

파일럿 정보를 활용한 확산 모델 기반 채널 추정 성능 향상 기법

김도영, 박지훈, 채승호*

한국공학대학교

{stardust, wlgn4457, shchae}@tukorea.ac.kr

Performance-Enhanced Diffusion-Based Channel Estimation Using Pilot Information

Doyeong Kim, Jihoon Park, Seong Ho Chae*

Tech University of Korea

요약

채널 추정은 무선 통신 시스템의 성능을 결정하는 핵심 요소로, 현재까지 다양한 무선 통신 시스템을 위한 채널 추정 기법들에 대한 연구가 활발히 진행 중이다[1]. 데이터 전송 수요의 급격한 증가에 따라 Massive MIMO 와 같은 복잡한 무선 통신 시스템이 등장하였으며, 이에 따라 고차원 채널 추정 문제가 중요한 과제로 대두되었다. 이러한 환경에서 기존의 전통적 채널 추정 방식인 LS(Least Squares) 기법과 MMSE(Minimum Mean Square Error) 기법이 한계를 보임에 따라, 이를 극복하기 위한 인공지능을 활용한 딥 러닝 기반 채널 추정 기법들이 제안되었다[2][3]. 하지만, 이러한 딥 러닝 기반 채널 추정 기법들은 특정 환경에서 학습된 모델에 의존하므로, 고 이동성 시나리오 등에서 채널 특성이 변화하면 성능이 저하되는 한계를 가진다.

최근, 이를 극복하기 위한 확산 모델 기반 채널 추정 기법[4]이 제안되었으며, 해당 기법은 데이터 분포 학습을 통해 기존 기법 대비 환경 변화에 강인한 모습을 가질수 있음이 검증되었다. 전체 채널 중 파일럿 신호가 위치한 일부 부반송파에 해당하는 채널은 비교적 정확히 알 수 있다. 따라서, 파일럿 신호에 가중치를 부여해 정확한 정보를 기반으로 채널을 추정하면, 보다 정확한 채널 추정이 가능하다. 그럼에도 불구하고, 기존의 확산 모델 기반 채널 추정 기법[4]은 수신된 신호만을 활용하여 채널 추정을 수행함으로써 성능에 한계를 가진다. 따라서, 본 논문에서는 채널 추정 성능을 보다 향상시키기 위한 파일럿 위치 정보를 추가로 활용한 확산 모델 기반 채널 추정 기법을 제안하고 성능의 우수성을 검증한다.

최근, 이를 극복하기 위한 확산 모델 기반 채널 추정 기법[4]이 제안되었으며, 해당 기법은 데이터 분포 학습을 통해 기존 기법 대비 환경 변화에 강인한 모습을 가질수 있음이 검증되었다. 전체 채널 중 파일럿 신호가 위치한 일부 부반송파에 해당하는 채널은 비교적 정확히 알 수 있다. 따라서, 파일럿 신호에 가중치를 부여해 정확한 정보를 기반으로 채널을 추정하면, 보다 정확한 채널 추정이 가능하다. 그럼에도 불구하고, 기존의 확산 모델 기반 채널 추정 기법[4]은 수신된 신호만을 활용하여 채널 추정을 수행함으로써 성능에 한계를 가진다. 따라서, 본 논문에서는 채널 추정 성능을 보다 향상시키기 위한 파일럿 위치 정보를 추가로 활용한 확산 모델 기반 채널 추정 기법을 제안하고 성능의 우수성을 검증한다.

II. 기존 확산 모델 기반 채널 추정 기법 [4]

확산 모델은 전방 확산 과정(Forward process)과 역과정(Reverse process; Sampling)의 2단계 과정들로 구성된다. 기존 채널 추정 기법의 전방 확산 과정은 잡음 없는 채널 데이터 \mathbf{H}_0 에 대해 임의의 확산 단계 값 $i \in \{1, \dots, I\}$ 를 선택한다. 여기서, I 는 최대 가능한 확산 단계 값이다. 각 확산 단계 k ($1 \leq k \leq i$)에서는 신호 보존 계수 $\bar{\alpha}_k = \prod_{s=1}^k (1 - \beta_s)$ 를

결정하고, 수식(1)과 같이 $\sqrt{1 - \bar{\alpha}_k}$ 비율의 가우시안 잡음을 추가해 확산 단계 k 에서의 채널 \mathbf{H}_k 를 생성한다.

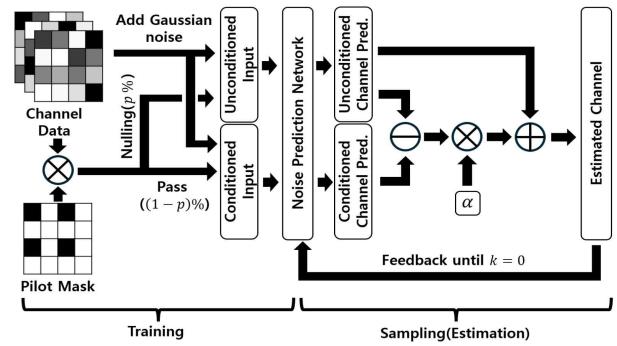


그림 1 모델 구조

$$\mathbf{H}_k = \sqrt{\alpha_k} \mathbf{H}_0 + \sqrt{1 - \alpha_k} \mathbf{n}, \quad (1)$$

여기서, β_s 는 s 번째 단계에서 기 결정되어 있는 값으로 노이즈의 양을 결정하는 파라미터이고, $\mathbf{n} \sim \mathcal{N}(0, \mathbf{I})$ 은 가우시안 잡음, \mathbf{I} 는 채널과 동일한 차원의 단위행렬을 나타낸다.

역과정에서는 전방 확산 과정에서 각 확산 단계별로 생성한 채널들에 대해서, 확산 단계 k 부터 1까지 역순으로 단계별 잡음을 예측하고 이를 제거하는 과정을 통해 최종 채널 $\tilde{\mathbf{H}}_0$ 를 추정한다. 구체적으로, $k-1$ 번째 확산 단계의 채널 추정치 $\tilde{\mathbf{H}}_{k-1}$ 는 수식(2)과 같은 형태로 추정된다.

$$\tilde{\mathbf{H}}_{k-1} = \frac{1}{\sqrt{\alpha_k}} \left(\mathbf{H}_k - \frac{\beta_k}{\sqrt{1 - \bar{\alpha}_k}} \boldsymbol{\epsilon}_{\theta}(\mathbf{H}_k, k) \right) + \sigma_k z, \quad (2)$$

여기서, $\boldsymbol{\epsilon}_{\theta}(\cdot)$ 은 잡음 예측 신경망의 출력, z 와 σ_k 는 각각 역과정에서 수렴을 위해 추가하는 가우시안 잡음과 표준편차를 나타낸다.

해당 확산 모델 채널 추정 기법은 역확산을 이용한 채널 추정에서 수신 신호에 파일럿 신호를 곱하는 LS 기법을 사용해 초기 채널 값 \mathbf{H}_k 를 얻지만, 잡음 예측 신경망에 파일럿 신호를 제공하지 않는다. 따라서, 신경망은 모든 채널 값을 동일한 신뢰도로 처리하게 되어, 채널 추정 성능에 제약이 생기는 한계를 가진다.

III. 제안하는 파일럿 강화 확산 모델 기반 채널 추정 기법

그림 1은 본 연구에서 제안하는 파일럿 강화 확산 모델 기반 채널 추정

기법의 전체 구조를 보여준다. 제안하는 모델은 기존 확산 모델 기반 채널 추정 결과를 파일럿 신호 정보를 추가로 활용한 추정 결과로 보정함으로써, 채널 추정 성능을 보다 개선할 수 있다. 이를 위해, 제안하는 모델은 두 추정 결과 모두 계산할 수 있어야 한다. 이때 파일럿 신호 정보를 추가로 활용한 채널 추정 결과를 얻기 위해 별도의 잡음 예측 네트워크를 사용하면 계산 자원 사용과 메모리 소모가 증가한다. 본 연구에서는 이를 방지하고자 잡음 예측 신경망의 입력에 파일럿 신호 정보 입력 \mathbf{C} 를 추가하고, \mathbf{C} 가 영행렬(파일럿 신호 정보가 주어지지 않음)일 때는 기존 기법처럼 \mathbf{H}_k 와 k 만으로 잡음을 예측하고, \mathbf{C} 에 파일럿 신호 정보 \mathbf{P} 가 주어질 때는 \mathbf{H}_k , k 와 \mathbf{P} 를 동시에 활용하여 잡음을 예측함으로써 하나의 잡음 예측 신경망에서 필요한 두가지 잡음을 예측 결과를 얻는다. 확산 단계 k 에서 이는 수식(3)의 형태로 주어진다.

$$\epsilon_{\theta}(\mathbf{H}_k, k, \mathbf{C}) = \begin{cases} \epsilon_{k, \mathbf{O}} & \text{if } \mathbf{C} = \mathbf{O} \\ \epsilon_{k, \mathbf{P}} & \text{if } \mathbf{C} = \mathbf{P} \end{cases} \quad (3)$$

여기서, \mathbf{C} 는 채널 데이터와 동일한 차원의 행렬이다. $\epsilon_{k, \mathbf{O}}$ 는 기존 기법과 동일한 정보로 예측한 잡음이므로 기존 기법으로 예측한 잡음과 동일하게 채널 분포 학습을 통해 환경 변화에도 강건한 성능을 가능하게 하고, 파일럿 신호 정보를 추가로 활용해 얻은 $\epsilon_{k, \mathbf{P}}$ 는 기존 기법보다 정확한 채널 추정을 가능하게 한다. 따라서, 수식(4)의 형태로 $\epsilon_{k, \mathbf{O}}$ 와 $\epsilon_{k, \mathbf{P}}$ 의 차이를 α 만큼 스케일링해 $\epsilon_{k, \mathbf{O}}$ 를 보정하여 확산 단계 k 에서의 잡음 예측 결과 ϵ_k 를 얻고, 이를 이용해 수식(5)의 형태로 $\tilde{\mathbf{H}}_{k-1}$ 를 추정해, 확산 모델 기반 채널 추정 기법이 기존에 가지고 있던 장점을 유지하면서 채널 추정 성능을 향상했시켰다.

$$\epsilon_k = \epsilon_{k, \mathbf{O}} + \alpha(\epsilon_{k, \mathbf{P}} - \epsilon_{k, \mathbf{O}}) \quad (4)$$

$$\tilde{\mathbf{H}}_{k-1} = \frac{1}{\sqrt{\alpha_k}} \left(\mathbf{H}_k - \frac{\beta_k}{\sqrt{1 - \bar{\alpha}_k}} \epsilon_k \right) + \sigma_k z \quad (5)$$

IV. 시뮬레이션

시뮬레이션에 사용된 채널 데이터는 참고문헌[5]의 QuaDRiGa 채널 생성기를 이용해 생성되었으며, 세부 설정은 표 1에 나타내었다.

시나리오	3GPP Urban Macro-cell
중심 주파수	6GHz
Tx, Rx 안테나 수	64 / 16
Tx-Rx간 거리	35-500m
BS 높이	25m
총 데이터 수	120,000

표 1. 채널 생성기 세부 설정

학습 및 채널 추정 과정에서 사용하는 채널 데이터는 푸리에 변환을 적용하여 시간-주파수 영역이 아닌 각도 영역에서 진행하여, 신경망이 정보의 희소성을 이용해 성능을 확보할 수 있도록 하였다.

모델의 학습 단계에서 전체 데이터의 10%를 파일럿 정보 없는 학습에 사용하였으며 남은 데이터는 모두 파일럿 정보가 주어진 학습에 사용하였다. 이때, 파일럿 신호 정보 유무에 따라 얻은 두 데이터의 차이를 스케일링하는 정도 α 는 10으로 설정하였다.

본 연구에서 제안하는 잡음 예측 신경망은 5개의 레이어로 구성된 CNN(Convolutional Neural Network)을 사용하였다. 참고문헌[4]에서 제안한 모델과 비교 시 동일 조건에서 추가 입력 \mathbf{C} 로 인해 파라미터 수가 증가할 것을 우려해 참고문헌[4]의 신경망보다 각 레이어마다 1개 적은 63

개의 CNN 커널을 사용하였다. 결과적으로 기존 모델과 거의 동일한 수준인 53,728개의 파라미터가 사용되었다.

시뮬레이션 결과는 그림 2에서 확인할 수 있다. LS와 LMMSE(Linear

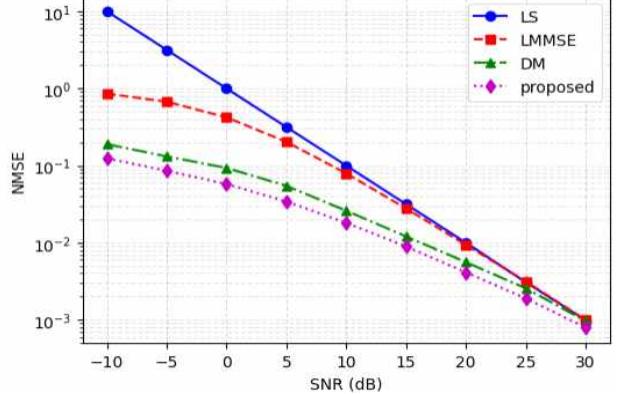


그림 2. 추정 기법별 NMSE

Minimum Mean Squared Error)로 표시된 그래프는 각 기법을 이용한 채널 추정 결과를 나타내며, DM은 참고문헌[4]에서 제안된 방식을 이용한 추정 결과를 나타낸다. 제안된 기법의 NMSE(Normalized Mean Squared Error)가 모든 SNR 구간에서 전통적인 채널 추정 기법뿐만 아니라 파일럿 강화가 적용되지 않은 기존 확산 기반 채널 추정 기법보다 우수한 결과를 확인할 수 있다.

V. 결론

본 연구에서는 파일럿 신호 정보를 활용한 보정을 통해 기존 확산 모델 기반 채널 추정 기법의 성능을 향상하는 기법을 제안하였다. 시뮬레이션 결과 제안된 기법이 전통적 채널 추정 기법들과 기존 확산 모델 기반 채널 추정 기법보다 우수한 NMSE 성능을 보여 제안한 기법의 성능적 우수성을 검증하였다.

ACKNOWLEDGMENT

이 논문은 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원-학·석사연계ICT핵심인재양성의 지원(IITP-2026-RS-2022-00156326, 50%)과 정보통신기획평가원-지역지능화혁신인재양성사업의 지원을 받아 수행된 연구임(IITP-2026-RS-2020-II201741, 50%)

참 고 문 헌

- [1] T. Kim and S. H. Chae, "A channel estimator via non-orthogonal pilot signals for uplink cellular IoT", *IEEE Access*, vol. 7, pp. 53419–53428, Apr. 2019.
- [2] M. J. Kang, S. H. Chae and J. H. Lee, "Channel estimation with DnCNN in massive MISO LEO satellite systems," in Proc. of the 14th Int. Conf. on Ubiquitous and Future Netw. (ICUFN), pp. 825–827, Jul. 2023.
- [3] J. Park and S. H. Chae, "Deep learning-based joint pilot location and number optimization for channel estimation in OFDM systems," in Proc. of the 16th Int. Conf. on Ubiquitous and Future Netw. (ICUFN), pp. 196–201, Jul. 2025.
- [4] B. Fest, M. Baur, F. Strasser, M. Joham and W. Utschick, "Diffusion-based generative prior for low-complexity MIMO channel estimation," *IEEE Wireless Commun. Lett.*, vol. 13, no. 12, pp. 3493–3497, Dec. 2024.
- [5] S. Jaeckel, L. Raschkowski, K. Börner and L. Thiele, "QuaDRiGa: A 3-D multi-cell channel model with time evolution for enabling virtual field trials," *IEEE Trans. Antennas Propag.*, vol. 62, pp. 3242–3256, 2014.