

자기장 맵을 이용한 딥러닝 기반의 실내 초기 층 탐지

조재호, 윤성준, 김진우, 신요안*

승실대학교 전자정보공학부

wkatalf8888@soongsil.ac.kr, tjdwns2214@soongsil.ac.kr, jwkim1016@soongsil.ac.kr, *yashin@ssu.ac.kr

(*교신저자)

Deep Learning-based Initial Floor Detection in Indoor Environments Using Magnetic Field Maps

Jae-Ho Cho, Seong-June Yoon, Jin-Woo Kim, and Yoan Shin*

School of Electronic Engineering, Soongsil University

(*Corresponding author)

요약

본 논문에서는 기압계 센서 데이터 기반 층 탐지의 한계를 극복하기 위해, 스마트폰의 지자기 센서를 활용한 자기장 맵과 딥러닝을 사용한 초기 층 탐지 기법을 제안한다. 슬라이딩 윈도우 기법과 데이터 증강 기법을 통해 방향 변화에 강건한 자기장 시퀀스를 구성하였으며, 이러한 시계열 시퀀스를 딥러닝 모델을 통해 학습 후 실험 및 검증함으로써 실내 환경에서의 초기 층을 정확히 구분 가능함을 확인하였다.

I. 서 론

최근 스마트폰을 이용한 실내 측위 (Indoor Localization) 연구에서는 외부 인프라 없이, 스마트폰에 내장된 관성 측정 장치 (Inertial Measurement Unit; IMU) 센서만을 이용하여 위치를 측위하는 보행자 관성 항법 (Pedestrian Dead Reckoning; PDR) 기술이 활발히 연구되고 있다 [1]. 이러한 실내 측위 환경에서 다층 구조의 건물에서는 사용자의 2차원 위치뿐만 아니라 정확한 층수까지 동시에 탐지할 수 있는 기술이 요구된다.

일반적으로 실내에서의 층 탐지는 스마트폰의 기압계 (Barometer)를 이용하여 사용자의 고도 변화를 감지하는 방식으로 이루어진다[2]. 하지만 기압계 센서는 대기압의 변화에 민감하게 반응하기 때문에, 동일한 층에서 데이터를 수집하더라도 날씨, 온도, 시간 등의 외부 환경 요인에 따라 측정값이 달라질 수 있다. 이러한 특징으로 인해 기압계 센서를 활용한 층 탐지 방식은 층간 이동을 감지하는 데는 유용하지만, 사용자의 초기 층 위치를 정확히 파악하는 데 한계가 존재한다. 따라서, 기압계 센서 기반의 층수 탐지 기술은 초기 층 정보를 정밀하게 추정할 수 있는 기술과의 결합이 필수적이다.

본 논문에서는 이러한 한계를 극복하기 위해, 각 층에서 수집한 자기장 센서 데이터를 기반으로 자기장 맵을 구축하고, 이를 딥러닝 모델에 학습시켜 사용자의 현재 층을 정확하게 탐지하는 딥러닝 기반 초기 층 탐지 기법을 제안한다.

으며, 모든 층에서 동일하게 130걸음의 데이터를 확보하였다.

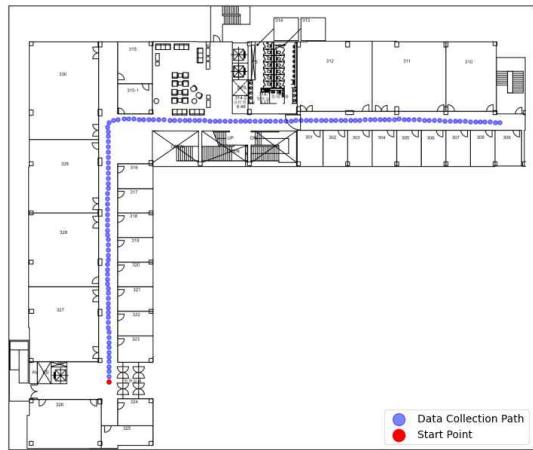


그림 1. 자기장 데이터 수집 경로

지자기 센서는 지구 자기장의 방향과 크기를 3차원 벡터 형태로 측정한다. 그러나 스마트폰의 방향이 변할 경우, 동일한 위치에서도 지자기 벡터의 구성 요소가 달라지므로, 방향에 따라 측정값이 달라질 수 있다[3]. 이로 인해, 자기장 맵 수집 경로의 반대 방향에서 데이터를 수집할 경우, 모델이 해당 층의 특성을 제대로 인식하지 못할 가능성이 있다. 이를 보완하기 위해, 본 연구에서는 기존 자기장 시퀀스를 역순으로 구성한 반대 방향 시퀀스를 추가 생성하여, 모델이 양방향 경로에 모두 대응할 수 있도록 데이터를 증강하였다. 또한, 각 시퀀스에 대해 ± 10 도 범위 내에서 무작위 회전 변환을 적용하여, 방향 변화에 대한 모델의 강건성을 향상시켰다. 이러한 데이터 증강 과정을 통해 각 층마다 총 60개의 자기장 시퀀스를 생성하였으며, 이 중 30개는 반대 방향 시퀀스로 구성하였다.

슬라이딩 윈도우 (Sliding Window) 기법은 시계열 데이터를 일정한 길이의 구간으로 분할하여, 딥러닝 모델이 시간적 패턴을 효과적으로 학습할 수 있도록 하는 기법이다[4]. 본 연구에서는 증강된 자작장 시퀀스에

대해 윈도우 크기 10, 이동 간격 1프레임을 적용하여 시계열 데이터를 생성하였다. 이때 생성된 각 시퀀스는 길이 10의 연속된 3차원 자기장 벡터로 구성된다. 슬라이딩 윈도우를 적용한 결과, 총 7,260개의 자기장 시퀀스가 생성되었으며, 3층부터 7층까지 총 5개 층에 대해 36,300개의 학습 시퀀스를 확보하였다. 모든 시퀀스는 (10, 3) 형태의 입력 데이터로 구성되며, 각 층의 자기장 시퀀스에는 해당 층을 나타내는 고유 클래스 라벨을 부여하였다. 생성된 전체 데이터는 학습, 검증, 테스트 세트로 8:1:1의 비율로 분할하여 모델 학습 및 검증에 활용하였다.

III. 딥러닝 모델 학습 및 실험 결과

본 연구에서는 LSTM (Long Short-Term Memory) 기반의 딥러닝 모델을 활용하여 층별 자기장 시퀀스를 학습 및 검증하였다. LSTM은 시계열 데이터를 효과적으로 처리할 수 있는 구조로, 실내 위치 추위과 같이 시간에 따른 데이터 패턴을 학습하는 데 적합한 모델이다[5]. 모델은 10프레임 길이의 자기장 3축 시퀀스를 입력으로 하여 사용자가 위치한 층수를 분류하도록 설계하였다. 모델 학습에는 Adam 최적화 알고리즘과 Categorical Cross Entropy 손실 함수를 사용하여 모델의 성능을 최적화하였다.

실험은 숭실대학교 조만식 기념관의 3층부터 7층까지를 대상으로 수행되었다. 본 실험에서는 제안한 방법이 적절성을 판단하기 위해 자기장 맵을 수집한 경로와 반대 방향의 경로를 걸으면서 실제 실험 데이터를 수집하였다. 실험 자기장 데이터 또한 학습 데이터와 같이 윈도우 크기를 10으로 설정한 후, 슬라이딩 윈도우 기법을 사용하여 모델 입력 데이터로 사용하였다. 각 층별 분류 정확도는 표 1에 정리되어 있으며, 3층과 5층은 각각 98.3%, 95.8%로 가장 높은 정확도를 보였다. 반면, 6층과 7층은 건물 구조의 유사성과 자기장 패턴 중첩으로 인해 상대적으로 낮은 88.4%의 정확도를 기록하였다. 그러나 모든 층에서 88% 이상의 분류 성능을 확보하여, 제안한 기법이 초기 층 탐지에 있어 실효성이 있는 대안이 될 수 있음을 실험적으로 입증하였다.

본 논문에서는 스마트폰의 자가기 센서를 활용하여 초기 층을 정확히 탐지할 수 있는 딥러닝 기반의 기법을 제안하였다. 제안 모델은 슬라이딩 윈도우와 데이터 중강 기법을 통해 생성된 자기장 시퀀스를 LSTM으로 학습하여, 사용자의 층을 효과적으로 분류하였다. 실험 결과, 전체 평균 92.7%의 높은 정확도를 기록하였으며, 모든 층에서 안정적인 성능을 확인하였다. 이를 통해 본 기법이 실내 환경에서 초기 층 탐지에 효과적인 대안이 될 수 있음을 검증하였다.

표 1. 모델의 초기 층 탐지 정확도

Floor Number	Accuracy
3 rd Floor	98.3%
4 th Floor	92.5%
5 th Floor	95.8%
6 th Floor	88.4%
7 th Floor	88.4%

ACKNOWLEDGMENT

본 연구는 과학기술정보통신부 및 정보통신기획평가원의 SW중심대학 사업의 지원을 받아 수행되었음

- [1] K.-S. Kim and Y. Shin, "Deep learning-based PDR scheme that fuses smartphone sensors and GPS location changes," *IEEE Access*, vol. 9, no. 1, pp. 158616-158631, Dec. 2021.
- [2] C. Lin and Y. Shin, "Multi-floor indoor localization scheme using a Seq2Seq-based floor detection and particle filter with clustering," *IEEE Access*, vol. 11, pp. 66094-66112, July 2023.
- [3] J. W. Lee, *Android Sensor Story*, Chs. 4-6, Freelec, 2014.
- [4] M. Datar, A. Gionis, P. Indyk, and R. Motwani, "Maintaining stream statistics over sliding windows," *SIAM J. Comput.*, vol. 31, no. 6, pp. 1794-1813, Jan. 2002.
- [5] S. Hochreiter and J. Schmidhuber, "Long short-term memory," *Neural Comput.*, vol. 9, no. 8, pp. 1735-1780, 1997.