

지연 거리 정보를 활용한 대규모 언어 모델 기반 측위 방법

정윤지, 이훈

울산과학기술원 전기전자공학과
heather2000@unist.ac.kr, hoonlee@unist.ac.kr

A Large Language Model Approach for Localization Methods With Delayed Information

Yunji Jeong and Hoon Lee

Dept. Electrical Eng., Ulsan National Institute of Science and Technology

요 약

본 논문에서는 지연된 거리 정보만을 사용하여 이동단말의 미래 위치를 예측하는 대규모 언어 모델 기반의 측위 방식을 제안한다. 사전에 학습된 언어 모델의 높은 일반화 능력을 활용하면, 단말 이동성에 대한 수학적 모델 없이 실시간으로 수집된 적은 양의 데이터만으로도 단말의 위치를 정확하게 추정할 수 있다. 모의 실험을 통해 제안하는 기법의 성능을 확인하고, 종래의 인공지능 기반 추론 방식과 성능을 비교하여 유효성을 입증한다.

1. 서 론

이동단말의 위치를 추정하는 측위 기술은 이동통신 시스템에서 매우 중요한 기술이다. 대표적으로 거리 정보를 활용하는 삼변측량과 각도 정보를 기반으로 하는 삼각측량 방식이 존재한다. 최근에는 거리와 각도 정보를 모두 사용하는 최적화 알고리즘 기반 측위 기법[1]과 인공지능 기반의 측위 체계[2]가 연구된 바 있다. 이러한 방식들은 현재까지 측정된 거리/각도 정보를 기반으로 현시점 사용자 위치를 예측한다.

Urban air mobility (UAM) 등의 초고속 이동단말의 경우 측위 과정에서 단말의 위치가 이미 변경될 수 있다. 따라서, 측위 알고리즘이 사용하는 입력은 지연된 거리 정보이며, 과거 정보만을 기반으로 위치를 추정해야 하는 고난도 측위 문제를 해결해야 한다. 단말 이동성에 대한 수학적 인 동적 모델이 존재하는 경우, 칼만 필터 등의 전통적인 신호처리 알고리즘을 사용할 수 있다. 하지만, 현실적인 이동통신 시스템에서 단말의 동적 모델을 획득하는 것은 불가능하다. 인공지능 측위 방법은 이동성 모델이 필요 없으나, 훈련 데이터와 상이한 테스트 환경에서는 성능이 열화된다.

본 논문에서는 large language model (LLM)을 기반으로 지연된 거리 정보만을 사용하는 새로운 측위 방식을 제안한다. 방대한 데이터로 학습된 LLM은 높은 일반화 능력을 지니고 있어 새로운 입력에 대해서도 적절한 응답을 출력할 수 있다. 새로운 환경에 대한 예시를 프롬프트에 제시하는 in-context learning (ICL) 기법[3]은 별도의 재학습 과정이 없어도 LLM이 새로운 환경에 빠르게 적응하도록 한다. 이러한 기능을 활용하여 이동단말의 지연 거리 정보만을 기반으로 미래 위치를 예측하는 측위 기법을 구축한다. 모의실험을 통해 제안하는 기법의 유효성을 평가한다.

II. 시스템 모델

이동단말의 위치를 삼변측량법으로 추정하기 위해 N 대의 기지국이 존재하는 통신 시스템을 상정한다. 기지국 i 는 파일럿 신호의 received signal strength (RSS)를 기반으로 이동단말과의 거리를 추정한다. 단말의 빠른 이동성 때문에 시간 t ($t = 1, \dots, T$)에서 기지국 i 는 지연된 거리 정보 $d_i[t-1]$ 를 획득한다. 추정 과정의 불확실성을 포함하면 기지국 i 의 시간 t 의 관찰값은 $o_i[t] = d_i[t-1] + \epsilon_i[t]$ 로 주어지며, $\epsilon_i[t]$ 는 평균이 0, 분산이 σ^2 인 가우시안 추정 잡음을 뜻한다.

각 기지국 i 는 H 개의 과거 관찰값들 $o_i[t-H+1:t] = \{o_i[\tau] : \forall \tau = t-H+1, \dots, t\}$ 을 사용하여 현재 단말의 거리 $\hat{d}_i[t]$ 을 다음과 같이 예측한다:

$$\hat{d}_i[t] = \mathcal{L}_i(o_i[t-H+1:t]). \quad (1)$$

이때 $\mathcal{L}_i(\cdot)$ 은 기지국 i 의 거리 예측기를 의미한다. 총 N 대의 기지국에서 추정된 거리 정보들 $\{\hat{d}_i[t] : \forall i\}$ 을 기반으로 삼변측량 기법을 통해 현재 사용자의 2차원 위치 벡터 $\mathbf{x}[t]$ 의 추정값 $\hat{\mathbf{x}}[t]$ 을 도출한다.

III. LLM 기반 측위 방법

본 논문에서는 각 기지국의 거리 예측기 $\mathcal{L}_i(\cdot)$ 을 LLM으로 설계하여 임의의 측위 환경에 대한 확장성을 달성하고자 한다. 상용 LLM의 추론 능력을 극대화하기 위해 ICL 프롬프트 방식을 사용한다[3].

일반적으로 ICL 예시가 많아질수록 LLM의 추론 성능이 향상된다. 그러나 시간 t 에서 기지국 i 가 사용할 수 있는 정보는 지연 거리 관찰값들 $o_i[t-H+1:t]$ 에 한정되어 임의로 데이터 수를 늘릴 수 없다. 이를 위해 시간 윈도우 $W < H$ 로 시계열 관찰값 $o_i[t-H+1:t]$ 을 분할하여 복수의 ICL 예제 데이터 집합을 구성한다. 구체적으로, 시간 t 에서 n 번째 예제 $S_i^{(n)}[t] = (X_i^{(n)}[t], Y_i^{(n)}[t])$ 은 입력 $X_i^{(n)}[t]$ 과 레이블 $Y_i^{(n)}[t]$ 을 포함하도록 다음과 같이 설계한다.

$$\begin{aligned} X_i^{(n)}[t] &= (o_i[\delta_n - W], \dots, o_i[\delta_n - 1]) \\ Y_i^{(n)}[t] &= o_i[\delta_n] \end{aligned} \quad (2)$$

여기서 $\delta_n = t - (H - W - n + 1)$ 이며, 시간 t 에서 기지국 i 는 총 $H - W$ 개의 ICL 예제들 $\{S_i^{(n)}[t] : \forall n = 1, \dots, H - W\}$ 을 LLM에 입력한다. 최종 예측에 필요한 지연 정보 입력 $X_i[t+1]$ 을 제공하고 거리 예측값을 출력하도록 지시한다.

IV. 모의실험 결과

모의실험을 통해 제안하는 LLM 기반 측위 방식의 유효성을 검증한다. 환경이 500m인 원형 셀에서 이동단말이 무작위로 생성된 초기 위치

$\mathbf{x}[0]$ 에서 $T = 240$ 초까지 1초 단위로 위치를 변경한다. 총 $N = 3$ 대의 기지국이 원형 셀 위에 정삼각형 형태로 분포해 있고, 단말은 Gauss-Markov 랜덤 프로세스[4]를 기반으로 이동하여 시간 t 에서의 속도를 시간 $t - 1$ 의 속도를 기반으로 변경한다. 제안하는 LLM 기반 추위 방법의 확장성을 검증하기 위해 단말이 120 초까지는 동일한 패턴으로 이동하다가 그 후 방향을 $[0.6\pi, 0.9\pi]$ 내에서 무작위로 변경한다.

LLM 기법의 추위 오차를 평가하기 위해 다음의 mean absolute error (MAE) 지표를 모의실험으로 계산한다.

$$MAE = E[|\mathbf{x}[t] - \hat{\mathbf{x}}[t]|]. \quad (3)$$

MAE는 총 1,000개의 독립적인 테스트 이동 경로 데이터에 대해 평가한다. 또한, 정량적인 비교를 위해 다음의 세 가지 방법을 고려한다.

- Ideal: 시간 t 에서 기지국이 지연시간 없이 현재의 거리 정보 d_t^i 의 추정값을 직접 관찰할 수 있는 이상적인 상황을 가정하여 제안하는 기법의 MAE 성능 하한을 도출한다.
- Multi-layer perceptron (MLP): 두 개의 계층 및 128개의 은닉 뉴런으로 구성된 MLP를 지도학습으로 훈련한다.
- Gated-Recurrent Units (GRU)[5]: 시계열 데이터에 적합한 GRU를 지도학습 한다. 해당 모델은 두 개의 GRU 계층과 각 128개의 은닉 뉴런, 그리고 단일 완전연결계층을 포함한다.

기존 인공지능 기반 추위 기법의 한계를 파악하기 위해 MLP와 GRU의 훈련 데이터는 120 초까지의 경로들로부터 구성한다.




그림 1 다양한 추위 기법들의 시간에 대한 MAE 성능

그림 1은 다양한 추위 방법들의 평균 MAE 성능을 시간에 따라 도시한 결과이다. 예상했던 대로 ideal 기법의 추위 성능이 가장 좋은 것을 알 수 있다. 제안하는 LLM 기법은 약 6 m의 MAE 성능을 보이다가 단말의 이동 경로가 크게 변화하는 120초 부근에서 큰 오차를 보인다. 그러나 변경된 이동성을 빠르게 파악하여 20 초 내에 다시 6 m 수준의 MAE 성능을 달성한다. 반면, MLP와 GRU는 LLM 대비 큰 오차를 보인다. 초기에 약 7 m의 MAE 성능을 보이지만, 급격한 방향 전이가 발생하는 120초를 기점으로 MAE가 급증하며 경로를 정교하게 추적하지 못한다. 이는 MLP와 GRU는 급격한 환경 변화가 발생하는 120 초 이후 데이터를 학습하지 못하여 과적합 되므로 발생하는 현상이다. 현실적인 이동통신 시스템에서는 단말 이동성의 무작위성이 더욱 커질 것이므로, 인공지능 추위 모델을 모든 가능한 환경에서 훈련하는 것은 현실적으로 불가능하다. 그에 비해 LLM 기법은 추가 학습이 필요 없이 프롬프트에 제공되는 ICL 예제만을 이용하여 새로운 환경에 빠르게 적응이 가능하므로 구현 관점에서 큰 장점을 갖는다.

그림 2는 단말의 실제 이동 경로와 LLM, MLP, GRU로 예측한 추정 경로의 예시를 도시한 결과이다. 그림 2(a)와 그림 2(b)의 예제들에서 이동성에 변화가 없는 초기 120초까지는 두 기법 모두 안정적인 예측 경로를 도출한다. 변화가 발생한 후에도 제안하는 LLM 기법은 실제 경로와

유사한 위치를 예측하는 반면에, MLP와 GRU 방식은 크게 동떨어진 경로를 출력한다. 이들은 학습된 경로 패턴에 대해서는 준수한 추위 성능을 보이나, 새로운 환경에서는 낮은 일반화 능력으로 오차가 크게 발산한다. 이러한 단점을 LLM 기반 추위 방법으로 해결하여 큰 변화가 발생해도 빠르게 적응하여 좋은 위치 추정 결과를 도출함을 확인할 수 있다. 이러한 모의실험들은 이동 경로가 실시간으로 변화하는 실제 무선 통신 환경에서 사전 정의된 학습만으로는 한계가 있으며, 제안하는 LLM 기반 접근이 효과적인 대안이 될 수 있음을 시사한다.

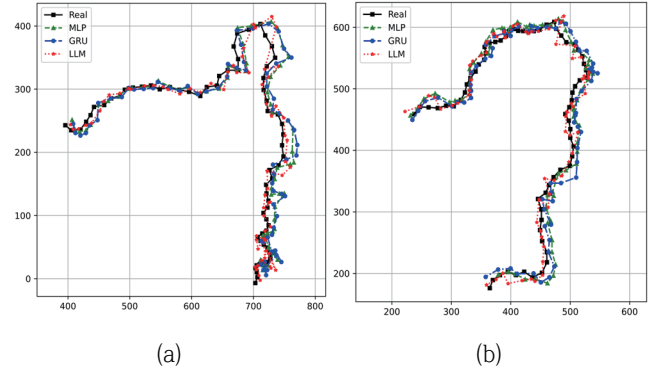


그림 2. 예측 이동 경로와 실제 이동 경로의 비교

V. 결론

본 연구는 LLM의 ICL 기능을 활용한 추위 기법을 소개하였다. 제안하는 기법은 이동성에 대한 수학적 모델 없이 지연된 거리 관찰 정보만을 활용하여 단말의 미래 위치를 높은 정확도로 예측할 수 있다. 특히 LLM 기반 추위 기법은 추가 학습이나 데이터를 요구하지 않으므로 임의의 이동통신 환경에서 미세조정 없이 바로 적용할 수 있을 것으로 예상된다.

ACKNOWLEDGEMENT

이 논문은 2023 년도 정부(과학기술정보통신부) (NRF-2022R1F1A1074009) 및 2021 년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원 (2021-0-00467, 지능형 6G 무선 액세스 시스템)의 지원을 받아 수행된 연구임.

참 고 문 헌

- [1] H. Kim, S. H. Lee, and S. Kim, "Cooperative localization with constraint satisfaction problem in 5G vehicular networks," *IEEE Trans. Intell. Transp. Syst.*, vol. 23, pp. 3180-3189, Apr. 2022.
- [2] H. Lee, H. K. Kim, S. Oh, and S. H. Lee, "Machine learning-aided cooperative localization under a dense urban environment: Demonstrates universal feasibility," *IEEE Veh. Technol. Mag.*, vol. 19, no. 3, pp. 78-89, Sep. 2024.
- [3] T. B. Brown, B. Mann, N. Ryder, M. Subbiah, J. D. Kaplan, P. Dhariwal, A. Neelakantan, et al., "Language models are few-shot learners," Jul. 2020.
- [4] M. Kim, H. Lee, S. Hwang, M. Debbah, and I. Lee, "Cooperative Multiagent deep reinforcement learning methods for UAV-aided mobile edge computing networks," *IEEE Internet Things J.*, vol. 11, no. 23, pp. 38040-38053, Dec. 2024.
- [5] K. Cho et al., "Learning phrase representations using RNN encoder-decoder for statistical machine translation," in *Proc. EMNLP*, Oct. 2014.