

MISO 밀리미터파 시스템에서 디노이즈 기계학습 모델 기반 채널 추정 기법

강민정, 이정훈

한국외국어대학교 전자공학과 및 응용통신연구센터

{love_minmin926, tantheta}@hufs.ac.kr

Machine learning-based denoise network
for channel estimation in mmWave MISO systems

Min Jeong Kang, Jung Hoon Lee

Department of Electronics Engineering and Applied Communications Research Center,
Hankuk University of Foreign Studies

요 약

밀리미터파 기반 시스템에서는 채널 정보에 따라 시스템의 성능이 좌우되므로 정확한 채널 정보를 얻는 것은 매우 중요한 문제이다. 그러나 일반적으로 채널 추정에 사용되는 least squares (LS) 방식의 경우, 채널 정보를 피드백 받는 과정에서 발생하는 다양한 노이즈를 고려하지 않으므로 LS 추정 기법을 사용하여 노이즈가 없는 채널 정보를 얻기 쉽지 않다. 본 논문에서는 multiple-input single-output (MISO) 밀리미터파 시스템에서 디노이즈 기계학습 모델을 활용하여 채널에 존재하는 다양한 노이즈를 제거함으로써 채널 추정 정확도를 높이는 채널 추정 기법을 살펴본다.

I. 서 론

밀리미터파 기반 시스템은 높은 데이터 전송률과 높은 스펙트럼 효율성을 가져 차세대 무선통신시스템에서 핵심적인 기술 중 하나로 여겨진다. 특히, 밀리미터파 기반 시스템의 경우 채널 상태에 대한 성능 의존도가 높으므로 최적의 성능을 얻기 위해서는 정확한 채널 상태를 찾는 것이 중요하다. 이에 따라, 일반적으로 채널 추정 과정에 널리 사용되는 least squares (LS) 추정과 밀리미터파 기반 시스템의 채널 특성을 이용하는 추정 기법인 compressive sensing (CS) 추정을 활용하는 연구가 활발히 이루어지고 있다. 또한 다양한 기계학습 모델을 활용하여 채널의 특징을 추출해서 낮은 복잡도로 채널을 추정하는 연구도 이루어지고 있다. [1-3]

본 논문은 multiple-input single-output (MISO) 밀리미터파 시스템에서 LS 추정을 사용하여 구한 채널 내에 존재하는 다양한 노이즈를 디노이즈 기계학습 모델을 활용하여 최소화하는 채널 추정 기법을 제안한다. 제안하는 기계학습 모델의 성능은 1) LS 추정 기법만을 사용하여 구한 채널과 2) LS 추정 기법만을 사용하여 얻은 채널로부터 제안하는 기계학습 모델을 이용하여 구한 노이즈를 뺀 채널로부터 얻는 normalized mean square error (NMSE)를 비교하여 검증한다.

II. 본론

본론에서는 본 논문에서 고려하는 시스템 모델에 대해 자세히 설명하고 제안하는 채널 추정 기법의 디노이즈 과정에서 사용하는 기계학습 모델의 구조 및 성능 검증에 대한 내용을 다룬다.

① 시스템 모델

본 논문은 time division duplexing (TDD) 밀리미터파 MISO 시스템을 고려하며, 송신단과 수신단은 각각 총 N_t 개와 하나의 안테나를 갖는다고 가정한다. 총 K 명의 수신단이 존재하며 송신단이 K 번째 수신단으로부터 수신 받은 신호 \mathbf{y}_k 는 다음과 같다.

$$\mathbf{y}_k = \mathbf{h}_k \mathbf{p}_k + \mathbf{n}_k. \quad (1)$$

$\mathbf{h}_k \in \mathbb{C}^{M \times 1}$ 는 송신단과 K 번째 수신단 사이의 채널을 의미한다. 이때, \mathbf{p}_k 는 K 번째 수신단의 파일럿 신호이고 $\mathbf{p}_i \mathbf{p}_j^H = \mathbf{0}, i \neq j$ 와 $|\mathbf{p}_k|^2 = 1$ 을 만족한다. 또한, $\mathbf{n}_k \sim \mathcal{CN}(\mathbf{0}, \sigma^2)$ 는 K 번째 수신단에서 송신단으로 신호를 보낼 때 더해지는 평균이 0 이고 분산이 σ^2 인 additive white complex Gaussian noise 이다. 여기서 파일럿 신호가 직교성을 가지므로 least squares (LS) 추정을 활용하여 송신단이 수신 받은 신호 \mathbf{y}_k 에서 구한 채널 $\hat{\mathbf{h}}_k$ 는 다음과 같다.

$$\hat{\mathbf{h}}_k = \mathbf{y}_k \mathbf{p}_k^{-1} = \mathbf{h}_k + \tilde{\mathbf{n}}_k, \quad (2)$$

이때 $\tilde{\mathbf{n}}_k \triangleq \mathbf{n}_k \mathbf{p}_k^{-1}$ 는 채널 추정시 발생하는 추정 오차, 즉 effective noise 를 의미하며, 수신 받은 신호 \mathbf{y}_k 에서 LS 추정만을 사용하여 채널을 추정할 경우 항상 포함된다.

② 제안하는 기계학습 모델

그림 1 은 본 논문에서 제안하는 채널 추정 기법의 디노이즈 과정에서 사용하는 기계학습 모델의 구조이다. 이때 사용하는 기계학습 모델은 denoising convolution neural network (DnCNN)과 유사한 구조이며, 송신단이 수신 받은 신호 \mathbf{y}_k 에서 LS 추정을 사용하여 구한 채널 $\hat{\mathbf{h}}_k$ 를 입력 값으로 받아 LS 추정을 사용하여 구한 채널 $\hat{\mathbf{h}}_k$ 에 있는 effective noise $\tilde{\mathbf{n}}_k$ 의 특징을 추출하여 최선의 effective noise $\hat{\mathbf{n}}_k$ 를 추정하는 기계학습 모델이다. 이에 따라, 기계학습 모델의 출력 값은 effective noise $\hat{\mathbf{n}}_k$ 가 되고 제안하는 채널 추정 기법을 사용하여 얻은 채널 $\hat{\mathbf{h}}_k$ 은 다음과 같이 표현된다.

$$\hat{\mathbf{h}}_k = \hat{\mathbf{h}}_k - \hat{\mathbf{n}}_k. \quad (3)$$

이때 DnCNN 구조의 기계학습 모델은 입력층과 출력층을 포함한 총 3 개의 층으로 구성되어 있으며, 입력층과 출력층 사이에는 15 개의 반복적인 convolution 층이 존재한다. 먼저 입력층에서는 3×3 크기의 64 개의 필터를 이용하여 64 개의 특징 맵을 만드는데, 여기서 사용하는 활성화 함수는 Leaky rectified linear unit (LeakyReLU)이며 다음과 같이 표현된다.

$$f(x) = \max(ax, x). \quad (4)$$

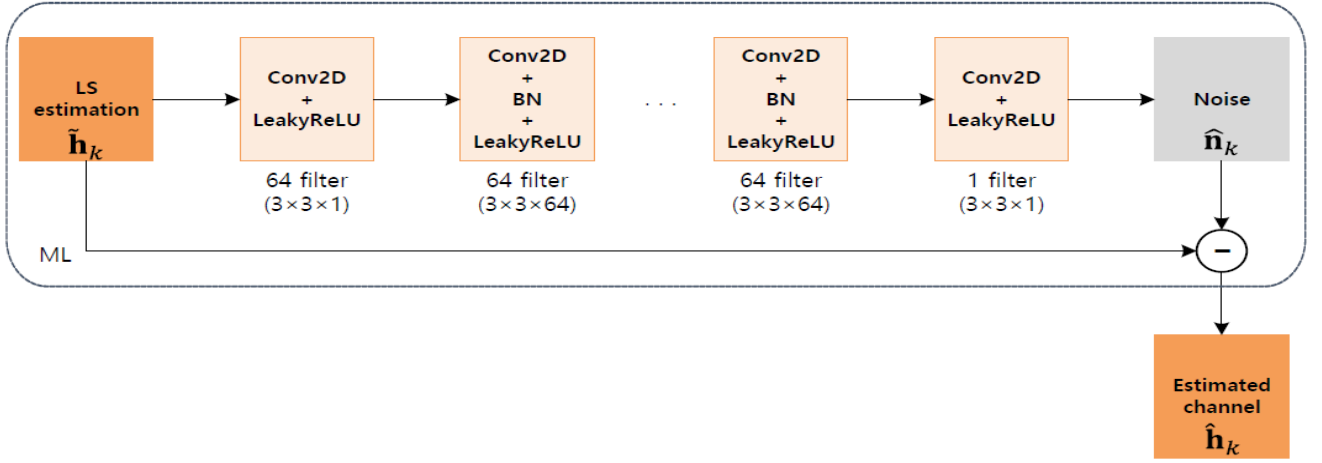


그림 1. 제안하는 채널 추정 기법

기존의 DnCNN 구조에서는 활성화 함수로 ReLU 를 사용하지만 본 논문에서는 여러 입력 값들 중에서 음의 값을 갖는 입력 값이 0 이 되는 것을 방지하기 위해 LeakyReLU 함수를 사용하였으며, $\alpha = 0.4$ 로 설정하였다. 반복적인 convolutional 층에서는 크기가 $3 \times 3 \times 64$ 인 64 개의 필터를 사용하였으며, 활성화 함수 LeakyReLU 사이에는 batch normalization (BN)을 사용하여 학습 속도와 성능을 향상시켰다. 마지막으로 출력층에서는 크기가 $3 \times 3 \times 64$ 인 하나의 필터를 사용하였다

③ 성능평가

본 논문에서는 송신단이 총 10 개의 안테나를 갖는 시스템에서 성능평가를 진행하였다. 제안하는 기계학습 모델의 성능은 기계학습 모델을 이용하여 구한 effective noise $\hat{\mathbf{n}}_k$ 의 값을 LS 추정만을 사용하여 구한 채널 $\tilde{\mathbf{h}}_k$ 에서 뺀 채널 $\hat{\mathbf{h}}_k$ 와 LS 추정만을 사용하여 구한 채널 $\tilde{\mathbf{h}}_k$ 로부터 얻는 normalized mean square error (NMSE)를 비교하여 검증하였으며, 검증에 사용된 NMSE 는 다음과 같이 표현된다.

$$\text{NMSE} = \mathbb{E} \left[\frac{\|\mathbf{h}_k - \mathbf{E}\|^2}{\|\mathbf{h}_k\|^2} \right], \quad \mathbf{E} \in \{ \tilde{\mathbf{h}}_k, \hat{\mathbf{h}}_k \}. \quad (5)$$

또한 성능평가에서는 하나의 수신단이 갖는 파일럿의 값을 1 이라고 가정하므로 신호 대 잡음비 (signal-to-noise ratio, SNR)는 다음과 같이 계산된다.

$$\text{SNR} = \frac{1}{\sigma^2}. \quad (6)$$

그림 2 는 LS 추정만을 사용하여 구한 채널 $\tilde{\mathbf{h}}_k$ 로부터 얻은 NMSE 를 이용하여 제안하는 기계학습 모델을 이용하여 구한 effective noise $\hat{\mathbf{n}}_k$ 의 값을 LS 추정만을 사용하여 구한 채널 $\tilde{\mathbf{h}}_k$ 에서 뺀 채널 $\hat{\mathbf{h}}_k$ 로부터 얻은 NMSE 를 정규화 한 결과이다.

III. 결론

본 논문에서는 MISO 밀리미터파 시스템에서 수신단으로부터 송신단이 수신 받은 신호에서 LS 추정을 사용하여 구한 채널 내에 존재하는 노이즈를 DnCNN 구조를 갖는 디노이즈 기계학습 모델을 사용하여 구한 다음 LS 추정을 사용하여 구한 채널 내에 존재하는 노이즈를 최소화하는 채널 추정 기법을 제안하였다. 제안하는 기계학습 모델의 성능은 LS 추정만을 사용하여 구한 채널과 LS 추정만을 사용하여 얻은 채널에서 제안하는 기계학습 모델을 이용하여 구한 노이즈를 뺀 채널로부터 얻는 NMSE 를 비교하여 검증하였으며,

LS추정만을 사용하여 구한 채널보다 LS추정과 제안하는 디노이즈 기계학습 모델을 함께 사용하여 구한 채널이 더 낮은 NMSE 를 가짐을 확인하였다.




그림 2. 정규화 한 NMSE

ACKNOWLEDGMENT

This work was supported by the National Research Foundation of Korea(NRF) grant funded by the Korea government(MSIT) (No. NRF-2021R1H1A1010858)

참 고 문 헌

- [1] H. Ye, F. Gao, J. Qian, H. Wang, and G. Y. Li, "Deep learning-based denoise network for CSI feedback in FDD massive MIMO systems," IEEE Communications Letters, vol. 24, no. 8, pp. 1742-1746, Aug. 2020.
- [2] Y. Jin, J. Zhang, B. Ai, and X. Zhang, "Channel estimation for mmWave massive MIMO with convolutional blind denoising network," IEEE Communications Letters, vol. 24, no. 1, pp. 95-98, Jan. 2020.
- [3] J. Gao, M. Hu, C. Zhong, G. Y. Li, and Z. Zhang, "An attention-aided deep learning framework for massive MIMO channel estimation," IEEE Transactions on Wireless Communications, vol. 21, no. 3, pp. 1823-1835, Mar. 2022.