

자기장 맵을 이용한 딥러닝 기반의 스마트폰 사용자 자세 추정

이예진, 김진우, 김요셉, 신요안*

송실대학교 전자정보공학부

whatt77@soongsil.ac.kr, jwkim1016@soongsil.ac.kr, yosep@soongsil.ac.kr, *yashin@ssu.ac.kr

(*교신 저자)

Deep Learning-based Smartphone User Pose Estimation Using Magnetic Field Maps

Ye-Jin Lee, Jin-Woo Kim, Yo-Sep Kim and Yoan Shin*

School of Electronic Engineering, Soongsil University

(*Corresponding author)

요약

본 논문에서는 기존 스마트폰 IMU 센서를 이용한 보행자 관성 항법(Pedestrian Dead Reckoning; PDR) 기법의 자세 고정 제약 한계를 극복하기 위해, 스마트폰에 내장된 자기기 센서를 활용한 자세별 자기장 맵 구축 및 딥러닝 기반 사용자 자세 분류 기법을 제안한다. 사용자의 보행 중 자세는 텍스트 타이핑, 통화, 주머니 휴대의 세 가지로 정의하였으며, 데이터 증강을 위해 자기장 시퀀스에 회전 변환 및 슬라이딩 윈도우 기법을 적용하였다. 제안된 기법의 성능 검증을 위해 딥러닝 모델을 통한 자세 분류 성능 평가를 수행한 결과, 다양한 피험자에 대해 높은 정확도를 나타내어 제안 기법의 효과적인 자세 분류 성능을 확인하였다.

I. 서 론

최근 스마트폰을 이용한 실내 측위 (Indoor Localization) 연구에서는 외부 자원 없이 스마트폰 내부의 관성 측정 장치 (Inertial Measurement Unit; IMU) 센서만으로 사용자의 이동 경로를 추정하는 보행자 관성 항법 (Pedestrian Dead Reckoning; PDR) 기술이 활발히 연구되고 있다 [1,2]. PDR 기법은 Wi-Fi, Beacon 등 별도의 인프라 없이도 실내 환경에서 위치 추정이 가능하다는 장점이 있어 인프라 제약이 있는 공간에서 유용하게 활용될 수 있다. 그러나, 기존 PDR 기법은 스마트폰이 일정한 자세로 고정되어 있다는 가정을 전제로 하며, 이는 실제 환경에서는 쉽게 성립되지 않는다. 사용자는 실생활에서 텍스트 타이핑, 통화, 주머니 휴대 등 스마트폰을 다양한 방식으로 휴대하게 되며, 이로 인해 센서의 기준 축이 지속적으로 변화되어 측위 정확도에 부정적인 영향을 미친다. 따라서, PDR 기법의 실생활 적용을 위해 스마트폰 휴대 자세 변화에 강건한 측위 기술이 요구된다. 이에 본 논문에서는 스마트폰에 내장된 IMU 센서를 활용하여, 다양한 사용자 자세를 인식할 수 있는 딥러닝 기반의 사용자 자세 추정 기법을 제안한다. 제안 기법은 사용자의 스마트폰 휴대 자세를 실시간으로 분류하고, 각 자세에 따라 적절한 센서 보정 또는 처리 전략을 적용함으로써, 자세 변화로 인한 측위 정확도 저하를 효과적으로 완화할 수 있다.

II. 자기장 데이터 수집 및 전처리

스마트폰의 자기기 센서는 현재 위치의 지구자기장을 x, y, z 의 3축 벡터 형태로 측정한다[3]. 그러나 사용자의 자세가 달라지면 스마트폰의 기준 축도 함께 변화하게 되며, 이로 인해 동일한 위치에서도 사용자의 자세에 따라 측정되는 자기장 값은 달라질 수 있다. 그림 1은 이러한 특성을 시각적으로 보여주는 예로, 텍스트 타이핑, 통화, 주머니 휴대의 세 가지 자세에 따라 측정된 동일한 경로의 자기장 시계열 값의 분포가 상이함을 보여준다. 본 연구에서는 이러한 자기기 센서의 특성을 이용하여 자세별 자기장 맵을 구축하고, 이를 전처리하여 딥러닝 기반 분류 모델의 입력 데이터 형태로 측정한다.

이터로 사용하였다. 자기장 맵은 전형적인 대형 사무형 건물인 송실대학교 협남공학관 3층에서 수집되었으며, 데이터 수집은 텍스트 타이핑, 통화, 주머니 휴대의 세 가지 자세를 고려하여 수행되었다. 또한, 각 자세별 130 걸음에 해당하는 동일한 길이의 자기장 시퀀스를 1회씩 수집하였다.

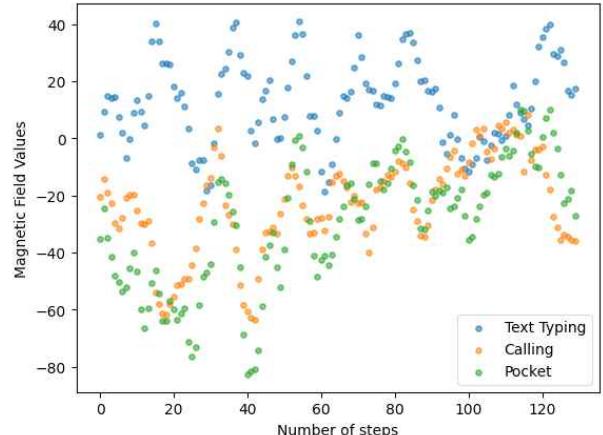


그림 1. 스마트폰 휴대 자세에 따른 자기장 값 분포

학습 데이터가 부족할 경우 데이터 증강 (Data Augmentation) 기법은 모델의 일반화 성능을 향상시키고 과적합을 방지하는 데 효과적으로 사용된다. 본 연구에서는 각 자세에 대해 130 걸음에 해당하는 자기장 시퀀스만을 수집하였으며, 추가적인 데이터는 확보하지 않았다. 이로 인해 수집된 데이터만을 그대로 입력 데이터로 사용할 경우, 데이터 부족으로 인한 딥러닝 모델의 과적합이 발생할 우려가 있다. 따라서, 모델의 일반화 성능을 향상시키고, 자세별 자기장 분포의 다양성을 반영하기 위해 각 자기장 시퀀스에 대해 ±10도 범위 내에서 임의의 각도를 적용한 z 축 기준 회전 변환을 적용하였다. 이러한 과정을 통해 각 자세별 100개의 자기장 시퀀

스를 생성하였으며, 총 300개의 자기장 시퀀스를 확보하였다. 위 회전 변환 과정을 통해 자기장 시퀀스에 노이즈를 추가함으로써 현실적인 변동성을 모사하고, 동시에 데이터 증강 효과도 달성하였다.

슬라이딩 윈도우 (Sliding Window) 기법은 시계열 데이터를 학습 가능한 형태로 구성하는 데 유용한 방법으로, 고정된 크기의 윈도우를 데이터를 따라 일정 간격으로 이동시키며 각 구간을 모델 학습에 사용하는 방식이다[4]. 본 연구에서는 회전 변환을 통해 증강된 데이터에 슬라이딩 윈도우 기법을 적용하여 연속적인 시계열 데이터를 생성하고, 이를 통해 모델이 시간적 패턴을 효과적으로 학습할 수 있도록 하였다. 윈도우 크기는 사용자의 자세가 실시간으로 바뀌는 상황에서 빠르게 변화를 감지할 수 있도록 5로 설정하였으며, 1프레임 단위로 이동시켜 최대한 많은 시계열 샘플을 생성하였다. 데이터 증강과 슬라이딩 윈도우 기법을 적용한 결과, 기준 (390, 3) 크기의 학습 데이터는 총 37,800개의 시퀀스로 구성된 (37,800, 5, 3) 크기의 시계열 데이터로 변환되었으며, 각 시퀀스는 5프레임 길이의 3축 자기장 벡터로 구성된다. 최종적으로 생성된 전체 데이터는 학습, 검증, 테스트 세트로 8:1:1의 비율로 분할하여 모델 학습에 활용하였다.

III. 딥러닝 모델 학습 및 실험 결과

본 연구에서는 스마트폰의 지자기 센서를 통해 수집한 데이터를 기반으로, 보행 중 사용자의 자세를 분류하기 위해 순환 신경망 구조인 LSTM (Long Short-Term Memory) 모델을 사용하였다. LSTM 모델은 시계열 데이터의 시간적 흐름과 변화를 효과적으로 학습하며, 연속적인 자기장 벡터의 변화 양상을 통해 서로 다른 자세를 구분하는 데 적합하다[5]. 모델 학습은 한 명의 피험자 데이터를 활용하여 수행되었으며, 분류 성능 평가는 학습에 포함된 피험자 (Seen)와 포함되지 않은 피험자 (Unseen)를 대상으로 각각 진행하였다. 특히, 제안한 모델이 특정 피험자에 특화되지 않고 다양한 피험자에게도 잘 동작하는지를 검증하기 위해, 학습에 포함되지 않은 세 명의 피험자 데이터를 기반으로 일반화 성능을 평가하였다. 모델은 해당 피험자들에 대한 사전 정보 없이 자세 분류를 수행하였으며, 자세별 예측 정확도는 표 1에 제시하였다.

실험 결과, Seen 피험자에 대한 자세 분류 정확도는 97.7%였으며, 세 명의 Unseen 피험자에 대해서는 각각 94.6%, 96.2%, 80.0%의 정확도를 기록하였다. 전반적으로 높은 분류 성능을 확인할 수 있었으나, 피험자 간 정확도 편차가 존재하였으며, 이는 개인의 보행 습관, 체형, 또는 스마트폰 휴대 방식의 차이에 기인한 것으로 보인다.

본 논문에서는 스마트폰에 내장된 지자기 센서를 활용하여 사용자의 보행 중 자세를 효과적으로 분류할 수 있는 딥러닝 기반의 자세 추정 기법을 제안하였다. 제안한 기법은 특정 피험자에 국한되지 않고, 다양한 보행 습관 및 스마트폰 휴대 방식에 대해서도 안정적으로 동작함을 실험을 통해 확인하였다. 이를 통해 실내 위치 추정 시스템에서 발생할 수 있는 자세 변화로 인한 오차를 사전에 보정할 수 있다는 가능성을 제시하였으며, 향후 PDR 기반의 실시간 실내 측위 시스템의 정확도 향상에 기여할 수 있을 것으로 기대된다.

표 1. 다양한 사용자의 스마트폰 휴대 자세 추정 결과

Subject ID	Subject Type	Accuracy
Subject 1	Seen	97.7%
Subject 2	Unseen	94.6%
Subject 3	Unseen	96.2%
Subject 4	Unseen	80%

ACKNOWLEDGMENT

본 연구는 과학기술정보통신부 및 정보통신기획평가원의 SW중심대학 사업의 지원을 받아 수행되었음 (2024-0-00071)

참고 문헌

- [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] Q. Wang, H. Luo, L. Ye, A. Men, F. Zhao, Y. Huang, and C. Ou, "Pedestrian heading estimation based on spatial transformer networks and hierarchical LSTM," *IEEE Access*, vol. 7, pp. 162309–162322, 2019.
- [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.