

# Residual Learning 을 활용한 Partial Pilot 기반 XL-MIMO 채널 추정 기법

김채현, 민경식  
가천대학교 전자공학과

chaehyeon@gahon.ac.kr, ksmin@gachon.ac.kr

## Channel Estimation based on Residual Learning for Partial Pilot-based Extremely Large-Scale MIMO Systems

Chaehyeon Kim, Kyungsik Min  
Department of Electronic Engineering, Gachon University

### 요약

초거대 다중입출력 (Extremely large-scale multiple-input multiple output: XL-MIMO) 시스템은 많은 안테나 수로 인해 안테나 수 보다 적은 수의 pilot, 즉 partial pilot 을 사용하여 채널을 추정해야 한다. 본 논문에서는 XL-MIMO 시스템에서 pilot 이 전송되지 않는 안테나에 대한 채널 추정 성능 향상을 위해 residual learning 을 활용한 partial pilot 기반 채널 추정 기법을 제안한다. 모의 실험을 통해 partial pilot 기반 XL-MIMO 시스템에서 residual learning 을 활용하여 pilot 이 없는 채널 추정을 수행할 경우 채널 추정 성능을 향상시킬 수 있음을 보여준다.

### I. 서론

6G 이동통신 시스템에서는 데이터 전송 속도를 최대 100 배 향상시키기 위해 256 개 이상의 안테나 사용이 고려되고 있다 [1]. 이러한 초거대 다중입출력 (extremely large-scale multiple-input multiple-output: XL-MIMO) 시스템에서 최대 전송률을 달성하기 위해서는 정확한 channel state information (CSI) 획득이 필수적이다 [2].

5G 의 경우 모든 안테나에서 pilot 을 전송함으로써 단말은 모든 기지국 안테나와 단말 안테나 간의 채널을 추정할 수 있다. 하지만, 256 개 이상의 안테나를 사용하는 6G XL-MIMO 기지국의 경우 orthogonal frequency division multiplexing(OFDM)의 동일 resource block 상에 모든 안테나에 대한 pilot 을 전송할 수 없다 [3]. Pilot 이 전송되지 않는 안테나에 대한 채널 추정을 위해 일부 안테나에서만 pilot 을 전송하여 일부 채널에 대한 추정만을 수행한 후 딥러닝을 활용하여 전체 채널을 추정하는 기술이 제안되었다 [4]. 하지만, 기존 연구의 경우 기본적인 deep neural network (DNN) 구조만을 사용함으로써 hidden layer 수가 증가해도 채널 추정 성능이 개선되지 않는 문제점이 존재한다 [5]. 본 연구에서는 DNN 기반 partial pilot XL-MIMO 시스템의 채널 추정 성능을 개선하기 위해 residual learning 을 활용한 채널 추정 기법을 제안한다.

### II. Residual learning 을 활용한 partial pilot 기반 XL-MIMO 채널 추정

$N_T$  개의 기지국 안테나와 하나의 단말 안테나로 이루어진 하향링크 XL-MIMO 시스템을 고려한다. 기지국과 단말 간 채널은 기지국의 안테나가 uniform planar array 로 구성된 correlated MIMO 채널을 고려한다 [4]. 기지국의 안테나 수가 OFDM resource block 에 존재하는 resource element 보다 많은 경우 모든 안테나에서 pilot 을 전송할 수 없다. 따라서 본 논문에서는 pilot 의 개수  $N_{pilot}$  이  $N_T$  보다 작은 경우 전체 채널을 추정하기 위해 residual learning 을 활용한 DNN 기반의 채널 추정 기법을 고려한다.

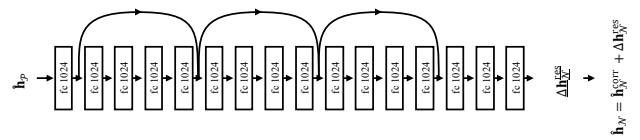


그림 1. Residual learning 을 활용한 DNN 기반 채널 추정.

### 1. 채널 추정 과정

Partial pilot 을 송신하는 안테나 집합을  $\mathcal{P}$ , 송신하지 않는 집합을  $\mathcal{N}$  이라하자.  $|\mathcal{P}| = N_{pilot}$  이며  $\mathcal{P}$ 에 속하는 안테나는 균일하게 선택된다. 기지국이  $N_{pilot}$  개의 안테나에서 pilot 을 송신하면 단말은 수신된 pilot 을 사용하여 일부 채널을 추정한다. 전체 채널을 추정하기 위해 단말은 추정된 일부 채널을 제안하는 모델에 입력하고 모델에서는 실제 채널과 공간 상관 행렬 기반 채널 간의 차이를 예측한다. 모델에서 예측하는 실제 채널  $\mathbf{h}_N^{\text{true}}$  과 공간 상관 행렬 기반 채널  $\hat{\mathbf{h}}_N^{\text{corr}}$  간의 차이는 다음과 같이 정의된다.

$$\Delta\mathbf{h}_N = \mathbf{h}_N^{\text{true}} - \hat{\mathbf{h}}_N^{\text{corr}} \quad (1)$$

식 (1)에서  $\mathbf{h}_N^{\text{true}}$ 은 pilot 이 전송되지 않는 안테나에 대한 실제 채널이며  $\Delta\mathbf{h}_N$ ,  $\mathbf{h}_N^{\text{true}}$ ,  $\hat{\mathbf{h}}_N^{\text{corr}}$ 는 모두  $(N_T - N_{pilot}) \times 1$  벡터이다. 또한  $\hat{\mathbf{h}}_N^{\text{corr}}$ 는 다음과 같이 얻어진다.

$$\hat{\mathbf{h}}_N^{\text{corr}} = \mathbf{R}_{N\mathcal{P}} \left( \mathbf{R}_{\mathcal{P}\mathcal{P}} + \sigma^2 \mathbf{I}_{N_{pilot}} \right)^{-1} \mathbf{y}_{\mathcal{P}} \quad (2)$$

식 (2)에서  $\mathbf{R}_{N\mathcal{P}}$  과  $\mathbf{R}_{\mathcal{P}\mathcal{P}}$ 는 각각  $\mathcal{N}$  과  $\mathcal{P}$  의 교차공분산행렬과  $\mathcal{P}$ 의 자기공분산 행렬이다 [4]. 또한  $\sigma^2$ 는 noise variance,  $\mathbf{y}_{\mathcal{P}}$  는 pilot 수신 벡터이다. 이후 단말은  $\Delta\mathbf{h}_N$ 을 사용하여 pilot 이 전송되지 않는 안테나에 대한 채널을 다음과 같이 계산한다.

$$\mathbf{h}_N = \Delta\mathbf{h}_N + \hat{\mathbf{h}}_N^{\text{corr}} \quad (3)$$

(3)에서 추정된 채널과 pilot 이 전송된 채널 추정 결과를 조합하여 전체 채널이 추정된다.

### 2. 제안 모델 구조

본 논문에서 제안하는  $\Delta\mathbf{h}_N$  예측을 위한 residual learning 기반 DNN 모델은 그림 1에 표현되어 있다.

표 1 Residual learning 기반 DNN 모델 파라미터

Parameters	Values
Number of hidden layers	16
Neurons per hidden layer	1024
Activation function	ReLU
Residual skip connection	4

표 2 시뮬레이션 파라미터

Parameters	Values
Antenna configuration, $(N_T, N_R)$	(256, 1)
Number of pilot symbols ( $N_{pilot}$ )	51, 32, 19
Modulation scheme	Quadrature phase shift keying
Correlation coefficient, $\rho$	0.9
Channel model	3GPP Pedestrian-A
Channel estimation	Linear mean square error

모델의 입력은 pilot 을 송신한 안테나에 대해 추정한 채널이다. 추정한 채널을 입력으로 넣으면 모델은  $\Delta h_N$ 을 예측한다. 제안하는 모델에서  $\Delta h_N$ 을 학습 및 예측하는 이유는 모델이 학습 및 예측하는 정보량이 적을수록 pilot 없는 채널의 추정 정확도가 개선될 수 있기 때문이다. 제안 모델은 fully connected layer로 구성되어 있으며 입력 forward propagation에 따른 정보량 손실을 줄이기 위해 은닉층 출력값을 다음 layer 은닉층 출력값에 더하는 skip connection을 적용하였다 [5]. 이외 자세한 모델 파라미터는 표 1에 설명되어 있다.

### 3. 학습 방식

제안하는 모델을 학습하기 위해 3GPP Pedestrian A 채널 모델을 통해 학습 데이터를 생성한다.  $N_{pilot}$  개의 pilot 송신 안테나에 대해서 추정된 채널을 feature, 식 (1)에 의해서 계산된  $\Delta h_N$ 을 label로 정의한다. 학습을 위해 사용한 손실 함수는 다음과 같다.

$$\mathcal{L} = \|\Delta h_N - \Delta h_N^{\text{res}}\|^2 \quad (4)$$

식 (4)에서  $\Delta h_N^{\text{res}}$ 는 제안 모델의 예측값이다. 모델 학습 시 learning rate는  $10^{-6}$ , epoch 수는 30, batch size는 32로 설정하였으며 optimizer는 Adam을 사용하였다.

### III. 모의실험 및 분석

제안 기법의 성능 개선을 확인하고자 fully connected DNN 모델(Plain)과 제안한 모델(RES) 실험을 통해 비교 분석하였다. 시뮬레이션에 사용된 시스템 파라미터는 표 1과 같다.

그림 2의 왼쪽은 기존 기법과 제안 모델 간의 normalized mean square error (NMSE) 성능을 signal-to-noise ratio(SNR)에 따라 보여준다. 실험에서  $N_{pilot} = \{51, 32, 19\}$ 를 고려하였으며,  $r = N_{pilot}/N_T$ 이다. 그림에서 보여지는 바와 같이 Plain 모델 대비 RES 모델이 모든 SNR 와 모든  $r$ 에서 개선된 NMSE를 달성한다. 특히  $r$ 가 작아질수록 기존 기법 대비 NMSE의 개선률이 향상된다. 이는 Plain 모델은 pilot 이 송신되지 않는 채널의 모든 정보를 DNN이 학습 및 예측하는 반면 RES 모델은 추정해야 하는 채널을 공간 상관 행렬 기반 채널과 residual 채널로 분해하고 residual 채널만 예측함으로써 Plain 모델과 유사한 모델 연산량으로도 적은 정보를 정확히 학습 및 예측할 수 있기 때문이다. 이러한 적은 정보량의 학습 및 추론에 의한 제안 모델의 효과는 pilot 수가 작아질수록 극대화된다. 따라서 residual 채널을 학습 및 예측하는 모델을 사용하면 partial pilot 기반의 XL-MIMO 채널 추정이 실질적으로 가능함을 확인할 수 있다.

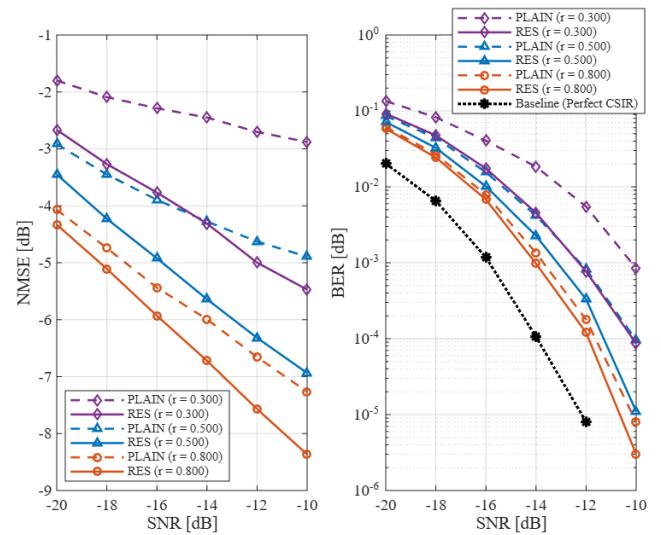


그림 2. Residual 모델과 plain 모델의 NMSE 및 BER 성능.

그림 2의 오른쪽은 제안 기법과 기존 기법 간의 bit error rate (BER) 성능을 SNR에 따라 비교한 그래프이다. NMSE 성능과 마찬가지로 RES 모델이 Plain 모델 대비 향상된 BER 성능을 보여준다. 또한 SNR 증가 할수록 Plain 모델 대비 RES 모델의 BER 개선도가 더 향상된다. 이는 사전 정보 없이 채널을 예측해야 하는 Plain 모델 대비 residual 채널을 추정하는 것이 전체 채널의 예측 정확도를 높이기 때문이다.

### IV. 결론

본 논문에서는 residual learning을 활용한 partial pilot 기반의 XL-MIMO 채널 추정 기법을 제안하였다. 제안된 기법을 통해 partial pilot 기반의 XL-MIMO 채널 추정 시 기존 DNN 기반의 채널 추정 대비 residual learning을 통해 NMSE 성능과 BER 성능이 개선됨을 확인하였다.

### ACKNOWLEDGMENT

이 성과는 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. RS-2025-24534162).

### 참고 문헌

- [1] J. Z. Wang et al., "A tutorial on extremely large-scale MIMO for 6G: Fundamentals, signal processing, and applications," IEEE Commun. Surveys & Tutorials, vol. 26, no. 3, Third Quarter, 2024.
- [2] H. Q. Ngo, E. G. Larsson, and T. L. Marzetta, "Energy and spectral efficiency of very large multiuser MIMO systems," IEEE Trans. Commun., vol. 61, no. 4, Apr. 2013.
- [3] Nokia, "Views on AI/ML operation and use cases for 6G radio air interface," 3GPP TSG RAN WG1 #122, Aug. 2025.
- [4] S. Lee, D. Sim, "Deep learning-based channel estimation for MIMO systems in spatially correlated channel," IEEE Access, vol. 12, Dec. 2024.
- [5] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," In Proc. IEEE Conference on Computer Vision and Pattern Recognition, 2016.