

## 확산 모델 기반 채널 추정 연구 동향

김도영, 박지훈, 채승호\*

한국공학대학교

{stardust, wlgns4457, shchae}@tukorea.ac.kr

## A research trend on the diffusion model-based channel estimation

Doyeong Kim, Jihoon Park, Seong Ho Chae\*

Tech University of Korea

## 요약

세대를 거듭하며 무선 통신 환경이 복잡해짐에 따라 다양한 조건에서 채널 추정의 정확도 확보가 중요한 과제로 남아있다. 기존의 딥러닝 기반 채널 추정 기법은 전통적인 방법에 비해 높은 성능을 보이나, 학습되지 않은 환경이나 급격히 변화하는 채널 조건에서는 성능이 저하되는 한계를 가진다. 본 논문에서는 이러한 한계점을 극복할 방안으로 확산 모델을 적용한 최근 채널 추정 연구들을 소개하고, 해당 접근법의 특징과 한계점을 살펴본다.

## 1. 서론

채널 추정은 통신 시스템의 성능을 결정하는 핵심 요소로써, 수십 년간 지속해서 연구가 이루어지고 있다[1]. 과거에 고안된 LS(Least Squares), MMSE(Minimum Mean Square Error) 기법부터 최근 딥 러닝을 적용한 채널 추정 기법까지 다양한 채널 추정 기법이 제안되었다[2],[3].

전통적 채널 추정 기법 중 하나인 LS 기법은 수신된 신호와 파일럿 신호 간의 오차를 직접 비교하여 채널을 추정하는 방식으로, 채널의 통계를 알지 못하는 상황에서도 사용될 수 있으나 복잡한 채널에서 성능이 떨어진다. 이에 반해, MMSE 기법은 LS 추정치를 기반으로 채널의 자기 상관(auto correlation) 행렬과 잡음을 이용한 보정을 통해 채널을 추정하는 기법으로 보정을 통해 LS 기법보다 더 높은 성능을 보이지만, 채널의 자기 상관 행렬과 잡음에 대한 정보가 있어야 한다는 한계를 가진다[4].

이러한 전통적 채널 추정 방법들의 한계를 극복하기 위해, 최근 딥 러닝을 적용한 채널 추정 기법들이 제안되었다[5]. 하지만, 다양한 딥 러닝 기반 채널 추정 기법들은 기존 기법 대비 높은 성능을 달성하지만, 특정 환경 조건을 바탕으로 채널 실험 값을 학습하기 때문에 환경이 변화하면 채널 추정 모델을 재학습해야 하며 학습한 적 없는 환경에서는 성능이 하락한다는 한계를 가진다. 이를 극복하기 위해, 최근 이미지 생성 분야에서 높은 성능을 보인 확산 모델을 이용한 채널 추정 연구가 많은 관심을 받고 있다. 본 논문에서는 확산 모델의 구조 및 동작을 간략히 설명하고 확산 모델을 사용한 채널 추정의 최신 연구 동향을 살펴본다.

## II. 확산 모델의 구조 및 동작 개요

확산 모델은 전방 확산 과정과 역과정으로 구성되며, 전방 확산 과정은 원본 데이터가 백색잡음에 가까워질 때까지 잡음을 단계적으로 주입하는 과정으로 다음 식으로 표현된다.

$$q(x_t|x_0) = \mathcal{N}(\sqrt{\bar{\alpha}_t}x_0, (1-\bar{\alpha}_t)\mathbf{I}), \quad x_t = \sqrt{\bar{\alpha}_t}x_0 + \sqrt{1-\bar{\alpha}_t}\epsilon, \quad (1)$$

여기서  $x_0$ 는 잡음이 추가되지 않은 원본 데이터,  $x_t$ 는 잡음이  $t$ 회 추가된 데이터를 나타내며,  $\mathcal{N}(\mu, \sigma^2)$ 은 평균이  $\mu$ 이고 분산이  $\sigma^2$ 인 가우시안 잡음,  $\alpha_t$ 와  $\bar{\alpha}_t = \prod_{s=1}^t \alpha_s$ 는 각각  $t$ 시점에서 원본 데이터를 보존할 비율을 결정하는 계수와 초기 데이터의 잔존 비율,  $\epsilon \sim \mathcal{N}(0, \mathbf{I})$ 는 단계별로 추가되는

가우시안 잡음을 나타낸다.

샘플링(Sampling)으로도 불리는 역과정은 잡음이 섞인 데이터  $x_t$ 를 시점으로 하여 신경망으로 예측한 잡음을 단계별로 제거하며  $t \rightarrow t-1$ 로 이동한다.  $\epsilon_\theta(\cdot)$ 를 파라미터  $\theta$ 를 사용하는 잡음 예측 네트워크라고 할 때 역과정은 다음 수식으로 표현된다.

$$x_{t-1} = \frac{1}{\sqrt{\alpha_t}} \left( x_t - \frac{\beta_t}{\sqrt{1-\alpha_t}} \epsilon_\theta(x_t, t) \right) + \sigma_t z, \quad (2)$$

여기서  $\beta_t = 1 - \alpha_t$ 로 각 단계에서 주입되는 잡음의 분산을 나타내고,  $z$ 와  $\sigma_t$ 는 각각 역과정에서 수렴을 위해 추가하는 가우시안 잡음과 그 표준편차를 나타낸다. 역과정에서 단계별로 추가된 잡음을 예측하도록 학습한 모델은 결국 원본 이미지의 분포를 학습하게 된다. 따라서 완전한 잡음 이미지에서 단계적으로 잡음을 제거하며 학습한 이미지들의 분포로 수렴하여 학습한 적 없는 고품질 이미지를 생성할 수 있게 된다.

다음 장에서 확산 모델을 활용한 채널 추정에 관한 최신 연구 결과들을 소개한다. 표 1은 본 논문에서 소개하는 연구 결과의 주요 내용과 확산 모델 유형, 잡음 예측 신경망 구조를 비교한 결과표이다.

시나리오	논문 번호	주요 내용	확산 모델 유형	잡음 예측 신경망 구조
massive MIMO	[6]	환경 변화에 대한 확산 모델의 강인성 확인	Score-based	RefineNET
	[8]	각도 영역 변환을 통한 추론 속도 향상	DDIM	CNN
	[9]	저해상도 ADC에서 성능 향상 및 불완전 데이터 기반 학습		
RIS	[7]	점진적 지식 증류를 통한 추론 속도 향상	DDPM	U-NET

표 1. 확산 모델 기반 채널 추정 연구

## III. 확산 모델 기반 채널 추정 연구[6]-[9]

참고문헌 [6]에서 확산 모델 기반 채널 추정 연구가 최초로 제안되었다. MIMO(Multiple Input Multiple Output) 환경에서 채널 정보를 더 정확하게 강건하게 추정하기 위해, 확산 모델의 일종인 확률 분포의 기울기인 스코어(score) 기반 모델을 채널의 통계적 특성을 학습하는 확률적 사전분포(probabilistic prior) 생성기로 활용하였다. 추정 시에는 이 사전 분포(prior)에 수신된 파일럿 신호 정보를 통해 얻은 우도(likelihood)를 결합하

여 사후 샘플링(posterior sampling)을 통해 채널을 추정한다. 모델의 성능을 검증하기 위해 훈련 환경과 테스트 환경을 의도적으로 다르게 설정하는 분포 불일치(out-of-distribution) 상황에서, 다른 딥러닝 기법들이 성능 저하를 보이는 것과 달리 확산 모델 기반 채널 추정은 이상적인 채널을 알고 있을 때와 거의 유사한 BER(Bit Error Rate)을 달성하였다. 이를 통해 확산 모델의 환경 변화에 대한 뛰어난 강건성을 입증하였다. 또한, 모델 크기의 수정을 통해  $16 \times 64$  크기의 채널에서 추론 지연 시간을 1.5초 수준으로 줄여 이동성이 낮은 시나리오에서 확산 모델의 실용성을 보였다. 저자는 이러한 잠재력을 가진 확산 모델은 저해상도 수신기의 채널 추정 성능 개선, 간섭 시나리오에서 오류 플로어(error floor) 극복 등의 분야에도 활용될 수 있어, 추가 연구가 필요함을 밝혔다.

참고문헌 [7]은 확산 모델의 높은 계산 비용 문제를 개선하면서 기존 MIMO 환경보다 더 복잡한 RIS(Reconfigurable Intelligent Surface) 환경에 적용한 연구이다. 해당 연구에서는 RIS 환경을 극복하기 위해 기존 수신단 잡음뿐만 아니라 RIS 하드웨어 자체에서 발생하는 위상 잡음(phase noise)까지 완화하기 위해 기존 사후 샘플링 과정에 RIS 위상에 대한 경사 하강법(gradient descent)을 통합하여 위상 잡음의 영향을 줄이는 방식을 제안했다. 또한, 기존 연구의 한계로 지적된 높은 추론 비용 문제를 해결하기 위해 점진적 증류(progressive distillation)를 도입했다. 이 기법으로 1024회의 샘플링 단계를 요구하는 기존 모델의 지식을 절반의 샘플링 단계를 가진 모델로 증류하는 과정을 반복하여 최종적으로 32회의 샘플링 단계를 갖는 모델로 만들어 추론 속도를 크게 향상하면서 성능 저하를 1dB 이내로 최소화했다. 그 결과, 제안된 모델은 기존 RIS 환경에서 채널 추정 기법들 대비 3.2dB 이상의 NMSE 향상을 보였으며, 위상 잡음을 고려하지 않았을 때보다 최대 3.74dB 더 나은 성능을 달성하여 확산 모델의 적용 범위를 확장하고 실용성을 높였다.

참고문헌 [8]은 확산 모델의 복잡도와 메모리 문제를 다루면서 실제 통신 환경에 적용 가능한 낮은 복잡도를 가진 채널 추정기 설계를 제안한 연구이다. 복잡도 문제를 해소하기 위해 기존에 시간-주파수 차원의 채널 데이터를 푸리에 변환을 통해 희소(sparse)한 특성을 보이는 각도 영역(angular domain)으로 변환한 뒤 분포를 학습하였다. 이를 통해 [5]를 포함한 기존 연구에서 사용한 수백만 개의 파라미터를 약 5만 5천 개 수준으로 줄인 경량 CNN(Convolutional Neural Network) 잡음 예측 모델구조를 구현하였다. 또한, 일정한 단계의 추론 과정을 거쳐야 하는 기존 확산 모델의 효율성을 개선하기 위해 관측된 신호의 SNR(Signal to Noise Ratio)에 해당하는 확산 단계에서부터 샘플링을 시작하는 방식을 채택했다. 이에 따라 SNR이 높을수록 더 적은 수의 추론 단계만 거치도록 하여 추가적인 추정 지연 시간 단축을 이루었다. 그 결과, 훨씬 적은 메모리와 계산량에도 불구하고 동일한 조건에서 참고문헌 [5]에서 제안한 스코어 기반 모델 대비 최대 5dB 더 우수한 추정 성능을 보였으며, SNR 정보가 부정확한 상황에서도 강건함을 유지하는 결과를 보여 확산 모델 기반 채널 추정의 실용화 가능성을 높였다.

참고문헌 [9]는 참고문헌 [6]에서 추가 연구가 필요한 부분으로 밝힌 확산 모델을 통한 저해상도 ADC(Analog to Digital Converter)의 성능 개선과 다수의 깨끗한 훈련 데이터 확보의 어려움을 극복하는 방식을 제안한 연구이다. 저해상도 ADC에서의 성능 저하를 해결하기 위해 저해상도로 왜곡된 측정치에 맞춰 사후 샘플링(posterior sampling) 과정의 우도(likelihood) 항을 수정함으로써 비선형 왜곡의 영향을 보상했다. 또한, 다수의 깨끗한 채널 데이터를 현실적으로 확보하기 어려운 문제를 해결하기 위해 SURE(Stein's Unbiased Risk Estimator)를 사용하여 잡음이 섞인 데이터만으로도 확산 모델이 실제 채널의 통계적 분포를 효과적으로 학습

할 수 있게 하였다. 그 결과, 제안된 모델은 전통적 기법과 딥 러닝 기반의 기존 기법보다 추론 지연 시간을 최대 10배 단축하고 파일럿 밀도를 줄였을 때도 강인한 성능을 보여 모든 부반송파에 파일럿 신호를 보내는 것이 힘든 고차원 채널에서 확산 모델 활용의 장점을 보였다.

## IV. 결론

앞서 소개한 연구 결과들은 확산 모델 기반 채널 추정이 기존 방식 대비 환경 변화에 강인한 성능을 가짐을 보였다. 세대를 거듭하며 복잡해지는 무선 통신 환경에서 이러한 특징은 장점이 될 수 있으며, 추가 연구를 통해 채널 추정에 필요한 시간을 단축할 수 있다면 고이동성 시나리오를 포함한 다양한 무선 통신 환경 채널 추정에 사용 가능하다.

## ACKNOWLEDGMENT

이 논문은 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원-학·석사연계ICT핵심인재양성의 지원을 받아 수행된 연구임 (IITP-2025-RS-2022-00156326)

## 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] Y. G. Li, L. J. Cimini, and N. R. Sollenberger, "Robust channel estimation for OFDM systems with rapid dispersive fading channels," *IEEE Trans. Commun.*, vol. 46, no. 7, pp. 902 - 915, Jul. 1998.
- [5] H. Ye, G. Y. Li and B. -H. Juang, "Power of deep learning for channel estimation and signal detection in OFDM systems," *IEEE Wireless Commun. Lett.*, vol. 7, no. 1, pp. 114-117, Feb. 2018.
- [6] M. Arvinte and J. I. Tamir, "MIMO channel estimation using score-based generative models," *IEEE Trans. Wireless Commun.*, vol. 22, no. 6, pp. 3698-3713, Jun. 2023.
- [7] W. Tong, W. Xu, F. Wang, W. Ni and J. Zhang, "Diffusion model-based channel estimation for RIS-aided communication systems," *IEEE Wireless Commun. Lett.*, vol. 13, no. 9, pp. 2586-2590, Sep. 2024.
- [8] 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.
- [9] X. Zhou, L. Liang, J. Zhang, P. Jiang, Y. Li and S. Jin, "Generative diffusion models for high dimensional channel estimation," *IEEE Trans. Wireless Commun.*, vol. 24, no. 7, pp. 5840-5854, Jul. 2025.