

시퀀스 위치 데이터를 활용한 CRNN 기반 실내외 위치 판단 기법

박연석*, 이채원, 최동욱, 박찬영
KT 기술혁신부문

{*yeonseok.park, lee.chaewon, matthew.choi, chanyeong.park}@kt.com

Indoor-Outdoor Classification Based on CRNN Model Using Sequential Location Data

Yeonseok Park*, Chaewon Lee, Dongwook Choi, Chanyeong Park
Tech Innovation Division, Korea Telecom

요약

모바일 단말기의 실내외 여부를 정확하게 판단하는 기술은 위치 기반 서비스(LBS)의 성능 향상에 핵심적인 역할을 한다. 기존에는 GNSS 또는 Wi-Fi 신호에만 의존하는 방식이 주류였으나, 실내외 경계 지역에서는 정확도에 한계가 존재한다. 본 연구에서는 GNSS, Wi-Fi 등 다양한 위치 측위 기술로부터 수집한 좌표 데이터를 지구 중심 고정 좌표계(ECEF)로 변환하고, 이를 시퀀스 형태의 텐서로 구조화하였다. 이후 CNN의 공간적 특징 추출과 RNN의 시간적 패턴 학습을 결합한 CRNN 모델을 설계하여 실내외 이진 분류를 수행하였다. 실험 결과, CRNN 모델은 테스트 데이터 기준 93.64%의 정확도를 기록하였고, 실내외 경계 지역에서도 우수한 분류 성능을 안정적으로 유지하였다.

I. 서 론

정밀 위치 측위 기술은 자녀 보호, 물류 관리, 긴급 구조 등 다양한 분야의 위치 기반 서비스(LBS, Location-Based Service)에서 핵심적인 역할을 한다. 특히 GNSS(Global Navigation Satellite System)와 Wi-Fi 기반의 위치 측위 시스템은 가장 널리 활용하는 기술이지만, 실내 환경에서는 GNSS 신호가 약화되고 실외에서는 Wi-Fi 신호가 불안정해지는 문제가 있다. 또한 건물 출입구나 창문 근처와 같은 실내외 경계 지역에서는 두 신호가 동시에 감지되거나 불안정하여 정확한 실내외 위치 판단이 어렵다.

이러한 한계를 극복하기 위해, 머신러닝 기반의 실내외 인식 기술 [1]과 스마트폰 기반의 연속 실내외 추정 기법 [2] 등이 제안되어 왔다. 그러나 기존 연구들은 주로 단일 시점의 위치 정보나 단일 센서 기반 접근에 머무르며, 시간적 연속성을 고려하지 않는다는 한계가 있다.

본 연구에서는 GNSS와 Wi-Fi 등 다양한 위치 측위 기술부터 수집한 데이터를 시퀀스 형태로 구성하고, 이를 입력으로 활용하는 CRNN(Convolutional Recurrent Neural Network) 기반 실내외 위치 판단 모델을 제안한다. CRNN 모델은 CNN을 통해 시점별 공간적 특징을 추출하고, RNN을 통해 시간 흐름에 따른 패턴을 학습함으로써, 연속된 위치 데이터를 효과적으로 분류할 수 있는 구조이다 [3]. 본 연구의 목표는 이러한 모델을 통해 실내외 경계 지역에서도 높은 정확도를 유지하는 실내외 위치 판단 시스템을 구현하는 것이다.


II. 방법론

2.1 데이터 수집

본 연구는 2021년부터 2023년까지 품질 테스트를 위해 수집한 실제 위치 측위 데이터를 기반으로 한다. 데이터는 모바일 단말기를 특정 위치에 고정한 상태에서 수집되었으며, 각 측정 지점마다 GNSS, Wi-Fi 등 총 5종의 위치 측위 기술을 활용하여 최소 50회 이상 반복 수집하였다. 다양한 환경의 실내외 조건을 반영하기 위해 지하주차장, 건물 외부, 창가 등 여러 장소에서 데이터를 확보하였다.

2.2 데이터 전처리

수집된 지리 좌표(위·경도)는 지구 중심 고정 좌표계인 ECEF(Earth-Centered Earth-Fixed)로 변환하였다 [4]. ECEF 좌표계는 위·경도 기반 시스템의 한계를 보완하며, 벡터 연산에 유리한 특징을 가진다. 변환된 좌표는 각 위치 측위 알고리즘별로 연속된 10개의 위치 정보를 시퀀스로 구성하고, 이를 모델 학습에 적합한 형태로 전처리하였다.



2.3 데이터 구조화

그림 1에 제시된 바와 같이, 최종 입력 데이터는 시퀀스 길이 10, 위치 측위 알고리즘 5종, ECEF 좌표 성분 3개로 구성된 3차원 텐서 형태로 구조화된다. 이 구조는 시퀀스, 알고리즘, 좌표 성분의 세 축으로 구성되며, RGB 이미지의 공간 배열과 유사한 형태로 CNN 기반 신경망이 다차원적인 시공간 패턴을 효과적으로 학습할 수 있도록 한다. 모든 입력 데이터는 ECEF 좌표의 각 성분(x, y, z)에 대해 평균과 표준편차를 기준으로 표준화하였다. 이를 통해 모델 학습의 안정성과 수렴 속도를 향상시킬 수 있었다.

2.4 CRNN 모델




그림 2. CRNN 모델 구조

그림 2는 실내외 위치 판단을 위해 설계한 CRNN 모델 구조를 도식화한 것이다 [3]. 모델의 입력은 시퀀스 길이 10, 5개의 위치 측위 알고리즘, 그리고 3개의 ECEF 좌표 성분으로 구성된 3차원 텐서이다.

Convolutional Layers는 2개의 2D CNN 레이어로 구성되며, 위치 측위 알고리즘 축에 대해 합성곱 연산을 수행함으로써 각 시점에서 128차원의 특징 벡터를 시퀀스 축을 따라 유지하면서 추출한다. Recurrent Layers는 2개의 Bidirectional GRU(Gated Recurrent Unit) 레이어로 구성되어, 양방향 시간 흐름에 따른 위치 패턴을 학습한다. 마지막으로, Fully Connected Layers를 통해 실내(1) 또는 실외(0) 클래스로 이진 분류를 수행한다.

III. 실험 결과 및 성능

3.1 데이터셋 구성

본 연구에서는 총 4,730개의 시퀀스 데이터가 구성하였고, 이 중 3,406개는 학습용, 852개는 검증용, 472개는 테스트용으로 분할하여 사용하였다. 실내 데이터는 실외보다 상대적으로 적게 수집되었기 때문에, 실내 시퀀스 데이터를 생성하는 과정에서 일정 간격의 중첩(overlapping) 기법을 적용하여 데이터 양을 보완하였다. 이를 통해 클래스 간 데이터 불균형 문제를 완화하고, 모델 학습 과정에서의 편향을 최소화하였다.

3.2 성능 평가

		Predicted Class	
True Class	Indoor	230	11
	Outdoor	20	211

그림 3. 테스트 데이터에 대한 Confusion Matrix

테스트 세트에 대한 평가 결과, 제안한 CRNN 모델은 93.64%의 정확도를 기록하였다. 그림 3에 제시된 Confusion Matrix 분석 결과, 실내 데이터 244개 중 230개(95.4%), 실외 데이터 231개 중 211개(91.3%)를 정확하게 분류되어, CRNN 모델의 실내외 위치 판단 성능을 입증하였다. 전반적으로, 제안한 모델은 다양한 환경에서도 실내외를 효과적으로 구분하는 높은 정확도와 우수한 일반화 성능을 입증하였다.

IV. 결론

본 연구는 다양한 위치 측위 알고리즘으로부터 수집한 데이터를 시퀀스 형태로 구조화하고, 이를 CRNN 모델을 통해 학습하여 실내외 위치 판단 정확도를 향상시키는 방법을 제안하였다. 제안한 모델은 단일 신호 기반 접근 방식의 한계를 극복하고, 실내외 경계 지역에서도 높은 정확도와 우수한 분류 성능을 보였다. 특히 CRNN 구조는 시공간적 특성을 동시에 학습할 수 있어, 위치 데이터의 시간적 연속성과 복잡한 패턴을 효과적으로 반영할 수 있음을 확인하였다.

다만, 실내 위치 좌표에 대한 라벨링은 여전히 어려운 과제로 남아 있다. 향후에는 수집이 용이한 실외 데이터를 기반으로 Autoencoder를 활용한 이상 탐지 기반 AI 기법을 적용하고, 이를 통해 간접적인 실내 추론 또는 보완적 분류 기능을 수행하는 하이브리드 실내외 위치 판단 시스템으로의 확장을 검토할 예정이다.

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)

참 고 문 헌

- [1] M. Mallik, A. K. Panja, and C. Chowdhury, "Paving the way with machine learning for seamless indoor-outdoor positioning: A survey," *Information Fusion*, vol. 94, pp. 126-151, 2023.
- [2] H. S. Maghdid, I. A. Lami, K. Z. Ghafoor, and J. Lloret, "Seamless outdoors-indoors localization solutions on smartphones: Implementation and challenges," *ACM Computing Surveys*, vol. 48, no. 4, 2016.
- [3] B. Shi, X. Bai, and C. Yao, "An end-to-end trainable neural network for image-based sequence recognition and its application to scene text recognition," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 39, no. 11, pp. 2298-2304, 2016.
- [4] J. Van Sickle, *Basic GIS Coordinates*. Boca Raton, FL: CRC Press, 2004.