

딥러닝 기반 밀리미터파 대역 채널 추정 기법 및 성능 분석

서경식, 노송
인천대학교

{ksseo5623, songnoh}@inu.ac.kr

요약

본 논문은 딥러닝 기반의 밀리미터파 채널 추정 기법을 제안하고, 무선 통신환경의 특성을 고려하여 딥러닝을 채널 추정기법에 적용할 때 고려해야 할 요소를 분석한다. 나아가 기존 채널 추정 기법과 비교 및 분석을 통해, 제안된 기법의 적용 타당성을 검증한다. 모의 시험을 통해 신경망 학습을 위한 데이터 구성에 따른 성능 변화를 알아보고 각 채널 추정 기법의 신호 대 잡음비(SNR: signal-to-noise ratio)에 따른 평균 제곱 오차(MSE: mean squared error)의 성능을 비교한다.

I. 서론

5 세대(5G) 이동 통신의 핵심 기술 요소인 밀리미터파(millimeter wave) 대역 통신은, 수 GHz 단위의 초광대역 주파수 스펙트럼을 활용하여 고용량 무선 데이터 트래픽이 예상되는 사용자 밀집 지역 통신망이나 네트워크 백홀 구축의 효율성을 극대화할 것으로 예상한다[1]. 밀리미터파 대역에서 예상되는 높은 경로 손실을 극복하기 위해, 다수의 안테나를 사용한 빔포밍(beamforming) 기술에 많은 연구가 발표되고 있다[2]. 높은 지향성을 가지는 빔포밍을 구현하기 위해서는 정확한 채널 추정 값의 확보가 필수적이다. 이에 본 논문에서는 최근 다양한 분야에 적용되고 있는 딥러닝 기법을 활용하여 밀리미터파 채널 추정 기법을 제안한다. 무선 통신과의 연계성을 고려하여 딥러닝 기술 적용시 고려해야 점을 살펴보고, 기존의 MUSIC(MUltiple SIgnal Classification), Root-MUSIC 채널 추정 기법과 비교 및 분석을 통해 제안된 기법의 적용 타당성을 검증한다.

II. 시스템 모델

송신기는 단일 안테나를 가지며, 수신기는 N 개의 안테나를 가지는 상향링크 통신 시스템을 고려한다. 송신기와 수신기 사이의 채널은 다음과 같다.

$$\mathbf{h} = \sum_{i=1}^P g_i \mathbf{a}(\theta_i). \quad (1)$$

P, g_i, θ_i 는 각각 전달 경로의 개수, i 번째 전달 경로의 이득 및 입사각(AoA: angle-of-arrival)을 나타낸다. 수신 안테나 요소의 간격이 d 로 일정한 균일 선형 배열 안테나(ULA: uniform linear array)에서 i 번째 경로에 대한 조향 벡터 $\mathbf{a}(\theta_i)$ 는 다음과 같다.

$$\mathbf{a}(\theta_i) = \left[1, e^{-j2\pi \frac{\lambda}{d} \sin \theta_i}, \dots, e^{-j2\pi \frac{\lambda}{d} (N-1) \sin \theta_i} \right]^T. \quad (2)$$

λ 는 반송파 신호의 파장이다. 이를 바탕으로 수신기에서 수신한 신호는 다음과 같다.

$$\mathbf{y} = \mathbf{h} \mathbf{x} + \mathbf{n}. \quad (3)$$

\mathbf{x} 는 송신 신호를 나타내며 전력은 1로 가정한다. \mathbf{n} 은 가산성 백색잡음이며 평균 0, 분산 σ_n^2 가우시안 분포를 따라 생성된다 ($\mathbf{n} \sim \mathcal{CN}(0, \sigma_n^2 \mathbf{I})$).

III. 채널 추정 기법

채널 추정 기법 중 잡음 부공간(Subspace) 이용하는 대표적인 기법 및 제안된 기법으로 심층 신경망(DNN: deep neural network)을 이용한 채널 추정 알고리즘의 동작 원리와 특징에 대해 살펴본다.

A. MUSIC [3]

수신기에서 수신한 신호에 대한 공분산행렬의 특이값 분해(SVD: singular value decomposition)를 수행한 결과는 다음과 같다.

$$\mathbf{R} = [\mathbf{U}_s \ \mathbf{U}_n] \begin{bmatrix} \mathbf{\Sigma}_s & 0 \\ 0 & \mathbf{\Sigma}_n \end{bmatrix} \begin{bmatrix} \mathbf{U}_s^H \\ \mathbf{U}_n^H \end{bmatrix}. \quad (4)$$

이때, \mathbf{U}_s 는 신호 부분 공간을 생성하고 \mathbf{U}_n 은 신호 부분 공간에 직교하는 잡음 부분 공간을 생성한다. 잡음 부분 공간을 이용한 스펙트럼은 다음과 같다.

$$P_{mu}(\varphi) = \frac{1}{\|\mathbf{U}_n^H \mathbf{a}(\varphi)\|^2}. \quad (5)$$

잡음 부 공간이 조향 벡터 $\mathbf{a}(\varphi)$ 와 직교한다는 성질을 이용해 관심 각도 공간에 대해 선형 완전 탐색을 통해 식 (5)를 최대로 만드는 $\hat{\theta}$ 을 구해 채널 추정을 달성한다.

$$\hat{\theta} = \text{argmax } P_{mu}(\varphi). \quad (6)$$

이때, 사용한 특이값 분해 연산에 높은 연산 복잡도가 요구되며, 완전 탐색 시 φ 의 각도 양자화 샘플의 수에 따라 추정 기법 성능이 영향을 받는다.

B. Root-MUSIC [4]

MUSIC 알고리즘에서 탐색 각도 φ 의 양자화 샘플의 수에 따라 성능이 영향을 받는 문제를 해결하기 위해 직접 해를 구하는 접근 방식을 사용한다. 먼저 z -변환을 이용해 식 (5)를 다음과 같이 변형할 수 있다.

$$\begin{aligned} P_{mu}^{-1}(\varphi) &= \sum_{l=-(N-1)}^{N+1} C_l z^l, \\ C_l &= \sum_{n-m=l} R_{mn}. \end{aligned} \quad (7)$$

위의 식을 통해 z 에 대한 다항식을 얻을 수 있고, 식(7)의 해 중 단위원 내부에 있으므로 경계에 가장 가까운 해 z_r 에서 다음과 같은 식을 통해 $\hat{\theta}$ 을 구할 수 있다.

$$\hat{\theta} = \cos^{-1} \left(\left(\frac{\lambda}{2\pi d} \right) \arg(z_r) \right). \quad (8)$$

이 기법은 MUSIC과 동일하게 특이값 분해 연산을 필요로 하여 높은 연산 복잡도가 요구된다. 그러나, 채널 추정 시 탐색각도 양자화 샘플을 통한 완전 탐색을 하지 않고 직접 해를 구하기 때문에 탐색각도 샘플 수에 무관한 채널 추정 성능을 얻게 된다.

C. 제안된 딥 러닝 기반 채널 추정 기법

제안된 딥 러닝 기반 채널 추정 기법은 수신기에서 수신된 신호를 통해 $\hat{\theta}$ 을 추정하는 문제를 풀도록 신경망을 사전 학습시킨다. 훈련을 위한 데이터는 수신신호 \mathbf{y} 와 해당하는 실제 각도 θ 이며 다음과 같은 손실함수를 최소화하는 방향으로 신경망을 학습한다.

$$MSE = \frac{1}{M} \sum_{k=1}^M \|\theta_k - \hat{\theta}_k\|^2. \quad (9)$$

M 은 훈련에 사용된 데이터의 개수를 나타낸다. 신경망의 구조와 학습에 사용된 세팅은 그림 1과 표 1에 나타냈다.

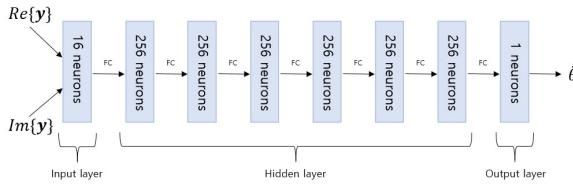


그림 1. 채널 추정을 위해 제안된 신경망 구조

환경 변수	값
Training Sample	4×10^5
Hidden Activation Function	ReLU
Output Activation Function	Tanh
Optimizer	Adam
Loss function	MSE
Learning Rate	10^{-3}
Epoch	5×10^3

표 1. 신경망 학습 변수 설정

IV. 성능분석 및 결론

본 논문에서 고려된 채널 추정 기법의 성능 평가를 위해 다음과 같은 시뮬레이션 환경을 고려한다: 안테나 개수 $N = 16$, 경로의 수 $P = 1$ 로 설정한다. 채널 생성 시 입사각은 120° 각도 구간 섹터에서 발생하는 상황을 가정한다 ($\theta \in [-\frac{\pi}{3}, \frac{\pi}{3}]$). 신호 대 잡음비는 $SNR = \frac{|g|^2}{\sigma_n^2}$ 로 정의한다.

그림 2는 학습에 사용된 데이터의 구성에 따른 성능을 나타낸다. Dataset1은 SNR이 $-5, 0, 5, 10$ dB인 데이터

10^5 개씩 총 4×10^5 개를 학습했고, Dataset2는 -5 dB의 데이터를 4×10^5 개, Dataset3은 10 dB의 데이터를 4×10^5 개 학습에 사용한 결과이다.

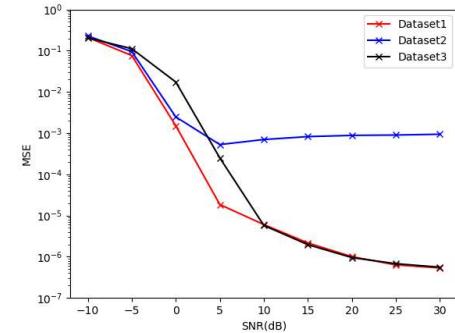


그림 2. 학습 데이터 구성에 따른 제안된 딥러닝 기반 채널 추정 성능 비교

고려되는 SNR 범위에서 Dataset1을 이용해 학습된 신경망의 성능이 가장 좋은 것을 확인할 수 있다.

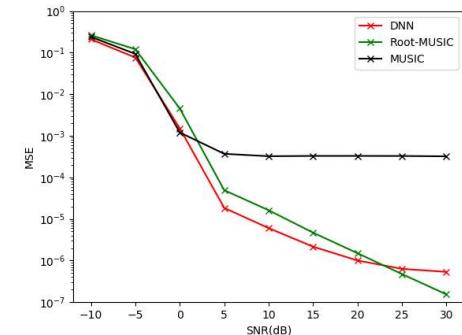


그림 3. 기존 채널 추정 기법과의 성능 비교

그림 3은 SNR에 따라 본 논문에서 고려된 채널 추정 기법의 MSE 성능을 나타낸다. 제안된 DNN을 통한 채널 추정 기법의 성능이 20dB 이하의 전 SNR 구간에서 기존 기법 대비 좋은 성능을 보이는 것을 확인할 수 있다.

본 논문에서는 단일 경로 상황에서의 모의 시험을 통해 제안된 기법의 성능 향상을 확인했다. 추후 연구로 다중 경로 상황을 고려할 수 있다. 또한 비 선형 연산의 근사화 표현이 가능한 딥러닝의 특성을 이용해 비선형 요소를 고려한 통신 시스템 연구로 확장이 가능하다.

ACKNOWLEDGEMENT

이 연구는 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원과 (NRF-2019R1G1A1009021), 인천대학교 2020년도 자체연구비(2020-0265) 지원을 받아 수행된 연구임.

참 고 문 헌

- [1] M. Polese et al., "Integrated access and backhaul in 5G mmWave networks: Potential and Challenges," *IEEE Commun. Mag.*, vol. 58, no. 3, pp. 62–68, Mar. 2020.
- [2] J. Zhang et al., "Hybrid beamforming for 5G and beyond millimeter-wave systems: A holistic view," *IEEE Open J. Commun. Soc.*, vol. 1, pp. 77–91, Dec. 2019.
- [3] R. Schmidt, "Multiple emitter location and signal parameter estimation," *IEEE Trans. Antennas Propag.*, vol. 34, no. 3, pp. 276–280, Mar. 1986.
- [4] A. Barabell, "Improving the resolution performance of eigenstructure-based direction-finding algorithms," in *Proc. Int. Conf. Acoustics, Speech, Signal Processing (ICASSP)*, pp. 336 – 339, Apr. 1983.