

# Haar 웨이블릿 변환 기반 확산 모델을 활용한 빠른 채널 추정 기법

권나현, 김정현

세종대학교

nhkwon9803@sju.ac.kr, j.kim@sejong.ac.kr

## Fast Channel Estimation Utilizing Haar Wavelet Transform-Based Diffusion Model

Nahyeon Kwon, Junghyun Kim

Sejong Univ.

### 요약

본 논문에서는 웨이블릿 변환 기반 확산 모델을 활용한 빠른 채널 추정 기법을 제안한다. 확산 모델은 이미지 처리를 포함한 다양한 분야에서 매우 뛰어난 성능을 보이며 현재 많은 주목을 받고 있는 딥러닝 모델이다. 최근에는 이러한 확산 모델을 이용하여 뛰어난 성능을 보인 채널 추정 기법이 제안되었다. 본 논문에서는 Haar 웨이블릿 변환을 확산 모델에 적용하여 데이터의 특성을 유지하면서 크기를 1/2로 줄이고 레이어의 최소화하여 복잡도 및 속도를 크게 개선한 새로운 모델을 제안한다. 실험을 통해 제안 모델이 선행 연구의 뛰어난 확산 모델의 성능을 유지하면서 학습 및 테스트 시간을 30% 수준으로 줄였을 뿐만 아니라 모델의 연산 속도를 크게 개선함을 보였다.

### I. 서론

채널 추정은 무선 통신 채널의 상태를 파악하기 위해 여러 파일럿 신호 측정을 통해 실제 채널 행렬을 추정하는 기법이다[1]. 전통적인 채널 추정 방식인 least squares(LS)와 minimum squared error(MMSE) 추정은 복잡한 연산으로 인해 저지연을 요구하는 6G 시스템에서는 적절하지 않다[2]. 이를 대체하기 위해 최근에는 빠르고 정확한 채널 추정을 위한 다양한 뉴럴 네트워크를 적용한 연구가 진행되고 있다.

선행 연구[3]는 최근 다양한 분야에서 뛰어난 성능을 보이는 확산 모델을 이용한 채널 추정 기법을 제안하였다. 해당 연구에서는 노이즈의 정도와 관계없이 타임 스텝만큼 역확산 과정을 수행하는 기존 확산 모델의 비효율성을 줄이기 위해, 채널 추정 과정에서 signal-to-noise ration(SNR)에 따라 타임 스텝을 결정하여 채널 추정을 가속하였다. 또한, 제안한 채널 추정 기법이 평균 제곱 오차 관점에서 최적에 근사함을 보였다.

Haar 웨이블릿 변환(이하 웨이블릿 변환)[4]은 데이터의 고유 정보를 보존하면서 데이터를 압축하는 데에 주로 사용되는 방법으로, 딥러닝 모델에 적용하여 연산 속도를 크게 개선시킬 수 있다. WaveDiff[5]는 이러한 웨이블릿 변환과 GAN 기반 확산 모델을 결합하여 기존 확산 모델의 성능을 유지하며 더욱 빠르게 추론할 수 있음을 보였다. 따라서 본 논문에서는 선행 연구의 확산 모델을 기반으로 웨이블릿 변환을 적용한 더욱 빠른 채널 추정 기법을 제안한다. 실험을 통해 제안 모델이 기존 확산 모델의 우수한 성능을 유지하며 연산 속도를 크게 향상시킴을 확인하였다.

### II. 본론

#### 1) 데이터

본 논문에서는 선행 연구에서 생성한 데이터를 사용하였다. 3<sup>rd</sup> Generation Partnership Project(3GPP) 공간 채널 모델 데이터와 QuadRiGa 2.4버전 채널 시뮬레이터 데이터를 사용하였으며, 두 데이터는 모두 다중 입력 다중 출력(multi-input multi-output, MIMO) 환경을 가정한다. 또한, 두 데이터는 수신 안테나 개수( $N_{rx}$ )가 64개이며, 송신 안테나 개수( $N_{tx}$ )는 16인 채널 행렬( $H \in \mathbb{C}^{N_{tx} \times N_{rx}}$ )로 이루어져 있다.

#### 2) 웨이블릿 변환

제안 모델의 입력 데이터는 Fast Fourier Transform(FFT)을 먼저 수행한 후 데이터의 크기를 줄여 복잡도를 감소시키기 위해 웨이블릿 변환을 적용한다. 웨이블릿 변환은 WaveDiff[5]의 방법을 활용하여, 주파수에 따라 4개의 서브 밴드(Low-Low, Low-High, High-Low, High-High)로 나누어 변환하고, 각 서브 밴드를 채널 축으로 연결해서 사용한다. 이러한 변환 과정을 통해 입력 데이터의 크기는 1/2만큼 작아지고 실수 및 허수로 구성된 채널은 서브 밴드 개수만큼 증가하여 ( $8, N_{rx}/2, N_{tx}/2$ )이 된다. 그림 1은 데이터 전처리 후의 시각화를 나타낸다. 원본 데이터인 (a)는 데이터의 분포가 고르게 퍼져, 육안상 큰 특징이 없다. 그러나 FFT를 적용한 (b)에서는 특정 부분에만 데이터가 부분적으로 밀집하도록 변화한다. 그리고 FFT 이후 주파수에 따라 웨이블릿 변환을 한 (c)에서는 FFT의 희소한 데이터 특성을 유지하면서 데이터의 크기가 작아진 것을 볼 수 있다. 이처럼 제안 모델에서는 입력 데이터의 크기를 1/2로 줄여, 빠른 연산이 가능하도록 변환하였다.

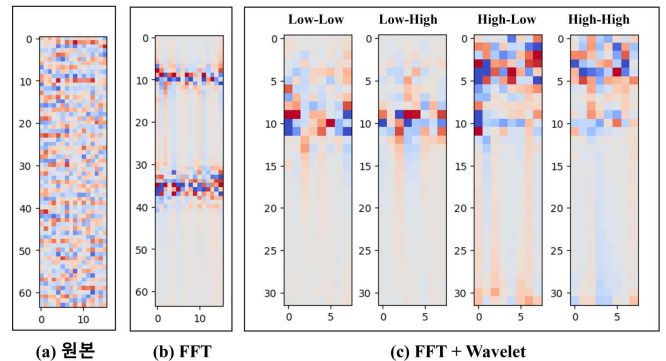


그림 1. 원본 데이터 및 전처리 후 데이터 시각화

#### 3) 확산 모델

확산 모델의 학습은 크게 두 단계로 나누어져 있다. 먼저 타임 스텝  $t$ 에 따라 점진적으로 노이즈를 추가하는 확산 과정은 다음과 같이 표현한다.

$$q(x_t|x_{t-1}) = N(x_t; \sqrt{\bar{\alpha}_t} x_{t-1}, (1 - \bar{\alpha}_t)I) \quad (1)$$

여기서  $\bar{\alpha}_t = 1 - \beta_t$ ,  $\bar{\alpha}_t = \prod_{s=1}^t \alpha_s$ 이며,  $\beta_t \in (0, 1)$ 는 원본 데이터에 추가되는 데이터로, 매우 작은 값으로 설정한다. 그리고 확산 모델은 추가된 노이즈를 점진적으로 제거하는 역확산 과정을 다음과 같이 수행한다.

$$p_\theta(x_{t-1}|x_t) = N(x_{t-1}; \mu_\theta(x_t, t), \sigma_t^2 I) \quad (2)$$

이때  $\mu_\theta(x_t, t)$ 와  $\sigma_t^2$ 는 타임 스텝  $t$ 에서 제거하는 노이즈의 평균과 분산을 나타낸다. 확산 모델은 Kullback-Leibler(KL) 발산을 이용하여 실제 분포인  $q(x_{t-1}|x_t)$ 와 파라미터화한 분포인  $p_\theta(x_{t-1}|x_t)$  간의 거리를 최소화하도록 학습한다.




그림 2. 제안한 채널 추정 기법의 확산 모델 구조

본 논문의 제안 모델은 선행 논문에서 사용한 모델을 기반으로 변형하였으며, 구조는 그림 2와 같다. 제안 모델에서는 3x3 컨볼루션 레이어를 여러 층 쌓아서 사용하며, 중간에 타임 스텝  $t$ 의 임베딩을 추가하여 학습한다. 그리고 연산 속도 및 복잡도를 개선하기 위해 기존 모델보다 컨볼루션 레이어를 1층 감소시켰다. 학습률은 0.0001이며, 타임 스텝  $T$ 는 100, 배치 크기는 128, 에포크는 500으로 선행 연구와 동일하게 설정하였다. 또한, 기존 모델과 같이 제안 모델에서도 온라인 채널 추정 단계에서 SNR에 따라 계산된 타임 스텝  $t$ 를 사용하여 추론 시간을 감소시켰다.

#### 4) 실험 결과

본 논문에서는 표준화된 평균 제곱 오차(normalized mean squared error, NMSE)로 성능을 평가한다. 그림 3의 (a)와 (b)는 각각 3GPP 및 QuaDRiGa 채널 시뮬레이션 데이터를 학습하여 SNR마다 NMSE를 확인한 결과를 나타낸 그래프이다. 그래프에서 결과를 비교해 보면, 두 데이터 모두 기존 모델과 웨이블릿을 적용한 제안 모델의 성능이 크게 다르지 않은 것을 볼 수 있다. 비록 QuaDRiGa 데이터의 낮은 SNR에서 선행 연구에 비해 다소 성능이 낮아졌으나, 해당 영역은 실제 통신에서 사용하기 어려운 채널 환경에 해당하고, 가장 크게 차이가 나는  $-10\text{dB}$ 에서도 그 차이는 0.05 미만으로 크지 않았다.

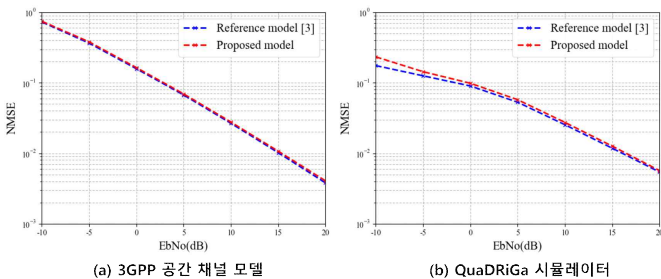


그림 3. 기존 모델과 제안 모델의 채널 추정 성능 비교

표 1은 기존 모델과 제안 모델의 파라미터 수 및 학습 시간, 테스트 시간 그리고 샘플 당 GPU 연산 시간을 정리한 표이다. 이때 GPU 연산 시간은 Pytorch의 프로파일러 기능을 사용하여 계산하였으며, 배치 단위로 연산을 수행한 후 배치 크기로 나누어 샘플 당 연산 시간을 계산하였다.

	기존 모델[3]	제안 모델
파라미터 수	55025	50923
학습 시간	9449s	2761s
테스트 시간	87s	26s
GPU 연산 시간	34.5us/sample	18.4us/sample

표 1. 기존 모델[3]과 제안 모델의 복잡도 비교

시간 측정 결과로부터 제안 모델이 기존 모델 대비 학습 시간 및 테스트 시간을 약 30%로 감소시켰고, GPU 연산 시간 역시 약 53%로 크게 감소시켰음을 확인할 수 있다. 이를 통해 제안 모델이 기존 모델의 뛰어난 성능을 유지하면서 복잡도를 크게 개선시켰음을 알 수 있다.

### III. 결론

본 논문에서는 웨이블릿 변환 기반 확산 모델을 이용한 채널 추정 기법을 제안한다. 웨이블릿 변환은 모델의 입력 데이터 크기를 1/2로 줄였으며, 이에 따라 모델의 학습 시간 및 테스트 시간을 30% 수준으로 크게 감소시켰다. 또한, 모델의 경량화를 위해 기존 모델 구조에서 한 층을 제거하여 총 4개의 컨볼루션 층으로 구성하였고, 제안 모델의 성능을 확인한 결과 기존 모델의 성능을 거의 유지했다. 이를 통해 모델의 복잡도가 감소했음에도 웨이블릿 변환으로 주파수에 따라 강조된 특성을 활용하여 채널의 특성을 잘 추정할 수 있음을 알 수 있다. 향후 연구에서는 다양한 형태의 웨이블릿 설계 및 적용을 통해 더욱 효과적인 채널 추정 기법도 가능할 것으로 기대한다.

### ACKNOWLEDGMENT

본 연구는 과학기술정보통신부 및 정보통신기획평가원의 정보통신방송 혁신인재양성(메타버스융합대학원)사업 연구 결과로 수행되었음 (IITP-2023-RS-2023-00254529).

이 논문은 2023년도 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업입(RS-2023-00271991).

### 참고 문헌

- [1] Arvinte, M., Tamir, I. J., "Score-Based Generative Models for Robust Channel Estimation," arXiv preprint arXiv:2111.08177, 2021.
- [2] Doshi, A., Andrews, J. G., "One-bit mmWave MIMO Channel Estimation using Deep Generative Networks," IEEE Wireless Communications Letters, vol. 12, no. 9, pp. 1593-1597, Sept. 2023.
- [3] Fesl, B., Baur, M., Strasser, F., Joham, M., Utschick, W., "Diffusion-based Generative Prior for Low-Complexity MIMO Channel Estimation," arXiv preprint arXiv:2403.03545, 2024.
- [4] Stanković, R. S., Falkowski, B. J., "The Haar wavelet transform: its status and achievements," Computers & Electrical Engineering, vol. 29, no. 1, pp. 25-44, Jan. 2003.
- [5] Phung, H., Dao, Q., Tran, A., "Wavelet Diffusion Models are fast and scalable Image Generators," in Proc. Computer Vision and Pattern Recognition Conference(CVPR), pp. 10199-10208, Jun. 18-22, 2023.