

PMI 와 RSRP 만을 활용한 딥러닝 기반 실내 위치 추정 기법

박상천, 이인규
고려대학교

{ppp103207, inkyu}@korea.ac.kr

Deep Learning-Based Indoor Localization Method Using only PMI and RSRP

Sangchun Park and Inkyu Lee
Korea Univ.

요약

단일 기지국 기반 실내 위치추정은 추가 인프라 없이 구현 가능하지만, 기존의 CSI 기반 방식은 대규모 MIMO 환경에서 CSI 획득과 피드백 오버헤드가 커 실제 5G 운용에 적용하기 어렵다. 본 논문은 5G 운용 절차에서 단말이 획득 가능한 RSRP 와 PMI 만을 입력으로 사용하는 딥러닝 기반 실내 위치추정 방법을 제안한다. PMI 가 포함하는 방향성 정보를 RSRP 와 결합하여 공간 구분력을 확장하며, 기존의 완벽한 CSI 를 활용한 방식과 비교해 다양한 채널 조건에서 높은 위치추정 성능과 강건성을 확인하였다.

I. 서론

단일 기지국 기반 실내 위치추정은 인프라 추가 없이도 서비스를 제공할 수 있어 활발히 연구되어 왔다. 기존 연구의 상당수는 기지국이 단말의 완전한 채널 상태 정보(channel state information; CSI)를 획득할 수 있다는 가정 하에, 채널 계수를 활용한 위치추정 기법을 제안하였다[1], [2]. 그러나 대규모 MIMO 환경에서는 안테나 수 증가로 채널 차원이 커지면서 CSI 피드백에 따른 측정 자원 및 시그널링 오버헤드가 급증하여, 실제 5G 운용에 적용하기 어렵다.

이를 대체하기 위해 5G 에서 기본 제공되는 참조신호 수신전력(reference signal received power; RSRP) 및 참조신호 수신품질(reference signal received quality; RSRQ)만을 이용한 방법도 제안되었으나[3], [4], 이를 지표는 공간 정보가 제한적이어서 복잡한 다중경로 환경에서 정확도 저하가 발생할 수 있다. 반면 프리코딩 행렬 인자(precoding matrix indicator; PMI)는 코드북 기반 범포밍에서 선택된 범 인덱스로서 채널의 방향성 정보를 간접적으로 포함한다. 따라서 본 논문에서는 5G 운용 절차에서 단말이 획득 가능한 RSRP 와 PMI 만을 활용한 딥러닝 기반 실내 위치추정 방법을 제안하며, 완전 CSI 기반 방식 대비 다양한 채널 조건(특히 복잡한 실내 다중경로)에서 높은 위치추정 정확도와 강건한 성능을 보인다.

II. 본론

우리는 다중입력단일출력(multiple-input single-output; MISO) 시스템을 고려한다. 기지국(base station; BS)은 M 개의 안테나 원소로 구성된 균일 선형 배열(uniform linear array; ULA)을 사용하며, 단말(user equipment; UE)은 단일 안테나를 갖는다고 가정한다. 수신 신호는

$$y = \mathbf{h}^H \mathbf{f} s + n$$

와 같이 정의되며, $\mathbf{h} \in \mathbb{C}^{M \times 1}$ 는 채널 벡터, $\mathbf{f} \in \mathbb{C}^{M \times 1}$ 는 범포밍 벡터, s 는 전력 $|s|^2 = 1$ 인 송신 신호, $n \sim \mathcal{CN}(0, \sigma_n^2)$ 은 잡음이며 잡음 전력이 σ_n^2 인 복소 가우시안 분포를 따른다. 채널은 가시선(line-of-sight; LoS) 성분과 비가시선(non-line-of-sight; NLoS) 성분을 포함하는 라이시안(Rician) 페이딩 모델을

$$\mathbf{h} = \sqrt{\frac{K}{K+1}} \alpha_{\text{LOS}} \mathbf{a}(\theta_{\text{LOS}}) + \sqrt{\frac{1}{K+1}} \sqrt{\frac{1}{L}} \sum_{l=1}^L \alpha_l \mathbf{a}(\theta_l)$$

따르며[5], K 는 라이시안 K 팩터이며, L 은 비가시선의 경로 개수, α_{LOS} 와 α_l 은 각각 LOS 채널과 NLOS 채널의 채널 이득이며 평균 전력은 1 을 가정한다. θ_{LOS} 과 θ_l 은 각각 LOS 채널과 NLOS 채널의 방위각이다. ULA 의 배열 응답 벡터(array response vector;)인 $\mathbf{a}(\theta)$ 는

$$\mathbf{a}(\theta) = [1, \dots, e^{jkd \sin \theta}, \dots, e^{jkd(M-1) \sin \theta}]^T$$

와 같이 정의되며[6], κ 는 파수이며, d 는 인접 안테나 원소 간 거리, θ 는 방위각을 나타낸다.

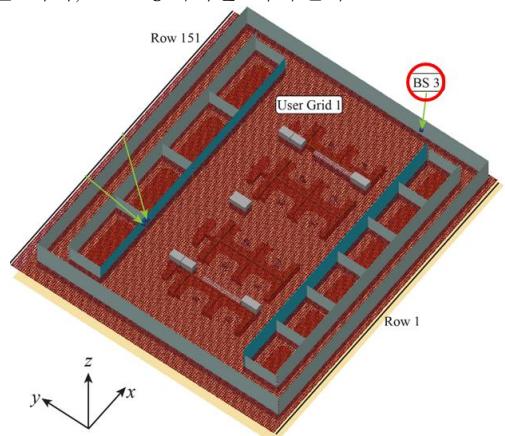


그림 1. 실내 오피스 환경

실험 환경은 그림 1 과 같이 DeepMIMO 의 실내 오피스 시나리오를 기반으로 구성하였다[7]. UE 는 0.2m 간격의 격자 형태로 배치되며, BS 는 그림 1 의 BS3 에 위치한다고 가정한다. 또한 UE 및 BS 의 높이는 각각 1m와 3m로 설정한다.

UE 가 PMI 및 RSRP 를 획득하기 위해, BS 는 3GPP 표준에서 정의된 이산 푸리에 변환(discrete Fourier transform; DFT) 코드북을 사용하여 빔포밍 벡터 집합을 구성하고[8], 이후 BS 는 각 빔에 대해 순차적으로 파일럿을 송신하는 빔 스위핑을 수행하고, UE 는 각 빔에 대한 RSRP 를 측정한다. UE 는 측정된 RSRP 가 최대가 되는 빔 인덱스를 PMI 로 결정한다.

본 논문에서는 코드북 기반 빔 스위핑으로 획득 가능한 빔별 RSRP 와 PMI 만을 이용하여 사용자의 2 차원 위치 (x, y) 를 추정하는 딥러닝 기반 위치 추정 방식을 제안한다. 제안 방식은 입력으로 선택된 N 개의 RSRP 값과 PMI 를 사용하며, 이를 fully-connected neural network 에 입력하여 위치 좌표로 회귀하는 형태로 추정한다. 비교를 위해 CSI 기반 기준 방법을 함께 고려하며, 해당 방법은 채널 벡터의 실수부와 헤수부를 분리하여 신경망 입력으로 사용한다.

기지국 안테나 개수는 $M = 64$ 로 가정하고, 코드북 크기도 64 로 설정한다. 빔포밍 벡터의 전력은 $|\mathbf{f}|^2 = 1$ 로 정규화하며, 신호 대비 잡음 전력 비율(signal-to-noise ratio)은 $\gamma = \mathbb{E}[\mathbf{h}/\sigma_n^2]$ 로 정의한다. 위치추정 성능 평가는 평균 절대 오차(mean absolute error; MAE) 를 사용하며, 학습 및 성능 비교에 동일한 지표를 적용한다.

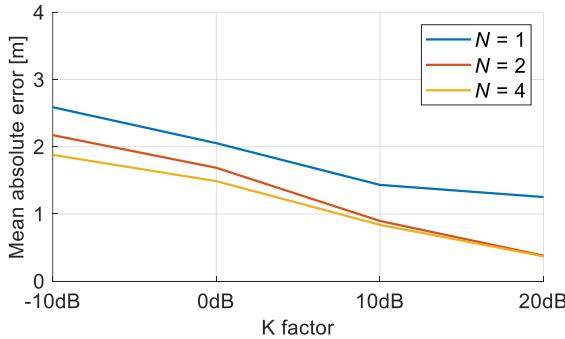


그림 2. RSRP 사용 개수에 따른 위치 추정 오차

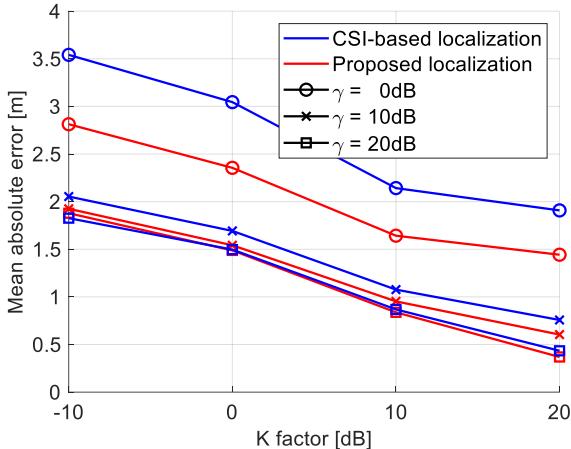


그림 3. 제안 방식과 CSI 기반 방식과의 성능 비교

그림 2 는 제안 방식에서 입력으로 사용하는 RSRP 개수 N 에 따른 MAE 를 나타낸다. N 이 증가할수록 위치추정 오차가 감소하며, 라이시안 K 팩터가 증가할수록(LoS 성분이 우세할수록) MAE 가 전반적으로 낮아지는 경향을 확인할 수 있다. 그림 3 은 SNR γ 와 K 팩터 변화에 따른

CSI 기반 방식과 제안 방식의 성능을 비교한 결과이다. 특히 낮은 SNR 구간에서 제안 방식이 CSI 기반 방식 대비 더 낮은 MAE 를 보여, 잡음이 큰 환경에서도 장건한 위치추정 성능을 확인할 수 있다.

IV. 결론

본 논문에서는 RSRP 와 PMI 만을 활용하는 단일 기지국 기반 실내 위치추정 방법을 제안하였다. 제안 방식은 코드북 기반 빔 스위핑으로 얻을 수 있는 측정치만으로 동작하므로 CSI 피드백 오버헤드가 큰 대규모 MIMO 및 5G 환경에 적합하다. 실험 결과, 제안 방식은 CSI 기반 방식 대비 우수한 위치 추정 성능을 보였다. 이는 PMI 가 제공하는 방향성 정보가 제한된 참조신호 기반 입력의 공간 구분력을 보완하여 위치추정 성능을 향상시킬 수 있음을 시사한다.

ACKNOWLEDGMENT

본 연구는 정보통신기획평가원의 지원을 받아 수행된 연구임 RS-2024-00397480.

참고 문헌

- [1] B. Zhang, H. Sifaou, and G. Y. Li, "CSI-fingerprinting indoor localization via attention-augmented residual convolutional neural network," *IEEE Transactions on Wireless Communications*, vol. 22, no. 8, pp. 5583–5597, Aug. 2023.
- [2] K. Vuckovic, S. Hosseini, F. Hejazi, and N. Rahnavard, "A CSI-based data-driven localization framework using small-scale training datasets in single-site MIMO systems," *IEEE Transactions on Wireless Communications*, vol. 23, no. 11, pp. 16346–16358, Nov. 2024.
- [3] X. Zhou, L. Chen, Y. Ruan, T. Zhou, and R. Chen, "IMPos: Indoor mobile positioning with 5G multibeam signals from a single base station," *IEEE Internet of Things Journal*, vol. 11, no. 11, pp. 20743–20756, June 2024.
- [4] X. Zhou, L. Chen, Y. Ruan, and R. Chen, "Indoor localization with multi-beam of 5G new radio signals," *IEEE Transactions on Wireless Communications*, vol. 23, no. 9, pp. 11260–11275, Sept. 2024.
- [5] M. K. Simon and M.-S. Alouini, *Digital Communication over Fading Channels*, 2nd ed. Hoboken, NJ, USA: John Wiley & Sons, 2005.
- [6] H. L. Van Trees, *Optimum Array Processing: Detection, Estimation, and Modulation Theory, Part IV*. New York, NY, USA: John Wiley & Sons, 2002.
- [7] A. Alkhateeb, "DeepMIMO: A Generic Deep Learning Dataset for Millimeter Wave and Massive MIMO Applications," *arXiv preprint arXiv:1902.06435*, 2019.
- [8] 3GPP, "NR; Physical layer procedures for data," 3GPP TS 38.214, V19.1.0 (Release 19), Sept. 2025.