

무선채널 환경변화 극복을 위한 딥러닝 기반 실내 측위 기술에 관한 연구

장갑석, 김용선, 고영조

이동통신연구본부, 통신미디어연구소, 한국전자통신연구원

{kschang, doori, koyj}@etri.re.kr

A Study on Deep Learning Based Indoor Positioning Technology for Overcoming the Change of Wireless Channel Environment

Kapseok Chang, Yongsun Kim, and Young-Jo Ko

Electronics and Telecommunications Research Institute

요 약

본 논문은 초정밀 측위 정확도를 얻기 위해 널리 도입되는 딥러닝 지문 기반 측위 방법에 관한 것이다. 종래의 딥러닝 지문 기반 측위 방법은 다중경로 무선채널로 인한 측위 정확도 저하를 효과적으로 해결할 수 있는 기술이지만, 학습을 위한 구축환경의 무선채널과 측위 수행을 위한 실제환경의 무선채널 간 불일치로 인한 측위 정확도 저하가 발생한다. 이러한 불일치 문제를 해결하기 위해 본 논문에서는 지향성 빔 지문 학습 기반 2단계 측위 방법을 제안한다.

I. 서론

현재까지의 이동통신 측위 기술은 수학적 접근 방법으로 모바일 기기나 무선채널에서 수신되는 다양한 신호를 바탕으로 실내 또는 실외 환경에서 사용자의 위치를 파악하였다. 그러나, 수학적 접근 방법의 치명적 문제는 다중경로가 존재할 경우 매우 높은 측위 오차를 보인다는 것이다. 이러한 문제를 해결하는 하나의 수단으로 최근 DL (Deep Learning) 신경망을 적용하고 있다. 측위에 적용된 DL 기술은 대부분 실내 측위를 기반으로 하고 있으며, 기존 지문(fingerprint) 방식을 DL 모델로 학습해 적용하는 것을 특징으로 한다. 지문을 위한 입력 데이터로 CSI (Channel State Information), RSS (Received Signal Strength), CIR (Channel Impulse Response) 또는 Hybrid 정보 등이 사용된다.

RSS 기반 지문 측위의 낮은 정확도 한계를 극복하기 위해, [1]에서는 주파수영역의 CSI 크기와 위상 정보 대신 이를 수학적으로 변형해 얻은 각파 지연 정보를 DL로 학습하는 지문 기법을 제안해 측위 성능을 향상시켰다. 또한, [2]는 Multi-Layer Perceptron을 이용한 실내 측위를 위해 대부분의 곳에 존재하는 자기장과 Wi-Fi를 결합한 지문 위치측위 방식을 수행했다. 이 문헌에서는 실험 결과 모델의 입력에 자기장 정보를 추가하면 Wi-Fi 지문만을 기반한 솔루션과 비교해 30%정도 위치측위 정확도가 향상됨이 관찰되었다. 상기의 종래 DL 지문 기반 측위 기술은 구축환경에서 학습시 사용한 데이터와 실제환경에서 실제 적용시 데이터 간 불일치(또는 상관성 저하)로 인해 측위 성능 저하가 발생할 수 있다. 구축환경에서 우수한 측위 성능을 보이는 딥러닝 학습 모델이라도, 이 환경의 공간에 새로운 고정체/이동체가 유입되어 구축환경에 적용된 무선채널과 상이한 무선채널을 겪는 실제환경에서는 그 측위 성능을 유지할 수 없다. 즉, 새로운 고정체/이동체의 영향이 반영된 수신 신호는 구축환경에 사용된 입력데이터의 일부분이 아닐 수 있으며 이에 의해 측위 성능이 저하될 가능성이 상존한다.

따라서, 특히 사람 또는 사물에 의한 환경변화 등의 영향을 고려해 구축환경의 학습에 사용된 입력데이터와 실제환경의 실제 데이터 간 낮은 상관성(또는 불일치)에 의한 위치측위 정확도 성능 저하를 극복할 수 있는 방법이 필요하다. 본 논문에서는 이에 대한 솔루션으로, 도식과 절차적으로 가독성 있게, 종래 준-전방향 지문 학습 기반 2단계 측위 방법과 차별화되는 지향성 빔 지문 학습 기반 2단계 측위 방법을 제안 기술한다.

II. 준-전방향 지문 학습 기반 2단계 측위 방법

그림. 1과 같이 주어진 대상공간이 기준위치들(즉, 서로 다른 좌표들)로 분할되고 기준 노드는 준-전방향 안테나 시스템을 채용하여 신호를 송신한다고 가정한다.

제 1 단계는 **구축환경에서 학습을 통해 기준위치별 학습모델을 구축한다**. 자세히는, 그림. 1과 같이 기준 노드는 대상공간을 커버하는 준-전방향으로 위치측위를 위한 신호를 송신한다. 이 때, 기준위치 노드는 기준위치를 옮겨 가며 ($n = 1, 2, \dots, N$) 학습을 수행해 기준위치별 학습모델을 구축한다.




그림. 1 구축환경에서의 준-전방향 학습의 개념도

구축환경에서 기준위치별 학습모델을 구축하는 과정은 그림. 2와 하기와 같다.

- ① 기준위치 노드는 기준 노드가 준-전방향으로 전송한 위치측위를 위한 신호를 수신한다.

- ② 기준위치 n 노드는 이 수신신호로부터 RSS(Received Signal Strength), CSI(Channel State Information), Modified CSI, CIR(Channel Impulse Response) 및 자기장 등의 정보를 추출하고 이를 기준위치 n 에 대한 딥러닝 기반 학습모델의 입력데이터로 삼는다. 입력데이터는 시간대별로, 계절별로 및 대상공간의 다양한 사람-사물 환경변화 시나리오별로 수집해 객관성과 가용성을 확보한다.
- ③ 기준위치 n 의 학습모델의 출력 y_n 이 1이 되도록 하는 학습을 수행해 기준위치별 학습모델을 구축한다.

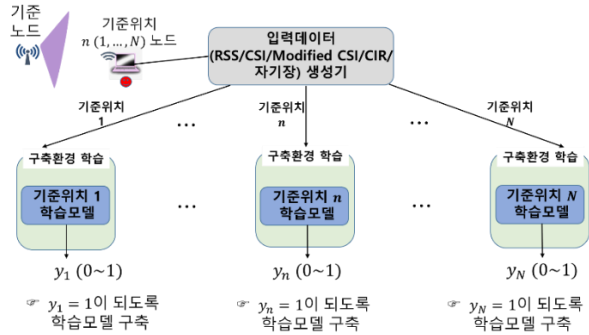


그림.2 구축환경에서의 기준위치별 학습모델 구축 과정

제 2 단계는 실제환경에서 구축된 학습모델을 적용해 측위를 수행하고, 주기적으로 또는 Event-driven 으로 학습모델을 업데이트한다.

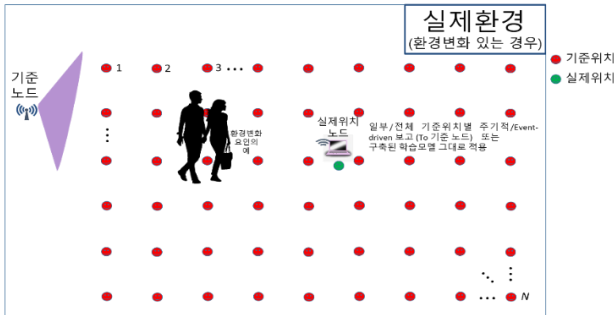


그림.3 실제환경에서의 준-전방향 학습의 개념도

그림. 3 과 같이 실제환경에서 기준 노드는 대상공간을 커버하는 준-전방향으로 위치측위를 위한 신호를 송신하고 이를 실제위치 노드가 수신한다. 그림. 4 를 바탕으로 실제위치 노드의 측위 결과 도출 과정을 하기와 같이 기술한다.

- ① 실제위치 노드는 기준 노드로부터 송신된 신호로부터 그림. 2 에서 언급한 학습모델의 입력데이터를 추출한다.
- ② 그림. 4 와 같이 기준위치 1 부터 기준위치 N 까지의 학습모델들에 상기에서 추출한 입력데이터를 유입시켜 학습모델별 출력치 \hat{y}_n ($n = 1, 2, \dots, N$)을 생성한다.
- ③ 그림. 4 와 같이 생성된 출력치들을 위치측위 추정기에 유입시켜, 식(1)에서 보는 바와 같이, 기준위치 n 의 좌표와 \hat{y}_n 간 곱셈을 모든 기준위치들에 대해 수행한 다음 이들을 모두 더해 실제위치 노드의 위치(또는 좌표)를 측위한다.

$$\text{실제위치 노드의 위치(좌표)} = \sum_{n=1}^N \{\hat{y}_n \times (\text{좌표})_n\} \quad (1)$$

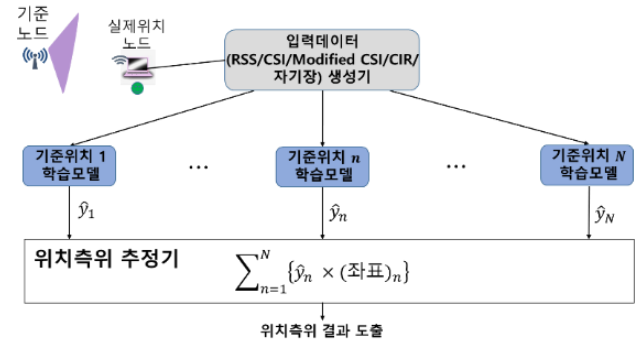


그림.4 실제환경에서의 준-전방향 기반 측위 도출 과정

그림. 3 과 같이 실제로는 구축환경과 달리 예기치 않게 온도가 변하거나 구축환경에서 고려치 않은 사람/사물에 의해 환경변화가 생긴다. 이 경우 기준 노드와 실제위치 노드 간 환경변화가 특정한 방향에만 생긴다고 하더라도 기준 노드가 준-전방향으로 신호를 송신하기 때문에 실제위치 노드에서의 수신 신호로부터 추출된 입력 데이터는 상기 환경변화의 영향으로 구축환경에 사용된 입력 데이터와의 상관성이 낮아져 실제환경의 측위 성능이 저하되는 문제가 상존한다.

III. 지향성 빔 지문 학습 기반 2 단계 측위 방법

본 장에서 제안하는 방법은 구축환경에서 빔별로 학습모델을 구축하고 실제환경에서 환경변화가 없는 빔을 선택해 측위함으로써 환경변화에 의한 성능 저하를 극복하는 방법이다. 그림. 5 와 같이 주어진 대상공간이 기준위치들(즉, 서로 다른 좌표들)로 분할되고 기준 노드는 지향성 빔을 생성할 수 있는 일련의 어레이(array) 안테나 시스템을 채용하여 신호를 송신한다고 가정한다.

제 1 단계는 구축환경에서 학습을 통해 빔별/기준위치별로 학습모델을 구축하며, 자세한 내용은 하기와 같다.

- ① 그림. 5 와 같이 기준 노드는 대상공간을 커버하는 빔들(빔₁, ..., 빔_m, ..., 빔_M)을 생성한다.
- ② 그림. 5 와 같이 기준 노드는 빔을 스위핑(sweeping)하며 빔을 송신하고, 기준위치 노드는 빔별로 기준위치를 옮겨 가며($n = 1, 2, \dots, N$) 학습을 수행해 빔별/기준위치별 학습모델을 구축한다.

구축환경에서 학습을 통해 기준위치별로 학습모델을 구축한다. 자세한, 그림. 5 와 같이 기준 노드는 대상공간을 커버하는 준-전방향으로 위치측위를 위한 신호를 송신한다. 이 때, 기준위치 노드는 기준위치를 옮겨 가며($n = 1, 2, \dots, N$) 학습을 수행해 기준위치별 학습모델을 구축한다.




그림.5 구축환경에서의 지향성 빔 학습의 개념도

구축환경에서 지향성 빔별/기준위치별 학습모델을 구축하는 과정은 그림. 6 과 하기와 같다.

- ① 기준위치 노드는 기준 노드가 지향성 빔_m 으로 전송한 위치측위를 위한 신호를 수신한다.
- ② 기준위치 n 노드는 이 수신신호로부터 RSS, CSI, Modified CSI, CIR 및 자기장 등의 정보를 추출하고 이를 기준위치 n 에 대한 딥러닝 기반 학습모델의 입력데이터로 삼는다.
- ③ 입력데이터는 시간대별로, 계절별로 및 대상공간의 다양한 사람-사물 환경변화 시나리오별로 수집해 객관성과 가용성을 확보한다.
- ④ 그림. 6 과 같이 빔_m 에서 기준위치 n의 학습모델의 출력 $y_{n,m}$ 이 1 이 되도록 하는 학습을 수행해 빔별/기준위치별 학습모델을 구축한다.

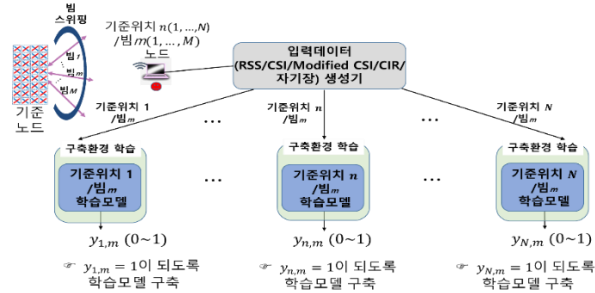


그림. 6 구축환경에서의 지향성 빔 학습모델 구축 과정

제 2 단계는 실제환경에서 구축된 학습모델을 적용해 지문 기반 위치측위를 수행하고, 주기적으로 또는 Event-driven 으로 학습모델을 업데이트한다.




그림. 7 실제환경에서의 지향성 빔 학습의 개념도

그림. 7 과 같이 실제환경에서 기준 노드는 대상공간을 커버하는 빔들을 스와핑으로 위치측위를 위한 신호를 송신하고 이를 실제위치 노드가 수신하고 환경변화가 있는 시나리오를 상정해 그림. 8 을 바탕으로 실제위치 노드의 위치측위 결과를 도출하는 과정을 하기와 같이 기술한다.

- ① 실제위치 노드는 기준 노드로부터 지향성 빔_m 으로 송신된 신호로부터 그림. 2 의 설명에서 언급한 학습모델의 입력데이터를 추출한다.
- ② 그림. 8 과 같이 기준위치 1 부터 기준위치 N까지의 학습모델들에 상기에서 추출한 입력데이터를 유입시켜 빔별/학습모델별 출력치 $\hat{y}_{n,m}$ ($n = 1, \dots, N$, $m = 1, \dots, M$)을 생성한다.
- ③ 그림. 8 과 같이 $\hat{y}_{n,m}$ ($n = 1, \dots, N$, $m = 1, \dots, M$)을 빔선택기에 유입시켜 하기와 같은 방법들 중 하나로 환경변화의 영향을 가장 덜 받는 단일/다수 빔/빔들을 선택한다.

방법 1 에서, 다음의 식에 의해 하나의 빔 m^* 을 선택하고, 선택된 빔에 대한 기준위치별 학습모델 출력치 \hat{y}_{n,m^*} 를 위치측위 추정기로 전달한다.

$$\begin{aligned} \text{선택된 빔 인덱스: } m^* &= \arg \max_{m=1, \dots, M} \{ \sum_{n=1}^N \hat{y}_{n,m} \} \\ \text{선택된 기준위치별 학습모델 출력치: } \hat{y}_{n,m^*} \end{aligned} \quad (2)$$

방법 2 에서, 다음의 식에 의해 그룹의 빔 m_g 를 선택하고, 선택된 빔들에 대한 기준위치별 학습모델 출력치 \hat{y}_{n,m_g} ($n = 1, \dots, N$, $g = 1, \dots, G$) 를 위치측위 추정기로 전달한다.

$$\begin{aligned} \text{선택된 다수 빔 인덱스들: } m_g \ (g = 1, \dots, G): \\ \{ \sum_{n=1}^N \hat{y}_{n,m_g} \} \text{이 가장 높은 } G \text{ 개의 빔 들의 인덱스들} \\ \text{선택된 빔별/기준위치별 학습모델 출력치: } \hat{y}_{n,m_g} \end{aligned} \quad (3)$$

- ④ 그림. 8 과 같이 상기 \hat{y}_{n,m^*} ($n = 1, \dots, N$) 또는 \hat{y}_{n,m_g} ($n = 1, \dots, N$, $g = 1, \dots, G$) 를 위치측위 추정기에 유입시켜, 다음 식에 의해 실제위치 노드의 위치(좌표)를 측위한다.

$$\begin{aligned} \text{실제위치 노드의 위치(좌표)} &= \sum_{n=1}^N \{ \hat{y}_{n,m^*} \times (\text{좌표})_n \} \\ &\text{또는 } \sum_{n=1}^N \sum_{g=1}^G \{ \hat{y}_{n,m_g} \times (\text{좌표})_n \} \end{aligned} \quad (4)$$

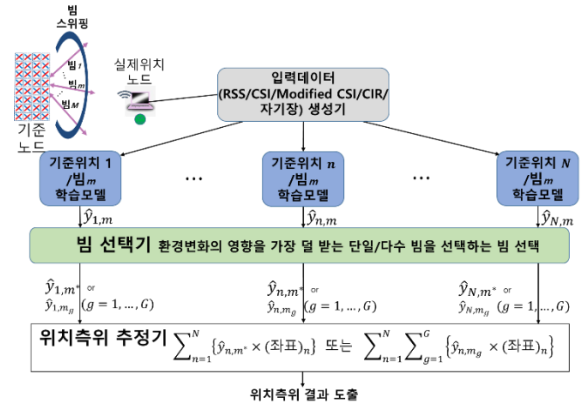


그림. 8 실제환경에서의 지향성 빔 기반 측위 도출 과정

IV. 결론

본 논문에서 제안하는 지문 학습 기반 측위 방법은 구축환경에서 빔별로 학습을 수행하고 이들 중 하나 또는 그룹을 실제환경의 측위에 채용하기 때문에 구축환경과 실제환경의 입력 데이터 간에 낮은 상관성이 발생하더라도 초정밀 측위를 실현할 수 있으므로 향후 성능 평가와 이론적 분석을 통해 이를 입증할 예정이다.

ACKNOWLEDGMENT

이 논문은 2023 년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임 (No.2018-0-00218, 초고주파 이동통신 무선백홀 전문연구실)

참고문헌

- [1] J. Vieira, E. Leitinger, M. Sarajlic, X. Li, and F. Tufvesson, "Deep convolutional neural networks for massive MIMO fingerprint-based positioning," in *Proc. PIMRC*, Montreal, Canada, 2017.
- [2] W. Zhang, R. Sengupta, J. Fodero, and X. Li, "DeepPositioning: Intelligent fusion of pervasive magnetic field and WiFi fingerprinting for smartphone indoor localization via deep learning," in *Proc. ICMLA*, pp. 7-13, 2017.