

딥러닝 기반 MIMO-OFDM 채널 추정을 위한 하이브리드 훈련 기법

하성영, 전요셉
포항공과대학교

{sungyoung, yoseb.jeon}@postech.ac.kr

Hybrid Training Method for Deep-Learning-Based Channel Estimation in MIMO-OFDM Systems

Sungyoung Ha, Yo-Seb Jeon
Pohang Univ. of Science and Technology (POSTECH)

요약

본 논문은 다중 입출력 직교 주파수 분할 다중화(MIMO-OFDM) 시스템을 위한 딥러닝 기반의 온라인 적응형 채널 잡음 제거 방법을 제안한다. 시간 및 주파수 영역에서 채널의 상관 관계를 완전히 활용하기 위해 잡음 제거 컨볼루션 신경망(DnCNN)을 사용한다. 채널의 특성이 서로 다른 환경에서 채널 잡음 제거를 용이하게 하기 위해, 오프라인 및 온라인 훈련을 포함하는 하이브리드 전략을 제안한다. 이를 위해 온라인 훈련 데이터 샘플은 데이터 제원 채널 추정을 통해 결정된 고품질 채널 추정치를 활용하여 생성되며, 이는 실제 채널을 대신하여 사용된다. 여기서 DnCNN 은 온라인 채널 환경에 적응하기 위해 온라인 훈련 데이터에 의해 미세 조정된다. 실험 결과는 제안된 채널 잡음 제거 방법이 채널 추정 오류를 효과적으로 완화함을 보인다.

I. 서론

현대 무선 통신 표준에서 핵심 기술 중 하나인 다중 입출력 직교 주파수 분할 다중화(multiple-input multiple-output orthogonal frequency-division multiplexing, MIMO-OFDM) 시스템은 효율적인 성능을 극대화하기 위해 수신기에서 정확한 채널 상태 정보를 요구한다. 이를 위해 5G 표준에서는 자원 요소의 일부에 삽입된 DM-RS 를 기반으로 채널 추정을 한다. 그러나 복조 기준 신호(demodulation-reference signal, DM-RS)의 수가 제한되어 있고, 시간 및 주파수 영역에서 변동하는 채널로 인해 채널 추정 오류가 불가피하다. 또한 선형 채널 추정 방법들은 낮은 복잡성으로 인해 주로 사용되지만, 낮은 SNR 영역에서는 DM-RS 의 수가 잡음(noise) 신호를 충분히 억제하지 못하기 때문에 성능 저하를 겪는다. 이러한 채널 추정 오류를 완화하기 위한 대표적인 방법 중 하나는 시간 및 주파수 영역에서의 채널 상관 관계를 이용하여 채널에 내재된 잡음을 제거하는 것이다. 기존의 채널 잡음 제거 방법은 시간 및 주파수 영역의 채널 상관 관계에 대한 사전 지식을 알거나 실제 채널 분포와 일치하는 충분한 훈련 데이터가 필요하다. 그러나 이는 무선 채널 환경이 예측하기 어렵고, 다양한 특성을 가지고 있기 때문에 실제 통신 시스템에서 충족되지 않을 수 있다. 이러한 한계점들을 해결하기 위해 본 연구에서는 훈련 데이터를 활용하여 현재 채널 환경에 대한 정보를 학습할 수 있는 적응형 채널 잡음 제거 방법을 제안한다. 이를 위해 데이터 지원 채널 추정을 이용하며, 온라인 훈련 데이터를 활용하여 채널 잡음 제거 방법을 설계하기 위해 딥러닝(deep learning) 접근 방식을 제안한다.

II. 본론

본 논문에서는 N_t 개의 송신 안테나, N_r 개의 수신 안테나를 가진 MIMO-OFDM 시스템을 고려한다. 이 때, n 번째 OFDM 심볼의 k 번째 부반송파에 위치한 송신 심볼 벡터는 $\mathbf{x}[n, k] \in \mathcal{X}^{N_t}$ 로 표현하며, 심볼 전력은 $\mathbb{E}[|\mathbf{x}[n, k]|^2] = 1$ 로 정규화 되었다. 여기서 \mathcal{X} 는 정상도 집합을 나타낸다. 수신된 심볼 벡터는 다음과 같다.

$$\mathbf{y}[n, k] = \mathbf{H}[n, k]\mathbf{x}[n, k] + \mathbf{v}[n, k], \quad (1)$$

위 식에서 $\mathbf{H}[n, k]$ 는 채널 주파수 응답(channel frequency response, CFR) 행렬을 의미하며, $\mathbf{v}[n, k] \sim \mathcal{CN}(\mathbf{0}_{N_r}, \sigma^2 \mathbf{I}_{N_r})$ 독립적인 가우시안(Gaussian) 잡음 벡터를 나타낸다.

본 논문에서 제안하는 온라인 적응형 채널 잡음 제거 방법은 딥러닝 기반의 접근 방식이다. 이 방법은 시간 및 주파수 영역에서 CFR 에 내재되어 있는 잡음을 동시에 제거하기 위해 잡음 제거 신경망을 활용한다. 제안된 기법의 기본 배경은 CFR 을 2D 이미지로 취급하여 이미지 잡음 제거 작업을 위한 신경망을 이용해 잡음을 제거하는 것이다. 본 연구에서 사용된 잡음 제거 컨볼루션 신경망(Denoising convolution neural network, DnCNN)은 잔차 학습과 배치 정규화를 활용하여 훈련 과정을 가속화하고 잡음 제거 성능을 향상시켰다 [1]. DnCNN 의 입력은 시간 및 주파수 영역의 잡음이 내재된 연속적인 CFR 이며, 출력은 동일한 차원을 가진 잡음이 제거된 CFR 이다. M_t 와 M_r 를 각각 시간 및 주파수 영역의 입출력 길이로 정의한 후, DM-RS 가 마지막으로 위치한 (i, j) 번째 CFR 의 잡음 제거 과정은 다음과 같다.

$$\hat{\mathbf{M}}_{r,t}^{(i,j)} = f_{\text{DL}}(\hat{\mathbf{M}}_{r,t}^{(i,j)}; \theta_{\text{DL}}), \quad (2)$$

위 식에서 $\hat{\mathbf{M}}_{r,t}^{(i,j)}$ 은 잡음이 제거된 채널이며, $\hat{\mathbf{M}}_{r,t}^{(i,j)}$ 은 잡음이 내재된 채널이다. 또한 $f_{\text{DL}}(\cdot; \theta_{\text{DL}})$ 은 DnCNN 함수이고 θ_{DL} 은 DnCNN 의 매개변수이다. DnCNN 의 목적은 잔차 $\mathcal{R}(\hat{\mathbf{M}}_{r,t}^{(i,j)}; \theta_{\text{DL}}) \approx \hat{\mathbf{M}}_{r,t}^{(i,j)} - \hat{\mathbf{M}}_{r,t}^{(i,j)}$ 를 학습하는 것으로 다음의 손실 함수를 최소화하기 위해 훈련된다.

$$\ell(\theta_{\text{DL}}) = \mathbb{E}[\|\mathcal{R}(\hat{\mathbf{M}}_{r,t}^{(i,j)}; \theta_{\text{DL}}) \approx \hat{\mathbf{M}}_{r,t}^{(i,j)} - \hat{\mathbf{M}}_{r,t}^{(i,j)}\|_F^2], \quad (3)$$

기존에 연구된 대부분의 딥러닝 기반 채널 잡음 제거 방법은 잡음 제거 신경망의 오프라인 훈련에 의존한다. 오프라인 훈련은 추론 기간에서 훈련된 신경망의 효과를 보장하기 위해 추론 기간의 채널과 유사한 시나리오에서 생성된 대량의 훈련 데이터를 필요로 한다. 그러나 실제로는 다양하고 예측할 수 없는 채널 환경으로 인해 추론 기간과 유사한 시나리오를 결정하는 것이 어렵다. 따라서, DnCNN 을 다양한 채널 환경에 적응 가능하게 하기 위해, 오프라인과 온라인 훈련 기간을 모두 포함하는 하이브리드 훈련 전략을 제안한다. 오프라인 훈련 기간에서 무작위로 초기화된 DnCNN 을 오프라인 데이터셋을 사용하여 사전 훈련한다. 이 데이터셋은 다양한 채널 분포를 기반으로 생성되며, 이는 온라인 통신 중에 실제로 만나는 채널 분포와 다를 수 있다. 온라인 훈련 동안 훈련 데이터 샘플은 N_{train} 개의 연속된 슬롯 동안 생성된다. 이 데이터는 DnCNN 의 매개변수를 현재 채널 환경에 적응시키기 위해 사용되며 이 데이터셋은 다음과 같이 표현할 수 있다.

$$\mathcal{D}_{\text{online}}^{\text{DL}} = \{(\tilde{\mathbf{M}}_{r,t}^{(i,j)}, \tilde{\mathbf{M}}_{r,t}^{(i,j)}) | r \leq N_r, t \leq N_t, n_i \leq N_{\text{train}}, k_j \leq K\}. \quad (4)$$

온라인 훈련 데이터 생성 후, 이 데이터를 이용해 미리 학습된 DnCNN 의 매개변수를 파인 튜닝한다. 온라인 훈련 데이터가 적고, 오프라인 훈련 데이터와 달라 생길 수 있는 과적합을 피하기 위해 전체 모델을 조율한다. 온라인 훈련을 사용할 때, DnCNN 의 매개변수는 잡음이 있는 CFR $\tilde{\mathbf{M}}_{r,t}^{(i,j)}$ 과 실제 CFR 의 대체로 사용되는 데이터 지원 CFR $\tilde{\mathbf{M}}_{r,t}^{(i,j)}$ 간의 관계에서 학습한다. 데이터 지원 채널 추정 은 검출된 심볼을 추가적인 가상의 DM-RS 로 활용하여 채널 추정 성능을 향상시킨다. 데이터 지원 채널 추정이 고품질의 채널 추정치를 제공하기 때문에, 이를 온라인 훈련 데이터의 레이블로 활용한다. 따라서 실제 채널에 대한 지식이 없어도 딥러닝 모델이 학습할 수 있도록 하여 온라인 통신 중 적응형 채널 잡음 제거를 용이하게 한다.

모의 실험에서는 제안된 채널 잡음 제거 방법의 심볼 오류율(symbol error rate, SER)을 평가한다. 중심 주파수가 3.5GHz 이고 15kHz 의 부반송파 간격 및 1024 개의 부반송파를 갖는 MIMO-OFDM 시스템을 고려한다. 하나의 슬롯은 14 개의 OFDM 심볼로, 하나의 자원 블록은 12 개의 부반송파로 구성된다. 4-QAM 변조를 사용하며, $(N_t, N_r = 2, 64)$ 의 안테나 구성을 가정한다. 시스템의 신호 대 잡음비(signal noise ratio, SNR)는 N_t/σ^2 로 정의하며 ETU 및 300km/h 의 속도 환경 아래에서 평가되었다.

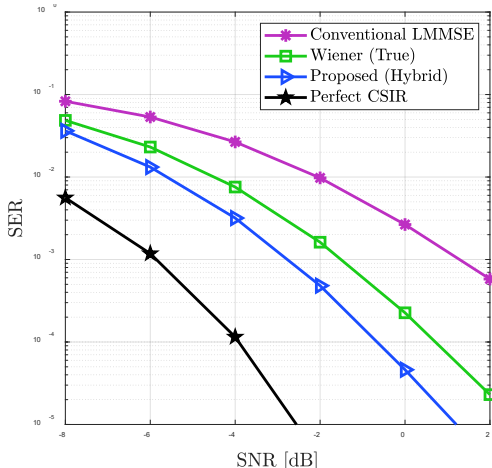


그림 1. 제안된 채널 잡음 제거 기법의 성능 평가
그림 1 은 제안된 딥 러닝 기반의 채널 잡음 제거 기법

을 SER 관점에서 평가한 것이다. 제안된 기법이 채널의 잡음 제거를 통해 기존의 전통적인 방법들에 비해 성능을 크게 향상시킨다는 것을 보인다. 주목할만한 점은 실제 채널을 사용하여 채널의 잡음을 제거한 Wiener 필터 기반의 Wiener (True) 보다 약 1dB 이상 성능 이득이 보인다는 것이다 [2]. Wiener 필터 기반의 기법은 비교적 작은 윈도우 내에서 제안된 수의 CFR 만을 활용할 수 있기 때문이다.

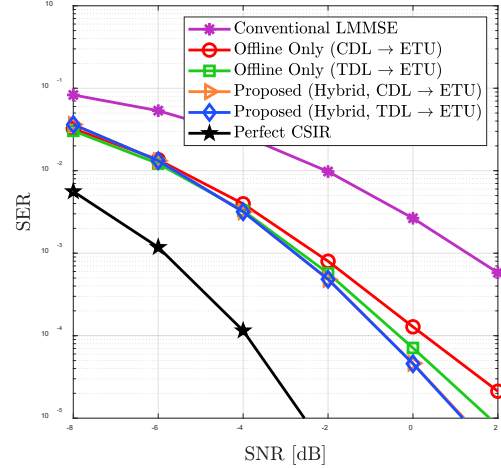


그림 2. 하이브리드 전략의 사용 유무에 따른 성능 평가

그림 2 는 제안된 하이브리드 훈련 전략을 사용한 딥러닝 기반 채널 잡음 제거 방법의 성능을 평가한 것이다. 이 실험에서는 채널 모델의 일치 또는 불일치 시나리오에서 제안된 방법의 성능을 평가하였으며, 이를 위해 오프라인 훈련 환경으로는 TDL 또는 CDL 의 시나리오를 고려한다. 채널의 모델이 다를 경우 오프라인 훈련을 통한 방법은 채널의 모델이 일치하는 경우에 비해 성능이 떨어지며, 제안된 하이브리드 전략을 사용하면 채널이 불일치하는 경우에도 성능 이득이 있음을 확인할 수 있다.

III. 결론

본 논문에서는 시변 채널 환경의 MIMO-OFDM 시스템을 위한 딥러닝 기반의 온라인 적응형 채널 잡음 제거 방법을 제안하였다. 채널의 사전 지식 없이도 온라인 채널 환경에서 채널의 잡음을 제거를 채널 추정의 성능을 향상시키는 것이 목표였으며, 이를 위해 데이터 지원 채널 추정을 사용하여 실제 채널 대신 실용적인 온라인 훈련 데이터를 생성하여 사용하였다. 딥러닝을 기반으로 온라인 훈련 데이터를 활용하는 채널 잡음 제거 방법을 설계하였으며, 실험을 통해 제안된 채널 잡음 제거 방법이 전통적인 DM-RS 기반 채널 추정의 성능을 크게 향상시킨다는 것을 확인하였다.

ACKNOWLEDGMENT

이 논문은 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (No. 2022R1C1C1010074).

참고 문헌

- [1] K. Zhang, W. Zuo, Y. Chen, D. Meng, and L. Zhang, "Beyond a Gaussian Denoiser: Residual Learning of Deep CNN for Image Denoising," *IEEE Trans. Image Process.*, vol. 26, no. 7, pp. 3142-3155, July 2017.
- [2] N. Wiener, *Extrapolation, interpolation, and smoothing of stationary time Series: with engineering applications*, Cambridge, MA, USA: MIT Press, 1949.