

다층 실내 측위에서 자기장 맵과 딥러닝 모델을 사용한 스마트폰 사용자 위치 초기화

김진우*, 조상훈°, 신요안*

Smartphone User Location Initialization in Multi-Floor Indoor Localization Using Magnetic Field Map and Deep Learning Model

Jin-Woo Kim*, Sanghoon Cho°, Yoan Shin*

요약

본 논문에서는 다층 실내 측위 기법에서 발생하는 문제를 해결하기 위해, 자기장 맵과 딥러닝 모델을 결합하여 스마트폰 사용자의 초기 층과 2차원 위치를 탐지하는 3차원 위치 초기화 기법을 제안한다. 제안 기법을 통해 인프라에 의존하지 않는 실내 다층 측위의 조건을 충족시켰으며, 실험을 통해 사용자의 3차원 위치 추정 성능을 검증하였다.

키워드 : 스마트폰 기반 실내 측위, 딥러닝, 자기장 맵, 3차원 위치 초기화, 보행자 관성 항법

Key Words : Smartphone-based indoor localization, Deep learning, Magnetic field map, 3D location initialization, Pedestrian dead reckoning

ABSTRACT

In this paper, we propose a 3D location initialization method that combines a magnetic field map and a deep learning model to detect the initial floor and 2D location of a smartphone user,

addressing the challenges of multi-floor indoor localization. The proposed method meets the requirements of infrastructure-free multi-floor indoor localization, and experiments have validated its performance in estimating the user's 3D position.

I. 서론

최근 스마트폰을 이용한 실내 측위 (Indoor Localization) 기술에 대한 연구가 활발히 진행되고 있다. 실내 측위에는 Wi-Fi Access Point (AP), Bluetooth Low Energy (BLE) Beacon 등 무선통신 신호의 세기를 이용하여 사용자의 위치를 추정하는 방식이 주로 사용된다¹⁾. 그러나, 이러한 실내 측위 기법은 경로 손실, 새도잉, 페이딩과 같은 문제가 발생하여 측위 정확도가 저하될 수 있다. 또한, 이러한 기법은 인프라 의존적이므로 재난 상황과 같은 유사시 활용에 한계가 있다. 따라서, 인프라에 의존하지 않는 보다 정밀한 실내 측위 기법이 요구된다. 인프라에 의존하지 않는 실내 측위 기법은 가속도 센서 (Accelerometer), 지자기 센서 (Magnetometer), 각속도 센서 (Gyroscope) 등을 포함한 스마트폰의 관성 측정 장치 (Inertial Measurement Unit; IMU) 센서만을 이용하는 보행자 관성 항법 (Pedestrian Dead Reckoning; PDR) 등 다양한 센서 응용 분야에서 활발히 연구되고 있다^{2,3)}.

이러한 실내 측위에서 다층 건물의 경우, 사용자의 2차원 위치뿐만 아니라 사용자가 위치한 층 정보도 필수적으로 요구된다. 인프라에 의존하지 않는 다층 실내 측위 기법에서 층 탐지는 일반적으로 스마트폰 기압계 센서 (Barometer)를 이용하여 기압 변화를 감지함으로써 사용자가 위치한 층을 판단한다^{4,5)}. 그러나, 기압계 센서는 날씨나 온도에 민감하여 동일한 위치에서도 날마다 다른 값이 측정된다. 이로 인해 기압계 센서를 이용한 층 탐지 기법은 사용자의 층간 이동은 감지할 수 있으나, 사용자가 위치한 초기 층을 정확히 탐지할 수 없다는 문제점이 있다⁶⁾. 또한, 2차원 위치를 계산하는 PDR 기법은 상대적인 위치 추정 방식이기 때문에 사용자가 위치한 초기 위치에 대한 불확실성 문제가 존재한다

※ 본 논문은 정부 (과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (RS-2023-00251595)

• First Author : (ORCID:0009-0001-9559-6956) School of Electronic Engineering, Soongsil University, jwkim1016@soongsil.ac.kr, 학생(석사), 학생회원

° Corresponding Author : (ORCID:0000-0003-4884-1477) Department of Statistics and Actuarial Science, Soongsil University, sanghcho@ssu.ac.kr, 부교수, 정회원

* (ORCID:0000-0002-4722-6387) School of Electronic Engineering, Soongsil University, yashin@ssu.ac.kr, 정교수, 종신회원
 논문번호 : 202410-231-A-LU, Received October 7, 2024; Revised October 10, 2024; Accepted October 10, 2024

다. 따라서, 인프라에 의존하지 않는 스마트폰 기반 다층 실내 측위 기법에서는 사용자가 위치한 초기 층과 초기 위치를 정확하게 탐지하는 방법이 요구된다.

본 논문에서는 스마트폰 기반 다층 실내 측위 기법의 문제점을 해결하기 위해, 각 층마다 스마트폰 지자기 센서를 사용하여 자기장 맵을 구축하고, 이를 기반으로 딥러닝 (Deep Learning) 모델을 활용해 스마트폰 사용자가 위치한 층 수를 탐지하는 기법을 제안한다. 또한, 자기장 맵을 이용한 2차원 초기 위치 추정 기법을 결합하여 다층 실내 측위에서 발생하는 3차원 위치 초기화 문제를 해결하고자 한다.

II. 자기장 맵과 딥러닝 모델 기반 층 탐지 기법

다층 실내 측위에서 스마트폰 사용자의 초기 층을 탐지하기 위해, 본 연구에서는 전형적인 대형 사무형 건물인 숭실대학교 형남공학관의 3층부터 7층까지를 대상으로 스마트폰 지자기 센서를 이용해 자기장 맵을 구축하였다. 자기장 데이터는 그림 1에 제시된 경로를 따라 스마트폰 화면이 하늘을 향하게 들고 걸으면서 수집하였으며, 각 층의 건물 구조는 동일하다. 또한 자기장 데이터는 걸음이 발생할 때마다 수집되었으며, 각 층에서 130걸음으로 동일하게 유지되었다.

지자기 센서는 지구 자기장의 벡터 방향과 크기를 측정하며, 이 벡터는 스마트폰 방향 변화에 따라 달라진다⁷⁾. 이로 인해 동일한 위치에서도 스마트폰 방향에 따라, 지자기 센서값이 다르게 측정될 수 있다. 이러한 지자기 센서의 특성 때문에, 지자기 센서값을 그대로 이용해 자기장 맵을 구축할 경우 스마트폰 방향에 따른 오차로 인해 특정 위치의 특성을 제대로 인식하지 못하는 문제가 발생할 수 있다. 이러한 문제점을 해결하기 위해, 본 연구에서는 모든 자기장 벡터를 기준 방향에 맞추어 정렬하여 자기장 맵을 구축하였다. 기준 방향은 그림 1의 도면상의 북쪽, 즉 0도로 설정하였으며, 실험

시에도 모든 자기장 벡터를 기준 방향으로 맞추어 스마트폰의 방향에 상관없이 해당 위치의 특성을 정확하게 인식할 수 있도록 하였다. 자기장 벡터 회전 변환은 식 (1), (2), (3)에 따라 수행된다.

$$V_{mag} = \begin{bmatrix} v_x \\ v_y \\ v_z \end{bmatrix}, \quad (1)$$

$$R_z(\theta) = \begin{bmatrix} \cos\theta & -\sin\theta & 0 \\ \sin\theta & \cos\theta & 0 \\ 0 & 0 & 1 \end{bmatrix}, \quad (2)$$

$$\begin{aligned} V'_{mag} &= R_z(\theta) V_{mag} \\ &= \begin{bmatrix} \cos\theta & -\sin\theta & 0 \\ \sin\theta & \cos\theta & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} v_x \\ v_y \\ v_z \end{bmatrix} \\ &= \begin{bmatrix} \cos\theta \cdot v_x - \sin\theta \cdot v_y \\ \sin\theta \cdot v_x + \cos\theta \cdot v_y \\ v_z \end{bmatrix}. \end{aligned} \quad (3)$$

여기서, V_{mag} 는 자기장 벡터이고, v_x, v_y, v_z 는 자기장 벡터의 구성 요소이다. 현재 기준 방향으로부터 스마트폰의 회전 각도는 θ 이며, 이 회전 각도는 스마트폰에 내장된 자이로스코프 센서를 사용하여 구해진다. z 축 회전에 따른 회전 행렬은 $R_z(\theta)$ 로 표현되며, 회전 변환된 자기장 벡터 V'_{mag} 는 식 (1)과 (2)에서 얻어진 자기장 벡터와 회전 행렬을 사용하여 식 (3)의 관계로 표현할 수 있다.

위 과정을 통해 구축된 자기장 맵은 각 층에서 130걸음 동안 수집된 자기장 데이터로만 구성되었으며, 추가적인 데이터는 수집되지 않았다. 이를 보완하기 위해, 수집된 자기장 시퀀스 데이터를 회전 변환하여 데이터 증강 (Data Augmentation)을 수행하였다. 구체적으로, 각 층의 자기장 시퀀스 데이터에 대해 $\pm 10^\circ$ 범위 내에서 랜덤한 각도를 적용하여 회전 변환하였으며, 이를 통해 각 층에서 60개의 자기장 시퀀스 데이터를 생성하였다. 이 중 30개의 데이터는 기존 시퀀스의 마지막에서 시작하는 자기장 시퀀스 데이터로, 딥러닝 모델이 반대 경로의 자기장 시퀀스도 학습할 수 있도록 하였다.

본 논문에서는 회전 변환을 통해 증강된 자기장 시퀀스 데이터에 슬라이딩 윈도우 기법을 적용하여 연속적인 시계열 데이터를 생성하였으며, 이를 통해 모델이 시간적 패턴을 효과적으로 학습할 수 있도록 하였다. 슬라이딩 윈도우 크기는 10으로 설정하였으며, 데이터 증강과 슬라이딩 윈도우 기법을 통해 650×3 형태의 학습 데이터가 $36,300 \times 10 \times 3$ 형태로 변환되었다. 여




그림 1. 자기장 데이터 수집 경로
Fig. 1. Magnetic field data collection path

기서 학습 데이터 세트는 8:1:1의 비율로 훈련, 검증, 테스트 세트로 분할하였다. 모델 학습은 LSTM (Long Short-Term Memory) 딥러닝 모델을 사용하였으며, 층 탐지를 위한 분류 문제로 접근하였다⁸⁾. 표 1은 송실대학교 형남공학관 3층부터 7층까지의 층 탐지 실험 결과를 보여준다. 실험은 제안한 방법의 타당성을 확인하기 위해 자기장 맵을 수집한 경로와 반대 방향의 경로를 따라 실험 데이터를 수집하였다. 표 1에서 제시된 바와 같이, 제안된 자기장 맵 기반 딥러닝 모델이 층 탐지에서 높은 정확도를 보이는 것을 확인하였다. 또한, 슬라이딩 윈도우 기법을 사용함으로써 사용자가 실내 어느 위치에 있더라도 처음 10걸음만으로 해당 층을 정확하게 탐지할 수 있음을 입증하였다.

표 1. LSTM 모델의 층 탐지 정확도
Table 1. Floor detection accuracy of the LSTM model

Model	Floor Number	Accuracy
LSTM	3 rd Floor	96.8%
	4 th Floor	91.8%
	5 th Floor	87.8%
	6 th Floor	97.5%
	7 th Floor	90.2%

III. 3차원 다층 실내 측위 실험 결과 및 결론

위 과정에 따라 사용자의 층 정보를 얻은 후, 2차원 위치 정보만 추가되면 PDR 기법을 적용할 수 있는 조건이 충족된다. 본 연구에서 2차원 위치는 k -NN

(Nearest Neighbor) 알고리즘을 사용하여 추정한다. k -NN 알고리즘은 새로운 데이터 포인트와 기존 데이터 포인트 간의 유클리디안 거리 (Euclidean Distance)를 계산하여 가장 가까운 k 개 데이터 포인트를 찾아 이들 타겟 값 평균을 통해 값을 예측하는 지도 학습 방식이다⁹⁾. 스마트폰에서 수집되는 센서값은 3축 정보로 표현되므로, 여기서 사용되는 데이터 포인트는 3차원 벡터로 표현되는 지자기 센서값이다.

k -NN 알고리즘의 k 값은 실험적으로 3으로 설정하였다. 그림 2에는 송실대학교 형남공학관 3층에서 수행된 제안 기법의 실험 결과를 도시하였다. 그림 2에 제시된 바와 같이, 처음 10걸음의 자기장 데이터를 사용하여 사용자가 위치한 층에 대한 정보를 얻고, 이후 해당 층의 자기장 맵을 기반으로 k -NN 알고리즘이 해당 위치의 지자기 센서값과 비교하여 사용자의 현재 위치를 추정한다. 제안 방식을 통한 초기 층과 위치가 결정됨에 따라, PDR 및 기압계 센서를 활용한 층 이동 감지 기법을 적용할 수 있는 조건이 충족되었으며, 이후 PDR 기법을 사용한 파란색 경로는 실제 경로와 유사하게 나타나며 안정적이고 높은 측위 성능을 보이는 것을 확인하였다.

본 논문에서는 스마트폰을 이용한 다층 실내 측위 기법에서 발생하는 3차원 위치 초기화 문제를 해결하기 위해, 자기장 맵과 딥러닝을 결합한 3차원 위치 초기화 기법을 제안하였다. 실험 결과를 통해 3차원 위치 추정에서 실제 사용자 경로와 제안 방식을 비교하였을 때 제안 방식이 높은 정확성을 보이는 것을 확인하였으며, 인프라에 의존하지 않는 스마트폰 기반의 다층 실내 측




그림 2. 다층 실내 측위 실험 결과
Fig. 2. Multi-floor indoor localization experiment results

위 기법의 가능성을 확인하였다.

References

- [1] T. D. Vy, T. L. N. Nguyen, and Y. Shin, "Pedestrian indoor localization and tracking using hybrid Wi-Fi/PDR for iPhones," in *Proc. IEEE VTC-Spring*, pp. 1-7, Helsinki, Finland, Apr. 2021.
- [2] 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.
- [3] C. Lin and Y. Shin, "Deep learning-based direction estimation scheme using smartphone inertial sensors," *J. KICS*, vol. 47, no. 6, pp. 898-907, Jun. 2022.
- [4] 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, no. 1, pp. 66094-66112, Jun. 2023.
- [5] C. Yi, W. Choi, Y. Jeon, and L. Liu, "Pressure-pair-based floor localization system using barometric sensors on smartphones," *Sensors*, vol. 19, no. 16, pp. 3622-3640, Aug. 2019.
- [6] I. Ashraf, S. Hur, M. Shafiq, and Y. Park, "Floor identification using magnetic field data with smartphone sensors," *Sensors*, vol. 19, no. 11, p. 2538, Jun. 2019.
- [7] J. W. Lee, *Android Sensor Story*, Chapters 4-6, Freelec, 2014.
- [8] S. Hochreiter and J. Schmidhuber, "Long short-term memory," *Neural Comput.*, vol. 9, no. 8, pp. 1735-1780, Nov. 1997.
- [9] F. Farahnakian, T. Pahikkala, P. Liljeberg, and J. Plosila, "Energy aware consolidation algorithm based on k -nearest neighbor regression for cloud data centers," in *Proc. IEEE/ACM UCC 2013*, pp. 256-259, Dresden, Germany, Dec. 2013.