

스마트폰 관성 센서를 이용한 딥러닝 기반의 이동 방향 측정 기법

임준상*, 신요안*

Deep Learning-Based Direction Estimation Scheme Using Smartphone Inertial Sensors

Chenxiang Lin*, Yoan Shin*

요약

스마트폰을 활용한 실내 측위에서 많이 사용되는 보행자 관성항법은 사용자의 움직임에 따라 변화하는 관성 측정 장비의 값을 사용하여 위치를 갱신한다. 보행자 관성항법은 보행 감지, 보폭 계산, 이동 방향 추정 총 3가지 요소로 이루어져 있는데, 실내 환경에서 보행 감지와 보폭 계산은 비교적 안정적으로 추정되지만 이동 방향 추정은 센서의 누적오차와 실내 자기장의 영향으로 방향 추정값에 변동성이 증가한다. 이 문제를 해결하기 위해, 본 논문에서는 사용자가 스마트폰을 가지고 걸을 때 스마트폰에 내장된 관성 측정 장비의 센서값을 수집하여 입력 데이터로 만들고 사용자가 걸을 때 실제 이동 방향을 출력 데이터로 구성해, 별도 보정계수 (Hyperparameter) 설정 필요 없이 방향 정보뿐만 아니라 관성 측정 유닛의 원시 데이터도 사용하여 사용자 이동 방향을 예측하는 딥러닝 기반의 이동 방향 추정 기법을 제안한다. 제안된 기법을 검증하기 위해 Android OS에서 관성 측정 장비의 센서 데이터를 수집하였고, Google사의 기계학습 라이브러리 TensorFlow를 사용하여 딥러닝 모델을 구현하여 제안 기법의 실험 결과를 확인하였다.

키워드 : 실내 측위, 스마트폰 기반 실내 방향 추정, 방위각, 딥러닝, 관성 측정 유닛

Key Words : Indoor Localization, Smartphone-based Indoor Direction Estimation, Azimuth, Deep Learning, Inertial Measurement Unit

ABSTRACT

Pedestrian dead reckoning (PDR) which is widely used in smartphone-based indoor localization, updates user's location by calculating the movement variations using the inertial measurement unit (IMU) inside the smartphones. The PDR consists of three components: step detection, stride length estimation, and direction estimation. In the indoor environment, although the step detection and the stride length estimation obtain accurate results relatively, the direction estimation accuracy can be easily affected by the cumulative errors and the magnetic noises. In this paper, we propose a deep learning-based direction estimation scheme by taking into account the gyroscope drift problem and the external magnetic field effects. The proposed scheme collects the IMU data when the user freely walks with the smartphone as the training data and labels the data using the actual walking direction as the output data. The proposed deep learning model receives the IMU sensor

* 이 논문은 2020년도 과학기술정보통신부의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (2020R1A2C2010006).

• First Author : School of Electronic Engineering, Soongsil University, CXLin@soongsil.ac.kr, 학생회원

◦ Corresponding Author : School of Electronic Engineering, Soongsil University, yashin@ssu.ac.kr, 중신회원

논문번호 : 202203-035-C-RE, Received February 25, 2022; Revised May 3, 2022; Accepted May 3, 2022

values while the user walks, and predicts the direction of the current step. In order to evaluate the performance of the proposed scheme, we built an Android app to collect the IMU sensor data, and train the deep learning model by utilizing the Google's TensorFlow machine learning library.

I. 서론

실외 공간에서 GPS (Global Positioning System), GLONASS (GLObal NAVigation Satellite System) 등의 위성 신호를 활용하여 사용자 위치를 계산할 수 있는데 반해, 실내에서는 위성 신호가 건물에 가리고 수신하기 어려워 위성 신호로 실내에서 사용자 위치를 측정하는, 즉 실내 측위 (Indoor Localization)는 큰 오차 때문에 사용 불가능할 수 있다. 최근 들어, 스마트폰 보급률이 높고 휴대가 간편하다는 점을 고려해 스마트폰 기반의 실내 측위에 관한 연구가 활발히 진행되고 있으며, 주요 기반 시설에 의존하는 (Infrastructure-dependent) 방식과 의존하지 않는 (Infrastructure-independent) 방식으로 크게 나눌 수 있다.

기반 시설에 의존하는 방식 중 초광대역 (Ultra Wide Band; UWB)^[1], Wi-Fi^[2], Bluetooth Low Energy (BLE)^[3]와 같이 스마트폰이 수신하는 무선 신호의 세기와 방향을 활용하여 사용자의 실내 위치를 계산하는 기법 등이 있는데, 이러한 기법의 공통적인 단점은 액세스 포인트 (Access Point), 비콘 (Beacon) 등과 같은 앵커 노드 (Anchor Node)에 대한 의존성이 있다. 앵커 노드는 미리 설치해야 하고, 실내 측위 정확도는 이들의 개수와 위치뿐만 아니라 환경의 변화에 의해 영향을 받는다^[4].

스마트폰 기반의 기존 보행자 관성항법 (Pedestrian Dead Reckoning; PDR) 기법은 기반 시설에 의존하지 않은 방식이며, 사용자가 스마트폰을 가지고 걸을 때 변화하는 관성 측정 유닛 (Inertial Measurement Unit; IMU) 내의 가속계 (Accelerometer), 지자계 (Magnetometer), 자이로스코프 (Gyroscope) 센서값을 이용하여 사용자 위치를 계산한다. 정확한 이동 방향을 얻는 것은 PDR 기법의 주요 기술적 목표이며, 지자계 센서는 실내 자기장 간섭에 민감하고 자이로스코프에서는 드리프트 (Drift)에 따른 누적오차가 있어 이동 방향의 정확도가 떨어지고 실내 측위 성능이 감소한다. 이 문제를 해결하기 위해 센서 융합 알고리즘은 이동 방향 추정 개선에 널리 사용되고 있다^[5-7].

최근에는 기존 PDR의 성능을 향상하기 위해 딥러닝 (Deep Learning; DL) 기반의 PDR 방안

에 대해 연구가 활발히 진행되고 있다^[8-10]. 예를 들어, [9]에서는 보폭 계산 정확성을 향상하기 위해 DL 모델이 스마트폰 사용자의 행위를 분류하는데 사용되고, [10]에서는 가속도를 적분하는 대신 보행자 이동 속도를 추정하는 DL 접근법이 제안되었다.

본 논문에서는 기존 PDR 기법의 이동 방향 추정에서 발생하는 자기장 간섭 문제, 센서 드리프트 문제를 해결하기 위해, 스마트폰 관성 센서를 사용한 딥러닝 기반의 이동 방향 추정 기법을 제안한다. 사용자가 걸을 때 스마트폰 IMU 센서값을 저장하여 실제 이동 경로를 바탕으로 학습 데이터로 만들어 사용자의 이동 방향을 안정화하고 예측하는 DL 모델을 지도 학습한 후, 실제 수집된 IMU 데이터를 사용하여 기존 이동 방향 추정 방안, 융합 알고리즘 방안 그리고 제안 기법을 이용하여 사용자의 이동 경로를 추적하고 각각의 측위 결과를 비교하여 이동 방향 추정 성능을 확인한다.

본 논문의 구성은 다음과 같다. 2장에서는 기존 스마트폰 IMU 센서 기반의 이동 방향 추정 기법과 방향 추정 성능 개선을 위한 융합 알고리즘을 소개한다. 3장에서는 제안하는 DL 기반의 이동 방향 안정화 기법에 대한 IMU 데이터 수집 및 전처리, 지도 학습 데이터의 구성과 모델의 훈련 방안

II. 센서 기반의 방향 추정 방식과 문제점

본 장에서는 스마트폰 IMU 센서 기반 이동 방향 추정 기법과 방향 정확성을 향상하기 위한 융합 알고리즘을 소개한다. 여기서 사용자가 스마트폰을 가지고 걸을 때 변화하는 IMU 센서값을 활용하여 방향을 추정하고, 융합 알고리즘이 추정된 방향의 성능을 개선하는 프로세스를 서술한다. 또한, 실내 환경과 IMU 센서의 한계에 의한 각각의 문제점도 설명한다.

2.1 기존의 방향 추정 방식

스마트폰 IMU 센서 기반의 이동 방향 추정 기법은 그림 1과 같다. 기존의 보행자 관성항법의 이동 방향은 스마트폰이 하늘을 향하고 있을 때 주요 회전축인

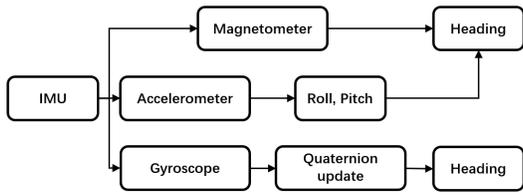


그림 1. 스마트폰 IMU 센서를 사용한 이동 방향 측정 구조
 Fig. 1. The framework of the heading estimation algorithm using smartphone IMU sensors

z 축 방향을 기준으로 사용하고, z 축 방향은 가속계 (단위: m/sec^2), 지자기 (단위: μT), 자이로스코프 (단위: rad/sec)로 이루어진 IMU에서 측정된 센서 값을 사용해 아래와 같이 계산된다.

$$\alpha_c^k = \tan^{-1}\left(\frac{-Mag_{Cy}}{Mag_{Cx}}\right), \quad (1)$$

$$\alpha_g^1 = \alpha_c^1, \quad (2)$$

$$\alpha_g^k = \alpha_g^{k-1} + \omega^k \Delta t. \quad (3)$$

여기서, α_c^k 는 가속계와 지자기 센서로 계산한 k 번째 걸음에서의 이동 방향이고, α_g^k 는 자이로스코프 센서로 계산한 k 번째 이동 방향이다. Mag_{Cx} 와 Mag_{Cy} 는 각각 가속계와 지자기로 계산한 보정된 지자기 값이다. ω^k 는 k 번째 걸음에서의 회전 각속도이고, Δt 는 회전 감지 시간이다. 첫 번째 α_g 가 식 (2)와 같이 가속계와 지자기 센서로 계산한 α_c 의 값으로 초기화하고, 나머지는 식 (3)에 따라 지난번 α_g 값에서 현재 각속도 ω^k 를 적분하여 α_g 를 갱신한다.

자이로스코프 센서에서 도출되는 α_g 와 가속도 및 지자기 센서에서 도출되는 이동 방향 α_c 는 각 센서의 특성에 따라 방향 정보가 다르다. 지자기 센서가 지구 자기장의 북쪽을 향하는 특성을 이용하여 α_c 에서 지구좌표계 (Global Coordinate System; GCS)의 방향 정보를 얻을 수 있는데, 실내에서 α_c 를 계산할 때 발생하는 문제는 주로 건물의 철골 구조나 전자 장비 등에서 발생하는 자기장에 의해 지구 자기력이 왜곡되어 측정되는 문제이며, 이러한 현상을 소프트 아이언 효과 (Soft Iron Effect)라고 한다^[11]. 자이로스코프 센서를 이용하여 계산된 이동 방향 α_g 는 자기장의 영향을 무시하는데, 회전각을 계산하는 센서의 측정 방식 때문에 추적 시간에 따라 센서의 측정 한계, 드리프트

현상 등에 의해 누적오차가 발생하여 짧은 추적 경로에만 정확하다^[6,12].

2.2 융합 알고리즘

스마트폰 IMU 센서를 이용하여 추정된 이동 방향 내의 불필요한 잡음을 감소시키기 위해, 기존 방법은 칼만 필터 (Kalman Filter; KF)^[13,14], 파티클 필터 (Particle Filter; PF)^[15], 상보 필터 (Complementary Filter; CF)^[16] 등의 알고리즘을 사용하여 센서값을 융합하여 각 센서의 특성을 활용해 이상치를 감쇄한다. 주요 저주파 잡음을 포함하는 자이로스코프 이동 방향과 주요 고주파 잡음을 포함하는 지자기 및 가속도의 이동 방향을 일정한 비율로 융합하는 CF 방식은 아래 식에 따라 이동 방향을 추정한다^[17,18].

$$\alpha_f^k = b\alpha_g^k + (1-b)\alpha_c^k. \quad (4)$$

여기서, α_c 와 α_g 는 식 (1)과 식 (3)에서 얻은 두 이동 방향이고, 계수 b 의 크기에 따라 α_c 와 α_g 의 융합 비율이 결정된다. 또한, b 의 값을 선택할 때는 각 센서의 응답 특성을 고려해야 하는데, 낮은 주파수 대역에서 성능이 좋은 α_c 와 높은 주파수 대역에서 성능이 좋은 α_g 의 센서의 성질에 따라 $b > 0.9$ 이상의 값을 상황에 맞게 선택한다.

선형 역학계의 상태를 추정하는 순환 필터 (Recursive Filter)인 KF는 아래 식에 따라 이동 방향을 추정한다^[19].

$$\alpha_m^k = \alpha_m^{k-1} + V^k \Delta t + \gamma, \quad (5)$$

$$\alpha_c^k = \alpha_m^k + \varphi. \quad (6)$$

예측 단계

$$\hat{\alpha}_m^{k^-} = A\hat{\alpha}_m^{k-1} + Bu^{k-1}, \quad (7)$$

$$P^{k^-} = AP^{k-1}A^T + Q, \quad (8)$$

보상 단계

$$K^k = \frac{P^{k^-}H^T}{HP^kH^T + R}, \quad (9)$$

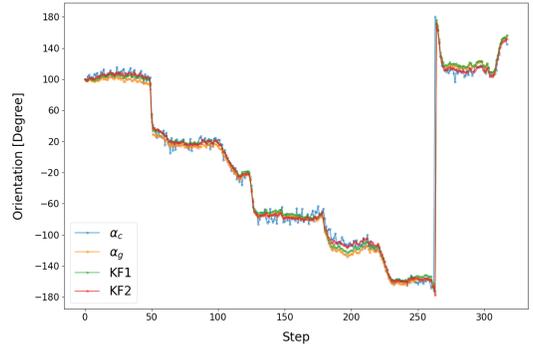
$$\hat{\alpha}_m^k = \hat{\alpha}_m^{k^-} + K^k(\alpha_c^k - H\hat{\alpha}_m^{k^-}), \quad (10)$$

$$P^k = (I - K^k H) P^{k-}. \quad (11)$$

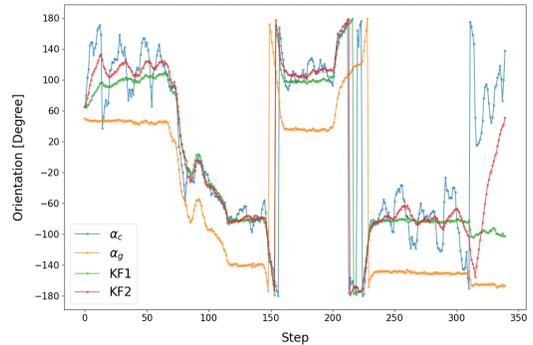
여기서 식 (5)는 상태 전이 함수이며, 식 (5)에서 α_m 는 이동 방향, V^k 는 시스템의 입력, γ 는 공분산 행렬 (Covariance Matrix) Q 를 가지는 정규분포 $\gamma \sim N(0, Q)$ 잡음 변수이다. 본 논문에서 V_i 는 자이로스코프 센서값이다. 식 (6)은 관찰 함수이며, 시스템의 관찰 값은 가속계와 지자기 센서에서 도출되는 α_c 이고 φ 는 공분산 행렬 R 을 가지는 정규분포 $\varphi \sim N(0, R)$ 잡음 변수이다. KF 알고리즘에 사용되는 파라미터를 표 1로 요약하였고 이동 방향만 추정해서 A, B, H 는 모두 1로 초기화한다. 식 (5)과 식 (6)에서 나온 γ 와 φ 의 표준편차인 Q 와 R 은 개발자가 설정하는 매개변수이고 Q 가 커지면 추정 잡음이 커져 자이로스코프 센서값의 사용 비율이 낮아지고 R 이 커지면 관측 잡음이 커져 가속계와 지자기 센서값의 사용 비율이 낮아진다.

실외에서는 α_c 의 값이 안정적이고 α_g 의 값과 비슷해서 서로 다른 매개변수를 사용하는 융합 알고리즘 결과도 비슷하다. 그러나 실내에서는 큰 자기장 잡음 때문에 융합 알고리즘 결과는 매개변수에 민감하고, 적당하지 않은 매개변수를 설정하면 잡음이 강한 공간에서 여전히 문제가 발생하며, 위와 같은 센서 융합 방식은 모든 환경에 따른 적합한 계수 설정이 어렵다.

그림 2는 서로 다른 잡음 환경에서 다른 매개변수의 설정에 따라 다른 융합 결과를 확인하기 위한 측정 결과이다. 그림에서 나온 KF의 결과는 식 (5)-(11)로 계산하였다. KF1 (초록색)은 Q 의 값이 0.001이고 R 의 값이 15인 KF 융합 결과이며, KF2 (빨간색)는 Q 의 값이 0.01이고 R 의 값이 1.5인 KF 융합 결과이다. 그림 2(a)는 자기장 잡음이 약한 실외에서의 측정 결과이고 KF1과 KF2의 융합 결과가 비슷한 모습을 확인할 수 있었으며, 그림 2(b)에서는 α_c (파란색)와 α_g (주황색)를 비교하여 α_c 가 실내에서 발생하는 자기장으로 인해 불안정한 모습이 나타났고 KF1과 KF2의 융합 결과가 큰 차이인 것을 확인할 수 있었다.



(a) 실외 환경



(b) 실내 환경

그림 2. 실외 및 실내에서 서로 다른 매개변수의 융합 결과
Fig. 2. Fusion results for different parameters in outdoor and indoor environments

또한, α_c 와 α_g 뿐만 아니라 IMU Raw 데이터에서도 사용자의 이동 방향과 자세 등 정보를 포함하고 있다. 예를 들어, 사용자는 스마트폰이 직진 방향을 가리키고 걸을 때 다른 보행자에 양보하기 위해 옆쪽에 움직인다. 이 때 스마트폰이 여전히 앞쪽에 가리키고 있다면, 추정된 방향은 앞쪽인데 실제 이동 방향은 완전 앞쪽이 아니다. 사용자가 오른쪽으로 이동하면 IMU 센서 중인 가속도 센서의 x 축 데이터를 변동시킬 것이고 적당하게 사용되면 추정된 이동 방향을 보정할 수 있다. 하지만 기존 알고리즘은 이러한 데이터를 사용하기 어렵다.

III. 센서 기반의 방향 추정 방식과 문제점

본 논문에서 제안하는 DL 기반 방향 추정 기법은 학습을 위한 데이터 수집 과정, 학습 성능을 높이기 위한 전처리 및 훈련 데이터 작성 과정, 그리고 모델의 훈련 과정으로 구성되며, 기존 IMU 센서 기반의 방향 추정 시 발생하는 문제 해결하기 위한 목적으로

표 1. KF 알고리즘에 사용된 파라미터
Table 1. Parameters used in the KF algorithm

Observed input	α_c (measurement)
Posterior output	α_m (estimate)
System model	A, B, H, Q, R
For internal computation	$\hat{\alpha}_m^{k-}, P^{k-}, P^k, K^k$

설계된 학습 데이터를 사용해 문제를 해결한다.

3.1 IMU 데이터 수집

본 논문에서는 DL 기법의 학습 방법 중 지도 학습 방식을 사용하여 모델을 훈련한다. 모델의 성능은 입력 데이터 (Input Data)와 출력 데이터 (Output Data)의 상관관계에 따라 변화되고, 실제 성능을 높이기 위해서는 입력과 출력의 관계성이 높은 특성을 사용하는 것이 중요하다. 제안하는 DL 기반 방향 추정 기법에서는 기존의 IMU 센서에서 발생하는 문제점을 해결하기 위해 아래와 같이 Raw 데이터를 구성한다.

$$RawData^k = \{ACC_{x,y,z}^k, \omega_{x,y,z}^k, Mag_{x,y,z}^k, \alpha_c^k, \alpha_g^k\}. \quad (12)$$

여기서, $Acc_{x,y,z}^k$, $\omega_{x,y,z}^k$, $Mag_{x,y,z}^k$ 는 스마트폰 3축에서 측정되는 가속도, 자이로스코프, 지자기 센서값이고 α_c 와 α_g 는 식 (1)-(3)에서 계산하는 이동 방향이다.

그림 3은 Raw 데이터의 수집 시점과 과정에 대한 상태 전이도를 도시하며, 아래 과정을 따라 진행된다.

초기 상태인 “Not Walk” 단계에서는 걸음이 감지되지 않으면 프로그램을 초기 상태로 유지하고 걸음 감지되면 “Step Queue” 상태로 변환한다. 걸음 감지 기준은 식 (13)과 같다.

$$\{a^k > a_+, a^{k+b} < a_-, b_{min} < b < b_{max}\}. \quad (13)$$

스마트폰 IMU 센서에서 얻은 가속도 벡터는 LCS (Local Coordinate System)로 계산된 값이므로 GCS로 변환해야 한다²⁰⁾. 여기서, a^k 는 RawData의 $Acc_{x,y,z}$ 값을 GCS로 계산한 수직 선형 가속도 값이고, a_+ , a_- 는 감지 기준인 상한과 하한 값이며 본 논문에서는 각각 1 m/sec^2 와 -0.8 m/sec^2 으로 설정

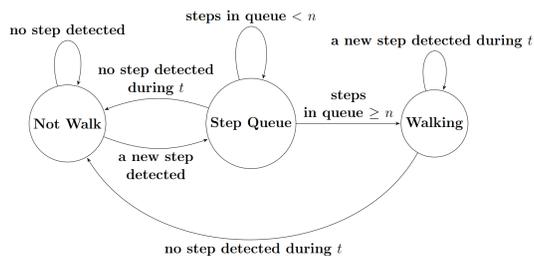


그림 3. 데이터 수집 시스템 상태 전이도
Fig. 3. State transition diagram of data collection

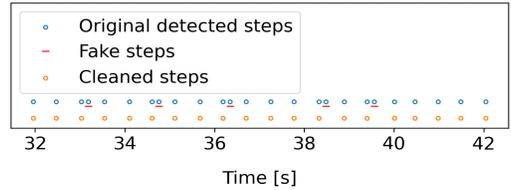


그림 4. 제안 알고리즘을 사용한 이상치 검출 및 제거 예시
Fig. 4. Example of outlier detection and elimination by the proposed algorithm

하였다. 또한, b 는 걸음 하나의 지속시간이고 b_{min} , b_{max} 는 지속 시간의 상한과 하한 값이며 각각 0.1 sec, 0.6 sec로 설정하였다. 각 파라미터 값의 설정에 대한 설명은 [20]에서 찾을 수 있다.

“Step Queue” 상태에서 시간 t 동안 새로운 걸음이 감지되지 않으면 “Not Walk” 상태로 변환되며, 새로운 걸음이 감지되면 IMU 센서 데이터가 메모리 대기열로 저장된다. 저장된 대기열 길이가 n 이상이 되면 “Walking” 상태로 전환된다.

“Walking” 상태에서 시간 t 동안 새로운 걸음이 감지되지 않으면 “Not Walk” 상태로 전환되고, “Walking” 상태에서 첫 번째 걸음이 감지되면 대기열에 있는 IMU 데이터를 먼저 스마트폰 데이터베이스에 저장하고 이후에는 걸음이 감지될 때마다 IMU 센서 데이터를 바로 데이터베이스에 저장한다. 본 논문에서는 t 를 2 sec로 n 을 3으로 설정하였다. 이는 사용자의 상태가 쉽게 “Walking” 상태로 전환되고 쉽게 “Not Walk” 상태로 돌아갈 수 있는 것을 의미한다.

위와 같은 데이터 수집 시스템은 다른 동작 (간단한 스마트폰 이동 등)을 걸음으로 인식하지 않게 되며, 보행 중에만 센서 데이터가 생성되도록 보장해 사용자가 보행 중 잠시 멈추고 다른 작업 (예: 메시지 전송, 다른 응용 프로그램 사용 등)을 수행하더라도 측위 결과에 영향이 없도록 보장한다. 데이터는 송실대 학교 중앙 광장 및 도로 등의 실외 공간과 전형적인 사무 공간의 복도로 볼 수 있는 베어드홀 1층과 실내외가 연결되었으며 넓은 홀 구조를 가진 형남공학관 2층에서 수집되었으며 총 4,398개의 RawData를 수집하였다.

3.2 데이터 전처리 및 훈련 데이터 작성

센서 데이터는 높은 정확도보다는 저전력, 작은 공간 점유 등을 목표로 설계한 IMU 센서의 한계와 보행 환경, 사용자의 움직임 등에 의해 잡음이 상당히 포함되어 있고 이에 따라 이상치가 발생한다. 데이터

전처리 과정은 훈련 데이터에서 이러한 이상치를 제거하여 모델에 잘 적용하고 성능을 향상할 수 있다.

사용자의 보행 이외의 다른 움직임에 의해 발생한 가속도로 인해 추가로 저장된 걸음 데이터는 전체 측위 시스템의 정확도를 낮출 수 있고, 해당 데이터는 사용자 걸음에 의해 생성된 데이터가 아니므로 학습에 영향을 줄 수 있으며, 이와 같은 데이터는 식 (14)에 따라 학습에서 제외한다.

$$\delta^k < \{\delta\}_\mu - 2\{\delta\}_\sigma. \quad (14)$$

여기서, $\{\cdot\}_\mu$ 와 $\{\cdot\}_\sigma$ 는 각각 수집된 데이터를 기반으로 계산한 각 걸음의 시간 간격 δ 의 평균과 표준편차이고, 그림 4는 실제 데이터 수집 과정에서 저장된 이상치가 포함된 데이터 집합과 기준에 따라 정제된 데이터 집합을 시간에 따라 도시하였다. 그림에서 이상 데이터는 인접 걸음과 간격이 약 100 msec로 나타났고 평균 간격과 큰 차이가 있어 이상 데이터로 간주하여 삭제되었다. 정제된 RawData에서 식 (15)와 같이 입력 특성 (Input Feature) 중 하나인 α_d^k 를 도출하였다.

$$\alpha_d^k = b(\alpha_d^{k-1} + \omega^k \Delta t) + (1-b)\alpha_c^k. \quad (15)$$

여기서 b 의 값은 0.98로 설정하며, α_d^k 의 계산은 주로 자이로스코프 센서값이 주도하고, 가속계/지자기 센서값은 자이로스코프의 드리프트 오차를 보정하는 것을 의미한다.

수집된 원시 센서 데이터에서 심한 잡음이 포함되어 있어 단순 이동 평균 (Simple Moving Average; SMA)을 사용하며, 현재 시점에 데이터에 발생하는 잡음을 완만하게 만들기 위해 과거의 데이터를 사용해 평균값을 아래와 같이 계산한다.

$$M(x_k) = \frac{1}{m} \sum_{i=k-m+1}^k x_i. \quad (16)$$

여기서, m 은 잡음 영향을 줄이기 위해 사용하는 과거 데이터의 참조 길이인 윈도우 사이즈 (Window Size)며, m 의 값이 너무 크면 지연 문제를 유발할 수 있어 본 논문에서는 $m = 2$ 로 설정하여 사용하였다.

스마트폰 IMU 센서는 서로 다른 측정 단위를 가지고 있어 저장되는 값의 범위도 각 센서마다 차이가 존재한다. 위와 같은 문제는 DL 기반의 모델에 입력 데

이터로 사용될 때 상대적으로 큰 특성 값에만 모델이 예측이 변화시킬 수 있으며, 데이터 크기의 정규화 (Normalization)를 진행해서 데이터 값이 적정한 공통 범위로 표현 되도록 한다. 입력 특성 X^k 와 출력 데이터 Y^k 는 아래와 같이 구성된다.

$$NAcc_{x,y,z}^k = \frac{M(Acc_{x,y,z}^k) - \{Acc_{x,y,z}\}_{\min}}{\{Acc_{x,y,z}\}_{\max} - \{Acc_{x,y,z}\}_{\min}}, \quad (17)$$

$$N\omega_{x,y,z}^k = \frac{M(\omega_{x,y,z}^k) - \{\omega_{x,y,z}\}_{\min}}{\{\omega_{x,y,z}\}_{\max} - \{\omega_{x,y,z}\}_{\min}}, \quad (18)$$

$$N\alpha_c^k = \frac{M(\alpha_c^k) + \pi}{2\pi}, \quad (19)$$

$$N\alpha_d^k = \frac{M(\alpha_d^k) + \pi}{2\pi}, \quad (20)$$

$$X^k = \{NAcc_{x,y,z}^k, N\omega_{x,y,z}^k, N\alpha_c^k, N\alpha_d^k\}, \quad (21)$$

$$Y^k = \{N\alpha_o^k\}. \quad (22)$$

여기서, $\{\cdot\}_{\max}$ 와 $\{\cdot\}_{\min}$ 는 각 특성 데이터 집합의 최대값과 최소값이고 식 (16)의 SMA 방식을 사용해 데이터의 잡음 감소를 고려하였다. 입력 특성 X 중 $NAcc_{x,y,z}$ 와 $N\omega_{x,y,z}$ 는 가속계와 자이로스코프 센서의 원시 데이터이고 두 센서는 사용자의 행동을 측정한다. 지자기 센서는 GCS의 각도를 제공하는데 실내 환경에서 지자기 원시 데이터는 불안정하고 모델 예측의 불안정을 유발할 수 있어서 여기서는 그의 대신 상대적으로 안정한 α_c 와 α_d 를 사용한다. 출력 데이터 $Y^k = \{N\alpha_o^k\}$ 는 지도상에 표기된 방위각과 실제 이동을 통해 얻은 데이터를 비교하여 잡음으로 인해 잘못 측정된 방위각을 수정하여 데이터를 레이블링 (Labelling) 할 수 있다. 본 논문에서는 학습을 위한 데이터 수집 지역의 방위각을 비교하여 α_o^k 를 설정하였으며, 식 (23)와 식 (24)에 따라 α_o^k 와 $N\alpha_o^k$ 를 서로 전환한다.

$$N\alpha_o^k = \frac{\alpha_o^k + \pi}{2\pi}, \quad (23)$$

$$\alpha_o^k = 2\pi N\alpha_o^k - \pi. \quad (24)$$

3.3 DL 모델 훈련

딥러닝은 일반적으로 주어진 문제를 함수 근사 문제, 즉 회귀 문제 (Regression Problem) 또는 분류 문제 (Classification Problem)로 접근할 수 있다. 본 논문에서는 이동 방향 추정 문제를 회귀 문제로 간주하여 함수 근사시키며, 그림 5는 제안 기법에서 사용되는 다층 퍼셉트론 (Multi-Layered Perceptron; MLP) 모델의 구조를 도시하였고, 모델의 매개변수는 표 2와 같이 설정하였다.

학습의 경사 소실 (Gradient Vanishing)과 폭주 (Exploding)을 방지하기 위해 LeCun Normal 초기화 방법을 사용하였으며, 각 은닉층 (Hidden Layer) 위에 추가적인 정규화 성능을 기대할 수 있는 배치 정규화 (Batch Normalization) 층을 추가하였다. 또한, 함수를 회귀로 근사할 수 있도록 하는 손실 함수 (Loss Function)는 Mean Absolute Error (MAE), Mean Square Error (MSE), Root MSE (RMSE) 등이 있고, 본 연구에서는 아래 식을 감소시키는 방향으로 가중치를 업데이트하는 MAE 방식을 사용하여 함수를 회귀 근사한다²¹⁾.

$$MAE(N\alpha_o, \hat{N}\alpha_o) = \frac{1}{N} \sum_{k=1}^N |N\alpha_o^k - \hat{N}\alpha_o^k|. \quad (25)$$

MAE는 회귀 문제에 사용되는 MSE와 비교하였을 때, 작은 오류에 대해 더 큰 손실 값을 반환하고 큰 오

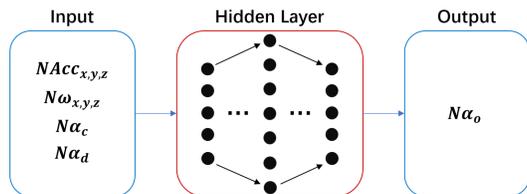


그림 5. 제안 기법에 사용되는 MLP 모델 개요
Fig. 5. MLP model overview

표 2. KF 알고리즘에 사용된 파라미터
Table 2. Parameters used in the KF algorithm

Model parameters	Values
Number of hidden layers	6
Number of trainable parameters	10,001
Activation function	SELU
Initializer	LeCun Normal
Loss function	MAE
Optimizer	RMSprop
Number of epochs	150

류에 대해 더 작은 손실 값을 반환한다²²⁾. 즉, MAE는 오류가 큰 비정상적인 걸음 데이터에 작은 손실 값을 반환해 모델의 가중치 업데이트에 반영이 적게 되어 이상 데이터에 대해 견고성을 갖는다. 위와 같은 설정으로 인해 본 연구에서 사용되는 MLP 모델은 잡음이 심한 실내 환경에서 발생하는 이상값에 초점을 맞추지 않고, 일반적인 상황에서 발생하는 드리프트 또는 자기장 영향 문제에도 정확한 방향을 예측하는 것에 초점을 맞췄다.

IV. 실험 결과

실험을 진행하기 위해 Android OS 기반 스마트폰에서 동작하여 데이터를 수집하고 딥러닝 모델 훈련은 Google사의 기계학습 라이브러리 Tensorflow를 사용하였다. 제안하는 딥러닝 기반 방향 추정 모델의 실내 방향 안정화 성능을 검증하기 위해, 복잡한 보행 경로의 구성이 가능하고 좁은 복도, 넓은 홀 구조, 다양한 전시물이 배치되어 있는 숭실대학교 환경직기념관 2층과 승덕경상관 2층에서 실험을 진행하였다. 실험에서 총 395개의 IMU 센서값을 수집하였다. 측위를 진행하기 위해서 보폭을 아래와 같이 계산하여 k 번째 걸음의 예측 지점 (\hat{x}_k, \hat{y}_k) 를 갱신한다.

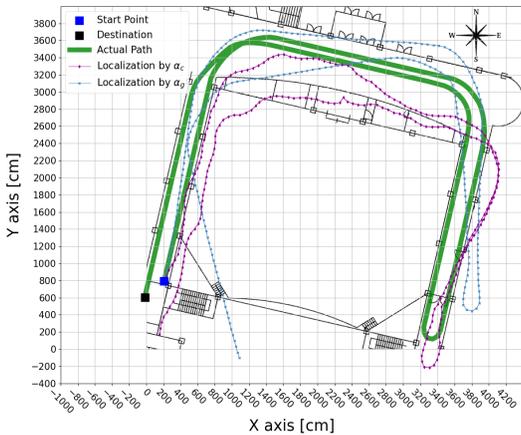
$$\lambda_k = \tau \sqrt{\alpha_{\max} - \alpha_{\min}}, \quad (26)$$

$$(\hat{x}_k, \hat{y}_k) = (\hat{x}_{k-1}, \hat{y}_{k-1}) + \lambda_k |\sin(\alpha) \cos(\alpha)|. \quad (27)$$

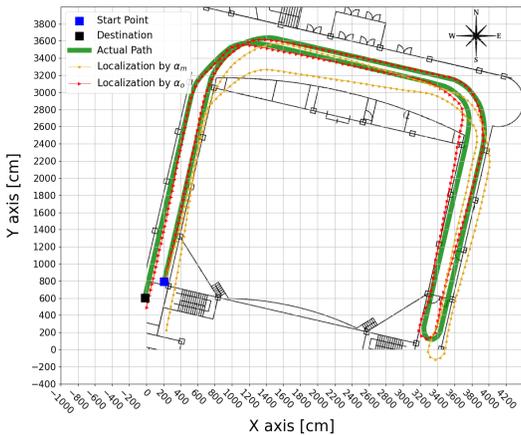
여기서, τ 는 보폭 보정 계수이고 본 논문에서는 $\tau = 0.52$ 로 사용했으며, 식 (27)의 α 는 제안 기법, KF 등 각 기법에서 계산된 이동 방향이 사용된다.

제안하는 DL 모델은 IMU 센서값을 이용하여 사용자의 이동 방향을 추정한다. IMU 중 지자계 센서의 측정은 주변 환경의 자기장이 주도하고 자이로스코프 센서의 측정은 회전 속도가 주도한다. 사용자나 환경 조건에 따라 가속도가 여러 패턴이 있을 수 있는데 다양한 가속도 패턴에 대해 모델 성능을 검증하기 위해 추적 실험에서 이동 패턴 (e.g., 회전 속도, 이동 속도)은 일정하지 않고 건물 구조, 보행자, 장애물 등에 따라 변화한다. 그림 6은 실험 장소 중 환경직기념관 2층에서의 각 PDR 기법별 측위 결과이다. 실내 환경에서 심한 자기장 간섭이 있어서 이동 방향의 갱신은 자이로스코프가 주도하기로 설정하고 그림에서 사용되는 KF는 $Q = 0.0001$, $R = 25$ 로 설정하였다. 실험의

이동 경로는 초록색의 실제 경로를 따라 걸으면서 얻은 IMU 센서값을 사용하여 각 PDR 기법들과 실제 경로와의 차이를 확인하였으며, 보라색과 하늘색 경로는 식 (1)-(3)으로 이동 방향을 계산하는 PDR 기법을 사용해서 얻은 측위 결과이고, 빨간색과 황금색 경로는 각각 KF 융합 알고리즘과 제안 기법을 사용해서 얻은 측위 결과이다. 그림 6(a)에서 앞서 언급한 기존 이동 방향 추정 기법의 문제점인 실내 자기장 잡음으로 인해 이동 방향 α_c 가 영향을 받아 불안정한 방향 각으로 인해 보라색 경로의 결과를 얻었으며, 자이로 스코프의 드리프트 문제로 인해 사용자가 이동 방향을 전환할 때마다 발생하는 누적 오류로 인해 하늘색



(a) α_y 와 α_c 의 측위 결과



(b) α_m 와 α_o 의 측위 결과

그림 6. 송실대학교 환경직기념관 2층에서의 PDR 기법별 측위 결과
Fig. 6. Tracking results on the second floor of Han Kyungchik Memorial Hall at Soongsil University

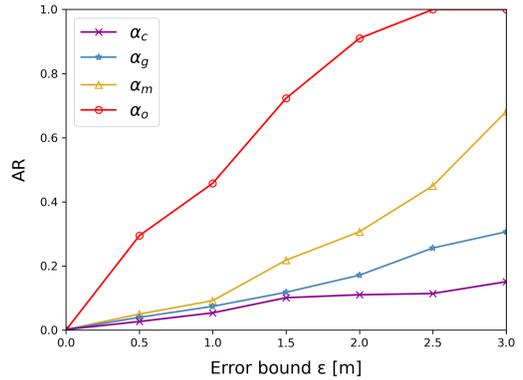


그림 7. 송실대학교 환경직기념관 2층과 송덕정상관 2층의 추적 정확도
Fig. 7. AR on the second floor of Han Kyungchik Memorial Hall and Sung-deok Hall at Soongsil University

의 이동 경로를 얻었다. 그림 6(b)에서 KF의 측위 결과는 α_c 와 α_y 를 융합하여 상대적으로 안정하고 정확한 결과를 얻었는데 드리프트 문제와 외부 자기장의 영향으로 실제 이동 경로와의 차이를 확인할 수 있었으며, 특히 드리프트 문제와 자기장 영향이 동시에 발생하는 홀 공간 (그림 6에서 $x: 1400 \sim 3200, y: 2600 \sim 3400$)에서 오류가 생기고 전체 측위 결과 정확성에 영향을 주었다. 이와 대조적으로 제안 기법에서는 매개변수 설정이 없이 기존 센서 융합 알고리즘에서 사용하기 어려운 IMU 데이터를 추가적인 입력값으로 사용함으로써, 기존 기법에 대비 정확한 측위 결과를 반환하는 것을 확인할 수 있었다.

각 PDR 기법의 정량적인 측위 정확도를 비교하기 위해 k 번째 걸음의 실제 위치 (x_k, y_k) 와 PDR을 통해 계산된 (\hat{x}_k, \hat{y}_k) 위치의 거리 D 를 계산하고, 설정된 오차 범위 ϵ 내부에 있는지에 따라 측위 정확도 AR (Accuracy Rate)를 아래와 같이 산출하였다.

$$D_k = \sqrt{(x_k - \hat{x}_k)^2 + (y_k - \hat{y}_k)^2}, \quad (28)$$

$$AR = \frac{\#\{D_k | D_k < \epsilon\}}{N}. \quad (29)$$

여기서 식 (29)의 $\#\{\cdot\}$ 는 조건을 만족시키는 경우의 수이고 N 은 걸음 개수이며, 그림 7의 측위 정확도 결과를 통해 제안하는 기법의 정확성과 안정화 성능을 확인할 수 있었다.

V. 결 론

실내 측위 오차의 원인은 주요 방향 추정 오차이다. 실내에서 이동 방향 추정의 정확도를 향상시키기 위해, 본 논문에서 추가적인 장비 없이 스마트폰 IMU 센서만 이용하여 별도 파라미터 설정이 없는 IMU Raw 데이터를 사용이 가능한 DL 기반의 이동 방향 추정 기법을 제안하였고, 기존의 이동 방향 추정 알고리즘과 융합 알고리즘을 비교하여 제안 기법의 실험 결과를 확인하였다. 기존 방안과 비교할 때 제안 기법 결과의 안정화 성능과 정확도를 확인할 수 있었고, KF 방안과 비교할 때 매개변수의 설정이 없어도 IMU Raw 데이터를 입력 특징으로 DL 모델에 사용되어 정확하게 사용자 이동 방향을 추정이 가능한 것을 검증하였다. 향후에는 스마트폰 센서 데이터에 포함하는 잡음을 처리하는 알고리즘의 개발과 DL 모델의 구조, 훈련 데이터 입력 특징의 설계 등을 통해 제안된 기법의 성능을 개선하는 연구를 진행할 예정이다.

References

[1] A. Poulouse and D. S. Han, "UWB indoor localization using deep learning LSTM networks," *Applied Sci.*, vol. 10, no. 18, pp. 6290-6319, Sep. 2020.

[2] 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 2021-Spring*, pp. 1-7, Helsinki, Finland, Apr. 2021.

[3] T. L. N. Nguyen, T. D. Vy, K.-S. Kim, C. Lin, and Y. Shin, "Smartphone-based indoor tracking in multiple-floor scenarios," *IEEE Access*, vol. 9, pp. 141048-141063, Oct. 2021.

[4] D. Cock, W. Joseph, L. Martens, J. Trogh, and D. Plets, "Multi-floor indoor pedestrian dead reckoning with a backtracking particle filter and viterbi-based floor number detection," *Sensors*, vol. 21, no. 13, pp. 4565-4594, Jul. 2021.

[5] A. Poulouse, B. Senouci, and D. S. Han, "Performance analysis of sensor fusion techniques for heading estimation using smartphone sensors," *IEEE Sensors J.*, vol. 19, no. 24, pp. 12369-12380, Dec. 2019.

[6] L. Pei, D. Liu, D. Zou, R. L. F. Choy, Y. Chen, and Z. He, "Optimal heading estimation based multidimensional particle filter for pedestrian indoor positioning," *IEEE Access*, vol. 6, pp. 49705-49720, Sep. 2018.

[7] S. A. Ludwig and A. R. Jimenez, "Optimization of gyroscope and accelerometer/magnetometer portion of basic attitude and heading reference system," *IEEE INERTIAL 2018*, pp. 1-4, Lake Como, Italy, Mar. 2018.

[8] K.-S. Kim and Y. Shin, "Deep learning -based pdr scheme for predicting movement changes for smartphone users," *J. KICS*, vol. 46, no. 11, pp. 1908-1919, Nov. 2021.

[9] I. Klein, Y. Solaz, and G. Ohayon, "Pedestrian dead reckoning with smartphone mode recognition," *IEEE Sensors J.*, vol. 18, no. 18, pp. 7577-7584, Sep. 2018.

[10] T. Feigl, S. Kram, P. Woller, R. H. Siddiqui, M. Philippsen, and C. Mutschler, "A bidirectional LSTM for estimating dynamic human velocities from a single IMU," in *Proc. IPIN 2019*, pp. 1-8, Pisa, Italy, Sep. 2019.

[11] L. Arvai and S. Homolya, "Filtering methods for indoor magnetic compass," in *Proc. ICC 2020*, pp. 1-5, Slovak Republic, Oct. 2020.

[12] D. Piyabongkarn, R. Rajamani, and M. Greminger, "The development of a MEMS gyroscope for absolute angle measurement," *IEEE Trans. Contr. Syst. Technol.*, vol. 13, no. 2, pp. 185-195, Mar. 2005.

[13] D. Roetenberg, H. J. Luinge, C. T. M. Baten, and P. H. Veltink, "Compensation of magnetic disturbances improves inertial and magnetic sensing of human body segment orientation," *IEEE Trans. Neural Syst. & Rehab. Eng.*, vol. 13, no. 3, pp. 395-405, Sep. 2005.

[14] Z. Chen, H. Zou, H. Jiang, Q. Zhu, Y. Soh, and L. Xie, "Fusion of WiFi, smartphone sensors and landmarks using the Kalman filter for indoor localization," *Sensors*, vol. 15, no. 1, pp. 715-732, Jan. 2015.

[15] R. Putta, M. Misra, and D. Kapoor, "Smartphone based indoor tracking using magnetic and indoor maps," in *Proc. IEEE*

ISSNIP 2015, pp. 1-6, Singapore, Apr. 2015.

- [16] S. P. Tseng, W.-L. Li, C.-Y. Sheng, J.-W. Hsu, and C.-S. Chen, "Motion and attitude estimation using inertial measurements with complementary filter," in *Proc. ASCC 2011*, pp. 863-868, Kaohsiung, Taiwan, May 2011.
- [17] A.-J. Baerveldt and R. Klang, "A low-cost and low-weight attitude estimation system for an autonomous helicopter," in *Proc. IEEE ICIES 1997*, pp. 391-395, Budapest, Hungary, Sep. 1997.
- [18] G. Milette and A. Stroud, *Professional Android Sensor Programming*, Ch. 6-7, John Wiley & Sons, 2012.
- [19] S. Romaniuk and Z. Gosiewski, "Kalman filter realization for orientation and position estimation on dedicated processor," *Acta Mechanica et Automatica*, vol. 8, no. 2, pp. 88-94, 2014.
- [20] Z. Chen, Q. Zhu, and Y. C. Soh, "Smartphone inertial sensor-based indoor localization and tracking with iBeacon corrections," *IEEE Trans. Industrial Inform.*, vol. 12, no. 4, pp. 1540-1549, Aug. 2016.
- [21] G. Aurelien, *Hands-on Machine Learning with Scikit-Learn, Keras & TensorFlow*, 2nd Ed., Ch. 1-2, O'Reilly Media, 2019.
- [22] C. J. Willmott and K. Matsuura, "Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance," *Climate Res.*, vol. 30, no. 1, pp. 79-82, 2005.

임 준 상 (Chenxiang Lin)



2021년 2월 : 고려대학교 컴퓨터학과 졸업
 2021년 3월~현재 : 숭실대학교 전자공학과 석사과정
 <관심분야> 컴퓨터공학, 인공지능, 통신공학
 [ORCID:0000-0001-7240-4096]

신 요 안 (Yoan Shin)

한국통신학회논문지 Vol. 34, No. 1 참조
 [ORCID:0000-0002-4722-6387]