

터널 내 딥러닝 기반 BLE RSSI 차량 측위

정기원, 장준영* 김민석**

충남대학교, *(주)와이파이브, **충남대학교

kwjung2571@o.cnu.ac.kr, *wkdwnsdud25@wifive.co.kr, **kms4105@cnu.ac.kr

Deep Learning-Based BLE RSSI Vehicle Localization in Tunnels

Jung Ki Won, Jang Jun Yeong, Kim Min Seuk**

Chungnam National Univ., *WiFive Co.,Ltd. **Chungnam National Univ.

요약

본 논문에서는 GPS (Global Positioning System) 음영 지역인 터널 내 정확한 차량 위치 추정을 위해, 저비용 BLE(Bluetooth Low Energy) 인프라와 딥러닝을 결합한 측위 시스템을 제안한다. 제안하는 시스템은 BLE RSSI (Received Signal Strength Indicator) 를 입력으로 MLP (Multi-Layer Perceptron) 모델을 학습시키고, 필터링을 적용하여 예측 안정성을 향상시켰다. 실험 결과, 평균 예측 오차 2.17 m 를 달성하였다. 본 연구를 통해 BLE 인프라와 딥러닝 및 필터링 결합이 GPS 음영 지역에서 신뢰성 높은 차량 측위 솔루션이 될 수 있음을 입증하였다.

I. 서론

자율주행 기술이 발전함에 따라, GPS 음영 지역에서 정밀 위치 정보 확보는 핵심 요구사항이 되었다. 본 연구는 저비용 BLE 인프라와 딥러닝 기술을 결합하는 새로운 접근법을 제안한다. BLE RSSI 를 fingerprinting 하여 위치를 추정하는 시스템 구축을 목표로 하며, 핵심 기여는 다음과 같다.

1. 통신 신호의 결측치 신호 간의 다변수 상관관계를 고려하는 MICE (Multivariate Imputation by Chained Equation) 보간법을 적용하여 입력 데이터의 신뢰도를 높였다.

2. 이미지나 텍스트와 같은 정형화된 데이터가 아닌, 통신 네트워크 데이터 (BLE RSSI) 를 딥러닝 모델의 입력으로 직접 활용하여 복잡한 비선형 관계를 학습(training) 하고 위치를 추정하는 시스템을 설계했다.

3. 딥러닝 모델의 출력에 포함된 outlier 를 완화하기 위해 후처리 필터링을 도입하여, 최종 결과의 안정성과 신뢰도를 크게 개선하였다.

본 연구에서는 실내에서 수 cm 수준의 높은 정밀도를 제공하는 UWB (Ultra-WideBand) 를 Ground Truth 로 활용하여 [1] 불안정한 BLE 신호만으로도 높은 측위 정확도를 달성하고, 비용 효율성과 정확도를 모두 만족하는 터널 내 차량 측위 솔루션을 제시한다.

II. 본론

본 연구에서 제안하는 측위 시스템은 데이터 전처리, 딥러닝 모델링, 후처리 필터링의 3 단계로 구성된다. 본 시스템은 "차량의 주행 상황과 관계없이, 특정 물리적 위치에서는 고유한 BLE RSSI fingerprint 가 형성될 것이다"라는 핵심 가정을 기반으로 한다. 이 가정의 타당성을 검증하기 위해 10 kph 등속 주행 데이터를 BLE RSSI 히트맵으로 시각화한 결과, 차량 이동에 따라 밝은 신호 강도가 대각선 패턴으로 순차적으로 나타나는 것을 확인했다[그림 1]. 이는 차량의 이동에 따른 물리적

거리 변화가 RSSI 신호 패턴에 명확히 반영됨을 의미한다.




그림 1. 10kph 등속주행 BLE RSSI 히트맵

2.1 데이터 전처리

결측치 처리 단계에서는 다양한 주행 시나리오에 걸친 앵커 신호 간의 전역적 correlation 학습을 위해 모든 데이터를 통합 데이터셋으로 구축하고, 머신러닝 회귀 모델 기반의 MICE 기법을 사용했으며 이는 결측치가 있는 각 변수(앵커)를 정답(y)으로, 나머지 모든 관측된 변수들을 입력 특징(X)으로 삼는 예측 모델을 구축한다. 약 25,000 개의 훈련 데이터를 활용하여 각 앵커 신호 간의 복잡한 correlation 모델 (Imputer) 을 학습시켰다.

2.2 딥러닝 모델링 및 평가

본 연구의 측위 모델로는 MLP 을 채택하였다. 모델의 구조는 [입력층 - 은닉층 1(128) - 은닉층 2(64) - 은닉층 3(32) - 출력층(2)]으로 구성된다. 각 은닉층 다음에는 ReLU 활성화 함수를 사용하여 비선형성을 부여하였고, 배치 정규화와 Dropout (p=0.3) 을 순차적으로 적용하여 학습 과정을 안정시키고 모델의 과적합을 방지하였다.

모델의 성능은 식 (1) 과 같이 UWB Ground Truth $p_{true} = (X_{true}, Y_{true})$ 와 모델의 예측 좌표 $p_{pred} = (X_{pred}, Y_{pred})$ 간의 유클리드 거리 오차 $d(p_{true}, p_{pred})$ 를 기반으로 평가하였다.

$$d(p_{true}, p_{pred}) = \sqrt{(X_{true} - X_{pred})^2 + (Y_{true} - Y_{pred})^2} \quad \dots \quad (1)$$

2.3 데이터 후처리

딥러닝 모델의 원시 예측 경로는 BLE RSSI 의 노이즈로 인한 급작스러운 위치 변동이나 역방향 이동 등 물리적으로 불가능한 현상을 포함할 수 있다. 이를 보정하는 후처리 필터링은 측위 시스템의 신뢰도와 안정성 향상에 필수적이다[2].

본 연구에서는 순차적 필터링 기법을 적용했다. 먼저 중앙값 필터를 적용하여 outlier 를 효과적으로 제거하고 그 다음으로 이동평균 필터를 통해 잔여 노이즈를 감소시키고 평활화된 경로를 생성하였다.

시점 t 에서의 원본 예측 좌표를 $p_t = (X_t, Y_t)$ 라고 할 때, 중앙값 필터를 거친 좌표 p'_t 는 식 (2) 와 같다.

$$p'_t = \text{median}\{p_{t-k_1}, \dots, p_t, \dots, p_{t+k_1}\} \quad \dots (2)$$

k_1 은 중앙값 필터의 윈도우 절반 크기이며, 전체 윈도우 크기는 $N_1 = 2k_1 + 1$ 로 정의된다. 본 연구에서는 $N_1 = 10$ 으로 설정하였다. 다음으로 이동 평균 필터를 거친 최종 예측 좌표 p''_t 는 식 (3) 와 같이 계산된다.

$$p''_t = \frac{1}{N_2} \sum_{i=-k_2}^{k_2} p'_{t+i} \quad \dots (3)$$

여기서 k_2 는 이동평균 필터의 윈도우 절반 크기이며 $N_2 = 2k_2 + 1$ 은 전체 윈도우 크기를 의미한다. $N_2 = 15$ 로 설정하였다. 두 필터의 순차적 적용을 통해 outlier 제거와 경로 평활화를 달성하며, 작은 윈도우 크기 설정으로 실시간 적용이 가능하도록 하였다.

2.4 실험 환경 및 데이터 수집




그림 2. 실험 환경

본 연구의 데이터 수집은 폭 9.1 m, 길이 475 m 의 실제 터널에서 수행되었다. 터널 한쪽 벽면을 따라 30 m 간격으로 설치된 4 개의 다방향 BLE 앵커(각 2 개 안테나) [3]로부터 RSSI 신호를 받아 총 8 차원 특징 벡터를 구성하였다. Ground Truth 는 UWB 앵커를 이용해 확보하였으며, 이는 모델이 예측해야 할 2 차원 (X,Y) 의 위치정보로 사용되었다. 7.5×60 m 의 측위 구간 내에서 10, 20, 30, 40 kph 정속 및 가·감속 등 다양한 시나리오로 차량을 주행하며 데이터를 수집하였고 이 과정을 통해 각 샘플이 8 차원의 RSSI 벡터와 2 차원의 좌표로 구성된, 총 25,000 개의 데이터셋을 구축하여 MLP 모델 학습에 사용하였다.

2.5 실험 결과

본 연구에서 제안한 측위 시스템의 성능을 검증하기 위해 딥러닝 모델 학습에 사용되지 않은 10 kph 등속 주행 데이터셋으로 제안 모델의 일반화 성능을 평가하였다. 실험 결과, 결측치 처리를 수행하지 않은 원본 데이터로 학습한 모델의 평균 예측 오차는 3.47 m 였다. 이는 상이한 주행 조건의 데이터가 혼재함에도

불구하고, 모델이 위치별 공통 신호 패턴을 성공적으로 학습했음을 시사하며, 핵심 가설의 타당성을 입증한다.




그림 3 MICE 보간법 적용 후 CDF

더 나아가, MICE 보간법을 적용한 데이터로 학습한 모델의 경우, 평균 예측 오차가 3.3 m 로 약 4.6 % 로 개선되었다. 전체 예측의 90 % 지점 오차는 원본 데이터 모델의 7.26 m 에서 6.46 m 로 약 11 % 감소하였다. [그림 3] 이후 예측 경로에 중앙값 필터와 이동평균 필터를 순차 적용한 결과 최종 평균 예측 오차는 2.17 m 로 크게 개선되었다. 중앙값 오차는 2.35 m에서 1.8 m로 23.4 % 감소하였고, 90 % 오차는 6.46 m에서 4.31 m로 33.3 % 감소하였다. [그림 4] 이는 제안된 필터링 기법이 시스템의 안정성과 신뢰도를 크게 향상시킨다는 것을 알 수 있다.




그림 4 필터링 후 CDF

III. 결론

본 연구는 차량의 주행 조건과 무관하게, “특정 물리적 위치에서는 고유한 BLE RSSI fingerprint 가 형성된다”는 핵심 가설을 검증하는 것을 목표로 하였다. 실험 결과, 10-40 kph 의 다양한 속도 및 가감속 시나리오로 학습된 모델이 최종 평균 예측 오차 2.17 m 를 보임으로써 위 가설을 성공적으로 입증하였다. 특히 별도의 센서 퓨전 없이, BLE 신호만으로 안정적인 결과를 얻었다는 점에서 그 실용적 가치가 높다고 할 수 있다.

ACKNOWLEDGMENT

본 연구는 충남대학교 학술연구비에 의해 지원되었음

참 고 문 헌

- [1] PS Farahsari, A Farahzadi, J Rezazadeh, A Bagheri, A survey on indoor positioning systems for IoT-based application, IEEE Internet of Things Journal, 2022
- [2] Z Zhang, J Liu, L Wang, G Guo, X Zheng, X Gong, An enhanced smartphone indoor positioning scheme with outlier removal using machine learning, Remote Sensing, 2021 - mdpi
- [3] 성태경, “실내위치 측정시스템 및 측정 방법”. 대한민국 특허권 2616631, 18 12 2023.