \mathbf{h}_n^ℓ 에 대한 추정된 채널 \mathbf{g}_n^ℓ 이 outdated 되고 이를 해결하기 위해 ML-based CP를 이용하여 실제 채널 \mathbf{h}_{n+1}^ℓ 을 예측한다. 이때 예측된 채널은 $\hat{\mathbf{h}}_{n+1}^\ell$ 로 표현한다.

II-2. 개별 학습(separate learning, SL) 기법

SL 기법은 다중 퍼셉트론(multi-layer perceptron, MLP)을 적용한 [2]의 ML-based CP를 각 subcarrier에 대해서 개별적으로 반복하는 기법이다. 본 논문에서 적

용한 MLP는 input layer, N 개의 hidden layer, 그리고 output layer로 구성 되어있으며, ℓ 번째 subcarrier 채널 예측을 위한 학습 데이터 셋은 다음과 같이 표현된다.

$$\mathbf{D}_{\text{tr}}^\ell(N_{\text{tr}}) = (\{\mathbf{g}_{n-n_o+1}^\ell, \dots, \mathbf{g}_n^\ell, \mathbf{g}_{n+1}^\ell\}, \text{where } n = n_o, \dots, N_{\text{tr}} + n_o - 1.$$

학습 데이터의 $\{\mathbf{g}_{n-n_o+1}^\ell, \dots, \mathbf{g}_n^\ell\}$ 부분은 MLP의 input layer으로 들어가는 특징(feature) 부분이며, \mathbf{g}_{n+1}^ℓ 부분은 특징에 대한 레이블(label)에 해당한다.

II-3. 공동 학습(joint learning, JL) 기법

SL 기법은 massive MIMO-OFDM 시스템에 간단히 적용될 수 있지만, 각 subcarrier에서 요구되는 학습 데이터를 수집하기 위한 time overhead를 고려하고 있지 않다. JL 기법에서는 time overhead를 감소시키기 위해 모든 subcarrier 채널에서 수집된 학습 데이터를 하나의 MLP에 넣어 학습을 진행하고, 이때 학습된 NN을 이용하여 모든 subcarrier 채널을 예측한다. JL 기법에서 사용되는 학습 데이터셋은 다음과 같이 표현된다.

$$\mathbf{D}_{\text{tr}}^{\text{JL}} = \bigcup_{\ell=1}^L \mathbf{D}_{\text{tr}}^\ell(N_{\text{tr}}).$$

공정한 성능 비교를 위해, NN 학습에 필요한 총 학습 데이터의 수를 SL 기법과 동일하게 $N_{\text{tr}} = N_{\text{tr}}'L$ 로 놓게 되면, JL 기법에서 요구되는 time overhead를 L 분의 1로 줄일 수 있다. 하지만 섹션 II-5에서 알 수 있듯이, subcarrier 채널 간 상호 상관(cross-correlation)이 높다는 것을 통해 모든 subcarrier 채널에서 수집된 학습 데이터들 간의 높은 correlation을 예상할 수 있다. 이때 유사한 학습 데이터로 NN를 학습하게 되면 ML-based CP의 성능에 영향을 미치게 된다 [3]. 다음 섹션에서는 JL 기법과 동일한 수준으로 time overhead를 감소시키는 동시에 학습 데이터 간의 correlation을 낮추는 기법을 연구하였다.

II-4. 도메인 변환(domain transformation, DT)

Massive MIMO-OFDM 시스템에서는 채널을 \mathbf{h}_n^ℓ 와 같이 subcarrier 별로 표현하는 것이 자연스럽다. 하지만 앞서 언급된 바와 같이 subcarrier 채널들 간의 cross-correlation이 높게 나타나기 때문에 antenna-domain 채널로 변환하여 표현하고자 한다. DT를 설명하기 위해 우선 \mathbf{h}_n^ℓ , \mathbf{g}_n^ℓ , 그리고 $\hat{\mathbf{h}}_{n+1}^\ell$ 의 m 번째 원소를 $h_n^{\ell,m}$, $g_n^{\ell,m}$, 그리고 $\hat{h}_{n+1}^{\ell,m}$ 와 같이 표기한다. 이때 m 번째 antenna와 n 번째 coherence time block에서의 실제 채널, 추정 채널, 그리고 예측 채널을 다음과 같이 정의할 수 있다.

$$\begin{aligned} \mathbf{h}_n^m &= [h_n^{1,m}, \dots, h_n^{L,m}]^T, \\ \mathbf{g}_n^m &= [g_n^{1,m}, \dots, g_n^{L,m}]^T, \\ \hat{\mathbf{h}}_{n+1}^m &= [\hat{h}_{n+1}^{1,m}, \dots, \hat{h}_{n+1}^{L,m}]^T. \end{aligned}$$

이러한 형태의 채널을 antenna-domain 채널로 명명하도록 한다.

II-5. Correlation properties

다음은 DT 를 시행하기 전의 subcarrier 채널 간의 cross-correlation 과 DT 이후의 antenna-domain 채널의 cross-correlation 값을 비교한다. 아래 Fig. 1 에서 알 수 있듯이, DT 를 하게 되면 채널 간의 cross-correlation 을 줄일 수 있다.




Fig. 1. Subcarrier 채널과 antenna-domain 채널의 cross-correlation.

II-6. DT 를 적용한 JL(JL with DT, JLDT) 기법

JLDT 기법은 앞서 언급한 DT 를 통해 바뀐 antenna-domain 채널을 이용하여, JL 기법과 유사하게 모든 antenna-domain channel 에서 학습 데이터를 수집하고, 학습된 NN 을 이용하여 모든 antenna-domain 채널을 예측하는 기법이다. JLDT 기법에 사용된 학습 데이터는 다음과 같이 표현된다.

$$\mathbf{D}_{\text{tr}}^{\text{JLDT}} = \bigcup_{m=1}^M (\{\mathbf{g}_{n-n_0+1}^m, \dots, \mathbf{g}_n^m\}, \mathbf{g}_{n+1}^m),$$

where $n = n_0, \dots, N_{\text{tr}}' + n_0 - 1$.

이때, JL 기법과 마찬가지로 각 antenna-domain 채널에서는 N_{tr}' 개의 학습 데이터가 수집되기 때문에 time overhead 를 L 분의 1로 감소시킬 수 있다. 하지만 JL 기법과 달리 채널의 형태가 subcarrier-domain 이 아닌, antenna-domain 이기 때문에 학습 데이터 간의 cross-correlation 을 크게 줄일 수 있다.

II-7. 시뮬레이션 결과

시뮬레이션 채널은 quasi deterministic radio channel generator (QuaDRiGa)를 사용하였고, urban micro (UMi) 시나리오를 적용하였다. 기지국의 안테나 수는 $M = 64$ 로 설정하였고, subcarrier 의 수는 $L = 50$ 로 설정하였다. Coherence time block 의 주기는 20 msec 이며, 반송파 주파수(carrier frequency)는 2.53 GHz 이다.

SL, JL, 그리고 JLDT 기법에 사용된 MLP 의 hidden layer 수는 2 개이며, node 의 수는 128 로 설정하였다. 또한, batch size 는 128, epoch 수는 100, 그리고 n_0 는 3 으로 설정하였다.

다음 Fig. 2 는 SNR 에 따른 SL, JL, 그리고 JLDT 기법의 정규화 평균 제곱 오차(normalized mean square error, NMSE) 성능을 보여준다. NMSE 는 다음과 같이 정의된다.

$$\mathbb{E} \left[\frac{\|\mathbf{h}_{n+1}^{\ell} - \hat{\mathbf{h}}_{n+1}^{\ell}\|^2}{\|\mathbf{h}_{n+1}^{\ell}\|^2} \right].$$

JL 기법은 SL 기법과 비교하여 각 subcarrier 에서 수집되는 학습 데이터의 수를 감소시켜 time overhead 를 줄일 수 있었지만, 채널 예측 성능에 열화가 발생하는 것을 확인할 수 있다. 이는 섹션 II-4 에서 설명한 것과 같이 JL 기법에서 수집되는 학습 데이터 간의 correlation 과 관련이 있다. 반면에 DT 을 거친 JLDT 기법은 time overhead 를 감소시키는 동시에 성능의 이득이 있음을 확인하였다.




Fig. 2. SNR 에 따른 SL, JL, 그리고 JLDT 기법의 NMSE 성능.

III. 결론

본 논문은 massive MIMO-OFDM 시스템에서 ML-based CP 에서 요구되는 time overhead 를 줄이기 위해 JLDT 기법을 제안하였다. 이 방식은 DT 를 통해 모든 antenna-domain 에서 수집되는 학습 데이터 간의 correlation 을 낮추었고, 이를 통해 SL 기법에 비해 time overhead 를 L 분의 1로 감소시키는 동시에 성능 이득을 얻을 수 있었다.

ACKNOWLEDGMENT

이 논문은 과학기술정보통신부 및 정보통신기획평가원의 대학 ICT 연구센터지원사업의 연구결과 (IITP-2020-0-01787)와 2020 년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임 (No. 2020-0-01882, 센서나 영상카메라 없이 미세한 무선신호 (Wi-Fi 등) 센싱 기반의 건물내 위험상황 문제해결기술개발)

참 고 문 헌

- [1] Marzetta, T. L. "Noncooperative cellular wireless with unlimited numbers of base station antennas," IEEE Transactions on Wireless Communications, 9, pp. 3590-3600, Nov. 2010.
- [2] Kim, H. et al. "Massive MIMO channel prediction: Kalman filtering Vs. machine learning," IEEE Transactions on Communications, 69, pp. 518-528, Jan. 2021.
- [3] Birodkar, V. et al. "Semantic redundancies in image-classification datasets: The 10% you don't need," 2019, (https://arxiv.org/abs/1901.11409).