

5G NR 테스트베드에서 PRS를 활용한 Transformer 기반 측위 성능 분석

서하숨, 정홍석, 김선우

한양대학교 융합전자공학부

{tgt0707, hssjung, remero}@hanyang.ac.kr

Performance Analysis of Transformer-Based Localization with PRS in a 5G NR Testbed

Hasom Seo, Hongseok Jung, Sunwoo Kim

Department of Electronic Engineering, Hanyang University

요약

본 논문은 5G NR 테스트베드에서 PRS (positioning reference signal) 기반 실측 데이터를 수집하고, Transformer 기반 AI (artificial intelligence) 측위를 제안하여 LS (least squares) 기반 측위와 정량적으로 비교한다. 제안 기법은 PRS로부터 추출한 ToA (time of arrival) 기반 거리 추정치와 RSRP (reference signal received power)를 입력으로 학습되어, 비가시선 및 다중경로가 지배적인 복잡한 전파 환경에서 단말의 위치를 직접 추정한다. 실험 결과 CDF 50 % 및 80 % 지점에서 AI 기반 측위는 LS 대비 각각 약 83 % 및 90 %의 오차 감소를 달성하였다. 이는 시뮬레이션 중심 연구의 한계를 넘어, 실측 기반 5G NR 환경에서 AI 기반 측위가 ToA 오차 증가로 인한 물리 기반 기법의 성능 저하를 효과적으로 완화하고 우수한 위치 정확도를 제공함을 실증적으로 입증한 결과이다.

I. 서론

최근 MATLAB, NVIDIA Sionna 등 ray-tracing 시뮬레이션을 활용한 무선 측위 연구가 활발히 진행되고 있다. Ray-tracing은 전파의 반사, 산란, 차폐를 물리 기반으로 모사함으로써 사실적인 데이터를 생성할 수 있다 [1]. 대용량 데이터 수집이 용이하여 AI (artificial intelligence) 기반 측위 모델 학습에 주로 사용되지만, 시뮬레이션이 현실 환경을 완벽히 재현할 수 없다는 근본적 한계로 인하여 학습된 모델을 실제 환경에 적용할 경우 측위 성능이 저하되는 문제점이 존재한다 [2]. 따라서 본 연구에서는 시뮬레이션 중심의 모델 학습을 넘어, 5G NR 테스트베드에서 PRS (positioning reference signal) 기반 실측 데이터를 수집하여 AI 측위 모델 학습을 진행한다. 이후, 실제 테스트베드 환경에서의 측위 성능을 정량적으로 분석함으로써 시뮬레이션 기반 무선 측위 연구의 한계를 보완하는 실증적 기여를 제시한다.

II. 시스템 모델

본 연구에서는 5G OFDM (orthogonal frequency division multiplexing) 기반 MIMO (multiple input multiple output) 시스템을 고려하여, 송신 안테나 N_{tx} 개와 수신 안테나 N_{rx} 개를 사용한다. 시간 슬롯 기반의 블록 페이딩 채널을 적용하여 각 OFDM 심볼 내에서 채널 응답이 고정되며, 최대 지연은 CP (cyclic prefix) T_{cp} 에 포함된다. 샘플링 시간 T_s 로 이산화된 시간 인덱스 $t=1,2,\dots,T$ 에서 단말이 수신한 측위 참조 신호 PRS $\mathbf{r}_t \in \mathbb{C}^{N_{rx} \times 1}$ 는 다음과 같이 모델링된다.

$$\mathbf{r}_t = \sum_{\tau=0}^{T_{cp}} \mathbf{H}_{\tau} \mathbf{y}_{t-\tau}^{\text{PRS}} + \boldsymbol{\xi}_t, \quad (1)$$

여기서 $\mathbf{y}_t^{\text{PRS}} \in \mathbb{C}^{N_{tx} \times 1}$ 은 PRS 송신 신호, $\boldsymbol{\xi}_t \in \mathbb{C}^{N_{rx} \times 1}$ 은 가우시안 백색 잡음이며, $\mathbf{H}_{\tau} \in \mathbb{C}^{N_{rx} \times N_{tx}}$ 는 $\tau=1,2,\dots,T_{cp}$ 샘플 지연에 대한 CIR(channel impulse response) 인덱스를 의미한다 [3].

PRS는 수신단에서 이미 알고 있는 참조 시퀀스이므로, PRS 관측 구간 Γ_{PRS} 에서 상관 기반 LS (least squares) 채널 추정을 통해 각 지연 τ 에 대한 CIR을 다음과 같이 추정할 수 있다.




그림 1. 한국전자통신연구원 연구원에 구축된 5G NR 테스트베드 및 gNB 배치도

$$\hat{\mathbf{H}}_{\tau} = \left(\sum_{t \in \Gamma_{\text{PRS}}} \mathbf{r}_t (\mathbf{y}_{t-\tau}^{\text{PRS}})^H \right) \left(\sum_{t \in \Gamma_{\text{PRS}}} \mathbf{y}_{t-\tau}^{\text{PRS}} (\mathbf{y}_{t-\tau}^{\text{PRS}})^H \right)^{-1}, \quad (2)$$

이때, $\hat{\mathbf{H}}_{\tau}$ 의 τ 축 나열 $(\hat{\mathbf{H}}_{\tau})_{\tau=0}^{T_{cp}}$ 를 PRS 기반으로 추정된 CIR로 정의하며, 추정된 CIR로부터 power delay profile(PDP)을 다음과 같이 정의한다.

$$P(\tau) = \|\hat{\mathbf{H}}_{\tau}\|_F^2, \quad (3)$$

ToA(time of arrival)는 다중경로 환경에서 최초 유의미 경로의 도달 지연을 추정하는 과정이며, 본 연구에서는 PDP가 임계값 γ 를 처음으로 초과하는 지연 인덱스를 $\hat{\tau}$ 로 정의한다. 이때, $\hat{\tau}$ 는 샘플 지연 인덱스이므로 ToA는 $\hat{t} = \hat{\tau} T_s$ 로 변환되며, ToA 기반 거리 측정치 $\hat{d}$ 는 전파 속도 c 를 곱하여 $\hat{d} = c\hat{t}$ 로 계산한다.

단말은 Γ_{PRS} 에서 gNB $b=1,2,\dots,B$ 의 안테나 포트 $a=1,2,\dots,A$ 에 대응하는 수신 신호 $r_{ba}[l]$ 를 관측하며, 5G NR 테스트베드에서 PRS를 활용한 Transformer 기반 측위 성능 분석.pdf 각 포트별 RSRP (reference signal received power)를 다음과 같이 정의한다.

$$\hat{\rho}_{ba} = \frac{1}{|\Gamma_{\text{PRS}}|} \sum_{t \in \Gamma_{\text{PRS}}} |r_{ba}[t]|^2. \quad (4)$$

III. Transformer 기반 측위 모델

본 연구에서는 위도, 경도 기반의 단말의 2차원 위치 $\mathbf{u}=[x,y]^T$ 를 추정하기 위해 gNB b 로부터 얻어진 ToA 기반 거리 추정치 $\hat{d}_b$ 및 안테나 포트별 RSRP $\hat{\rho}_{ba}$ 를 입력으로 사용한다. gNB b 에 대한 입력 토큰 벡터 $\mathbf{z}_b \in \mathbb{R}^{A+1}$ 를 다음과 같이 정의한다.

$$\mathbf{z}_b = [\hat{d}_b, \hat{\rho}_{b1}, \hat{\rho}_{b2}, \dots, \hat{\rho}_{bA}]^T, \quad (5)$$

이때 $\mathbf{z}_b$ 를 선형 임베딩하여 D 차원으로 변환하고, gNB 인덱스에 따른 학습 가능한 임베딩을 더해 초기 토큰 행렬 $\mathbf{H}^{(0)} \in \mathbb{R}^{B \times D}$ 를 구성한다. 이후 Transformer 인코더 레이어를 통해 gNB 간의 관계가 반영된 $k=1,2,\dots,K$ 번째 레이어의 self-attention은 다음과 같이 계산된다.

$$\mathbf{H}^{(k)} = \text{softmax} \left(\frac{\mathbf{Q}^{(k)} (\mathbf{K}^{(k)})^T}{\sqrt{D}} \right) \mathbf{V}^{(k)}, \quad (6)$$

$$\mathbf{Q}^{(k)} = \mathbf{H}^{(k-1)} \mathbf{W}_Q^{(k)}, \quad (7)$$

$$\mathbf{K}^{(k)} = \mathbf{H}^{(k-1)} \mathbf{W}_K^{(k)}, \quad (8)$$

$$\mathbf{V}^{(k)} = \mathbf{H}^{(k-1)} \mathbf{W}_V^{(k)}, \quad (9)$$

여기서 $\mathbf{Q}^{(k)}, \mathbf{K}^{(k)}, \mathbf{V}^{(k)} \in \mathbb{R}^{B \times D}$ 는 각각 query, key, value 행렬이며, 이전 레이어 출력 $\mathbf{H}^{(k-1)}$ 로부터 선형 변환으로 생성된다. $\mathbf{W}_Q^{(k)}, \mathbf{W}_K^{(k)}, \mathbf{W}_V^{(k)} \in \mathbb{R}^{D \times D}$ 는 학습 가능한 가중치이며, 이후 multi-head attention 및 잔차 연결, 레이어 정규화, feed-forward network를 포함하는 Transformer 인코더 구조를 거친다 [4].

최종 레이어 출력 $\mathbf{H}^{(K)} = [\mathbf{h}_1^{(K)}, \mathbf{h}_2^{(K)}, \dots, \mathbf{h}_B^{(K)}]^T$ 로부터 gNB 전체 정보를 대표하는 전역 표현을 평균 풀링으로 구성하고, MLP(multi-layer perceptron)를 통해 단말의 위치 $\hat{\mathbf{u}}=[\hat{x}, \hat{y}]^T$ 를 추정한다.

$$\hat{\mathbf{u}} = \text{MLP} \left(\frac{1}{B} \sum_{b=1}^B \mathbf{h}_b^{(K)} \right). \quad (10)$$

학습은 추정 위치 $\hat{\mathbf{u}}$ 와 실제 위치 $\mathbf{u}$ 간의 평균 제곱 오차 $\|\mathbf{u} - \hat{\mathbf{u}}\|_2^2$ 를 최소화하며 수행한다.

IV. 5G NR 측위 테스트베드 구축 및 결과 분석

A. 5G NR 테스트베드 구성 및 실험 방법

본 연구에서는 한국전자통신연구원 대전본원을 대상으로 구축된 5G NR 테스트베드에서 PRS 신호를 이용한 실측 기반 측위 실험을 진행하였다. 테스트베드는 그림 1과 같이 총 4개의 gNB로 구성되며, 각 gNB는 4개의 송신 안테나 포트를, 단말은 dipole 안테나를 사용한다. 또한, 본 테스트베드는 5G NR n79 대역에서 운용되며, gNB-단말 간의 링크는 중심 주파수 4.45 GHz 및 대역폭 100 MHz 설정 하에서 PRS를 송·수신한다.

수집된 ToA를 기반으로 추정된 거리와 gNB 안테나 포트별 RSRP는 Transformer 기반 측위 모델의 입력으로 사용되었다. 4개의 gNB에 대한 토큰을 $D=64$ 차원 임베딩으로 변환한 뒤, $\mathbf{H}^{(0)} \in \mathbb{R}^{4 \times 64}$ 를 형성한다. 이후 multi-head attention 4, feed-forward network 128차원, GELU 활성화 함수로 이루어진 2개의 Transformer 인코더 레이어를 거친 뒤 최종 토큰의 출력을 MLP에 입력하여 2차원 단말 위치를 회귀한다.




그림 2. Transformer 기반 측위와 LS 기반 측위 오차 비교

B. Transformer 기반 측위 결과 및 분석

실측 데이터를 기반으로 5G NR 테스트베드에서 AI 기반 측위 성능과 LS 기반 측위 성능을 정량적으로 비교하였다. CDF 50 % 지점에서의 측위 오차는 AI 기반 측위가 9.61 m, LS 기반 측위가 55.91 m였으며, CDF 80 % 지점에서는 AI 기반 측위가 16.23 m, LS 기반 측위 성능은 156.63 m의 결과가 확인되었다.

이러한 결과는 무선 통신 환경에서 비가시선 및 다중경로로와 시각 동기 오차로 인해 ToA 기반 거리 추정 오차가 크게 발생하며, 이로 인해 기하학 및 물리적 정보를 이용한 LS 기반 측위 성능이 크게 저하됨을 시사한다. 반면 AI 기반 측위는 측정 데이터의 패턴을 학습한 데이터 기반 추정으로서, 복잡한 전파 조건에서도 상대적으로 안정적이고 강인한 성능을 보일 수 있음을 수치적으로 검증하였다.

V. 결론

본 논문에서는 5G NR 환경에서 PRS 기반 실측 데이터를 활용한 Transformer 기반 측위를 제안하고, 이를 LS 기반 측위와 정량적으로 비교하였다. 실험 결과 AI 기반 측위는 CDF 50 % 및 80 % 지점에서 LS 대비 각각 약 83 %, 90 %의 오차 감소를 보였다. 향후에는 실제 환경을 모방한 디지털 트윈 기반 데이터와 실측 데이터를 결합한 학습을 통해 다양한 환경으로의 일반화 성능 강화하고, 측위 정확도를 추가적으로 개선할 계획이다.

ACKNOWLEDGMENT

이 논문은 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임 (No. RS-2024-00337857, 5G 및 다중 GNSS 기반 긴급구조용 복합측위 기술 개발)

참고 문헌

- [1] J. Hoydis, F. A. Aoudia, S. Cammerer et al., "Sionna RT: Differentiable Ray Tracing for Radio Propagation Modeling," in *Proc. IEEE Glob. Commun. Conf. Workshops.*, 2023
- [2] K. Gao, H. Wang, H. Lv et al., "Localization-Oriented Digital Twinning in 6G: A New Indoor-Positioning Paradigm and Proof-of-Concept," *IEEE Trans. Wirel. Commun.*, 2024.
- [3] L. Italiano, B. Camajori, M. Brambilla et al., "A tutorial on 5G positioning", *IEEE Commun. Surv. Tutor.*, 2025.
- [4] A. Vaswani, N. Shazeer, N. Parmar et al., "Attention is All you Need", in *Proc. 31st Conf. NIPS.*, 2017.