

스마트폰 사용자의 이동 변화량 예측을 위한 딥러닝 기반 보행자 관성항법 기법

김관수*, 신요안°

Deep Learning-Based PDR Scheme for Predicting Movement Changes for Smartphone Users

Kwan-Soo Kim*, Yoan Shin°

요약

실내에서 스마트폰 사용자의 위치를 추적하기 위해 이동 변화량을 센서 기반으로 계산하는 보행자 관성항법 (Pedestrian Dead Reckoning; PDR)에서, 사용자 보폭 추정 문제, 보행 경로에 따른 센서 드리프트 문제 등을 해결하여 측위 정확도를 향상하기 위한 연구가 활발히 진행되고 있다. 본 논문에서는 기존 보행자 관성항법에서 발생하는 문제를 해결하기 위해, 사용자가 건물 외부에서 스마트폰을 가지고 걸을 때 얻을 수 있는 가속계, 지자기, 자이로스코프의 센서값을 전처리하여 입력 데이터로 하고, 걸음마다 기록된 GPS 위성 신호로 계산된 위치 변화량을 출력 데이터로 구성해 심층 신경망을 지도 학습시켜, 실외 뿐 아니라 실내에서도 스마트폰 사용자의 보행 중 이동 변화량을 예측하는 딥러닝 기반의 PDR 기법을 제안한다. Android OS 기반 삼성전자의 Galaxy S8 스마트폰에서 앱을 구축하고, 딥러닝 프레임은 스마트폰에 이식이 쉬운 Google사의 TensorFlow를 사용하여, 제안하는 딥러닝 기반 PDR 기법의 측위 성능을 확인하였다.

키워드 : 보행자 관성항법, 딥러닝, 지도 학습, 스마트폰 기반 실내 측위, 범 지구 위성항법 시스템

Key Words : Pedestrian dead reckoning, Deep learning, Supervised learning, Smartphone-based indoor localization, Global navigation satellite system

ABSTRACT

The pedestrian dead reckoning (PDR) using the inertial measurement units (IMUs) inside the smartphones, calculates the movement variations track the location of indoor smartphone users, and the research is actively underway to improve the localization accuracy by solving user stride estimation and sensor drift problems along the walking paths. In this paper, we propose a deep learning-based PDR method to address the issues arising from the existing PDR schemes. The proposed PDR method pre-processes the sensor values of accelerators, geomagnetic sensors, and gyroscopes that users can obtain when walking with smartphones outside the building, and constructs the location variations computed by GPS satellite signals as the output data. By using the supervised deep neural networks with the configured data, we predict changes in the movement of smartphone users, while walking outdoors as well as indoors. We built the apps on Android OS-based Samsung Galaxy S8 smartphones, utilized the deep learning framework of Google's TensorFlow which is easy to port to smartphones, and verified the localization performance of the proposed method.

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

• First Author : School of Electronic Engineering, Soongsil University, kwansk93@soongsil.ac.kr, 학생회원

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

논문번호 : 202107-162-C-RN, Received July 12, 2021; Revised July 28, 2021; Accepted August 4, 2021

1. 서 론

최근 들어, 실내에서 스마트폰 사용자를 위한 내비게이션, 재난 발생 시 정확한 구조 위치 파악과 같은 다양한 상황에서 필요한 고도화된 실내 측위 (Indoor Localization) 기술이 요구되고 있다. 스마트폰을 사용한 실내 측위 기술은 측위 시 사용하는 자원에 따라 2가지 종류로 구분할 수 있으며, 스마트폰 내부 자원인 관성 측정 유닛 (Inertial Measurement Unit; IMU)에서 사용자의 움직임에 따라 변화하는 가속계 (Accelerometer), 자이로스코프 (Gyroscope), 지자기 (Magnetic Field) 센서값을 사용하여 사용자의 이동 변화량을 계산하는 PDR 기법과 외부 자원인 Wi-Fi AP (Access Point) 또는 Beacon의 BLE (Bluetooth Low Energy) 신호 등 무선통신 신호의 세기와 방향을 활용하는 기법 등이 있다.

Wi-Fi AP 또는 Beacon의 BLE 신호를 활용하여 사용자의 실내 위치를 계산하기 위해, 이미 알려진 위치에 설치된 다수 AP와 스마트폰 기기 사이의 거리를 TOA (Time of Arrival)로 계산한 후 삼변측량 (Trilateration) 기법을 사용해 위치를 계산하거나, AP의 수신 신호 세기 (Received Signal Strength)를 저장한 데이터베이스를 기반으로 사용자 위치를 추정하는 핑거프린트 (Fingerprint) 기법이 있다. AP의 신호를 사용하여 측위를 하는 경우 실내 환경에 따라 발생하는 경로 손실 (Path Loss), 다중 경로 (Multi-path), 쉐도잉 (Shadowing) 등의 무선통신 채널 문제로 인해 오차가 발생하며, 정확한 측위를 위해서는 AP와 스마트폰 기기 간의 LoS (Line-of-Sight) 상황이 안정하게 보장되어야 한다.

스마트폰 기반의 PDR 기법은 사용자의 보폭과 이동 방향을 스마트폰 내 IMU, 즉 센서값을 기반으로 계산하여 변화하는 위치를 측정하는데, 두 가지 요소에서 발생하는 문제점을 해결하기 위한 연구가 활발히 진행되고 있다. 첫 번째로 보폭 추정은 가속계 센서값과 보정계수를 사용하여 걸음 길이를 계산한다. 특히, 보정계수 설정은 경험적이거나 생체 역학적 접근법에 따라 결정되는데, 각 사용자에게 적합한 보정계수 설정이 중요하다¹⁻³⁾. 두 번째, 이동 방향의 계산은 스마트폰의 IMU 데이터로 계산한 지역 좌표계 (Local Coordinate System; LCS) 방향을 회전행렬 (Rotation Matrix)를 사용해 전역 좌표계 (Global Coordinate System; GCS)로 변환하여 사용하는데, 이동 방향 추정 시 가장 큰 문제 중 하나는 사용자의 보행 경로의 따라 발생하는 센서의 드리프트 (Drift)

현상이고, 그때 각속도 값을 적분하면 방향에 대해 누적 오차가 발생해 측위 성능에 감소시킨다.

스마트폰 IMU 기반의 PDR 기법에서 발생하는 문제점을 해결하기 위해, 연속되는 시간에서 측정된 센서값을 샘플링 (Sampling)한 후 샘플 데이터 집합의 통계적 지표를 활용해 이상치를 감쇄하는 파티클 필터 (Particle Filter), 칼만 필터 (Kalman Filter) 기법과⁴⁻⁶⁾, 이와 대조적으로 각 센서의 응답 특성에 맞게 필터를 통과시킨 후 적절한 비율로 결합해 사용하는 상보 필터 (Complementary Filter; CF)를 사용하여 방향각 추정에 불필요한 잡음을 감소시키는 기법이 있다^{7,8)}. 최근에는 고도화된 실내 측위 기술을 위해 인공 신경망 (Artificial Neural Network) 기반 딥러닝 (Deep Learning; DL) 방식의 다양한 기법으로 측위 모델을 만들고 학습에 사용되는 데이터를 스마트폰 내외부 자원으로 구성해 모델을 학습시켜 성능을 향상하는 연구가 활발히 진행되고 있다⁹⁻¹¹⁾.

앞서 언급한 실내 측위 기법과 다르게, 실외에서는 GNSS (Global Navigation Satellite System)으로서 미국의 GPS (Global Positioning System), 러시아의 GLONASS (GLObal NAVigation Satellite System) 등의 위성에서 송신하는 신호를 사용하여 사용자의 위치를 계산한다. GPS 측위 방식은 크게 GPS 위성의 신호만을 감지하는 S (Stand-alone) 타입과 인터넷망의 보조를 받는 A (Assisted) 타입으로 구분된다. 스마트폰에서는 측위 성능과 배터리 효율을 고려해, 대부분 A-GPS 타입을 사용한다. 그림 1(a)는 실제 시험 시 사용되는 스마트폰을 사용해 사용자의 걸음에 따라 측정된 GPS 위치와 실제 이동 경로를 지도 위에 표시하였고, 그림 1(b)는 그림 1(a)의 GPS 위치를 자세히 관찰하기 위해 좌표축 상에 도식하였다. 여기서, 연속적인 걸음을 통해 GPS 신호를 감지하는 스마트폰에서 두 걸음 사이의 오차 성분이 일정하다고 가정하면, 실제 지도상의 위치에서는 상당한 오차가 발생하지만 사용자의 걸음에 따른 이동 방향과 거리는 큰 오차가 없다고 할 수 있고 실제 그림 1의 측정 결과를 통해 이를 확인할 수 있었다.

본 논문에서는 스마트폰 IMU 센서 기반의 PDR 기법에서 발생하는 보폭 추정 문제, 센서의 드리프트 문제를 해결하기 위해, 건물 외부에서 스마트폰 사용자가 걸으면서 저장되는 다중 센서값과 GPS 위치 변화량을 활용한 딥러닝 기반의 PDR 기법을 제안한다. 스마트폰 내부의 IMU 데이터와 앞서 확인한 GPS 위치 데이터의 가정과 실제 측정 결과를 바탕으로 딥러닝의 지도 학습 데이터를 구성하고, 이를 통해 사용자

$$R_y^{-1}(\phi)R_x^{-1}(\theta)F_A = R_z(\psi)[0 \ 0 \ g], \quad (7)$$

$$F_{Ax}\cos\phi - F_{Ay}\sin\phi = 0, \quad (8)$$

$$F_{Ax}\cos\theta + F_{Ay}\sin\theta\sin\phi + F_{Az}\sin\theta\cos\phi = 0, \quad (9)$$

$$\phi = \tan^{-1}\left(\frac{F_{Ax}}{F_{Ay}}\right), \quad (10)$$

$$\theta = \tan^{-1}\left(\frac{-F_{Ax}}{F_{Ay}\sin\phi + F_{Az}\cos\phi}\right). \quad (11)$$

가속계 센서만 사용하면 Pitch 각도와 Roll 각도만 추정할 수 있으며, Yaw 각도 ψ 는 가속계 센서에서 구한 ϕ, θ 와 지자기 센서값을 결합하여 아래와 같이 계산한다.

$$F_M = R_x(\phi)R_y(\theta)\underbrace{R_z(\psi)B[\cos\alpha \ 0 \ \sin\alpha]^T}_H, \quad (12)$$

따라서, 위의 수식에 따라

$$\begin{aligned} H &= R_y^{-1}(\theta)R_x^{-1}(\phi)F_M \\ &= \begin{bmatrix} F_{Mx}\cos\theta + F_{My}\sin\theta\sin\phi + F_{Mz}\sin\theta\cos\phi \\ F_{My}\cos\phi - F_{Mz}\sin\phi \\ F_{Mx}\sin\theta + F_{My}\cos\theta\sin\phi + F_{Mz}\cos\theta\cos\phi \end{bmatrix} \\ &= [F_{CMx} \ F_{CMy} \ F_{CMz}]^T, \end{aligned} \quad (13)$$

$$\cos\psi B\cos\alpha = F_{CMx}, \quad \sin\psi B\cos\alpha = F_{CMy}, \quad (14)$$

$$\psi = \tan^{-1}\left(\frac{-F_{CMy}}{F_{CMx}}\right). \quad (15)$$

여기서, 식 (12)의 α 는 일반적으로 스마트폰 화면이 하늘 방향을 향하고 있을 때 y 축 방향과 지구 자기력 선 사이의 각도이고, B 는 그 때 측정된 자기력의 크기이다. IMU 지자기 센서에서 측정된 센서값 F_M 과 회전행렬, 지구의 자기력은 식 (12)의 관계로 표현할 수 있으며, F_{CM} 는 기존 지자기 센서값과 가속계 센

서에서 계산한 ϕ, θ 를 사용한 보정된 지자기 센서값이다. Yaw 각도 ψ 는 보정된 지자기 센서값을 사용해 추정한다^[12].

또 다른 방향 추정 센서인 자이로스코프 센서는 사용자의 회전에 따른 각속도를 반환해 주며, 아래 식에 따라 적분을 통해 3축의 방향을 계산한다^[13].

$$\left[\omega_{i,k} = \int_0^{\Delta t} \omega_i(\tau) d\tau \right]_{i=x,y,z}, \quad (16)$$

$$Gyro_0 = [\theta + \omega_{x,0} \phi + \omega_{y,0} \psi + \omega_{z,0}]^T, \quad (17)$$

$$Gyro_k = Gyro_{k-1} + [\omega_{x,k} \ \omega_{y,k} \ \omega_{z,k}]^T. \quad (18)$$

여기서, $\omega_{i,k}$ 는 k 번째 걸음에서 감지된 자이로스코프 센서의 3축에 따라 측정된 회전각이고, Δt 는 회전이 감지된 시간이다. 자이로스코프는 회전 속도를 반환해 주기 때문에, 초기 방향은 지자기와 가속계에서 측정된 각도를 사용한다. PDR 기법에서는 일반적으로 사용자들이 주로 스마트폰을 보고 걸을 때의 주요 회전 축인 $-z$ 축을 중심으로 계산된 방위각 ψ 를 사용하여 위치 추정에 사용한다.

사용자의 보폭은 스마트폰의 가속도 센서를 사용하여 아래와 같이 계산한다.

$$\lambda_{Kim} = \tau_{Kim} \left(\sum_{k=1}^N |F_{A_k}| / N \right)^{\frac{1}{3}}, \quad (19)$$

$$\lambda_{Weinberg} = \tau_{Weinberg} (F_{A_{\max}} - F_{A_{\min}})^{\frac{1}{4}}. \quad (20)$$

여기서, 식 (19), (20)은 가속계 센서의 값을 사용해서 사용자의 보폭을 추정하는 대표적인 방식이고^[1-2], 보행자의 보정계수 τ 와 걸음 사이에서 측정되는 가속계 센서값 F_{A_k} 또는, 최대값 $F_{A_{\max}}$ 과 최소값 $F_{A_{\min}}$ 을 사용하여 걸음 길이를 계산한다.

이동 방향과 보폭이 결정되면, k 번째 걸음에서 측정된 보폭 λ_k 와 이동 방향 ψ_k 을 사용하여 위치 $L_k(x_k, y_k)$ 를 아래와 같이 갱신한다.

$$L_k = L_{k-1} + \lambda_k [\sin(\psi_k) \ \cos(\psi_k)]^T. \quad (21)$$

III. PDR 기반 측위 오차 요소 및 해결 방안

일반적으로 스마트폰 센서의 설계 목적은 높은 정확도보다는 저전력에 초점을 맞추었다. IMU 데이터를 사용하여 사용자의 위치를 갱신하는 PDR 기법은, 각 센서의 측정 방식에 따라 주변 환경 혹은 측정 장비에서 발생하는 잡음과 센서의 측정 한계로 인한 영향을 쉽게 받아 오차가 발생한다. 앞의 문제를 해결하기 위해 센서 융합 (Sensor Fusion)을 통한 문제점 보완이 중요하다.

IMU에서 주변 환경에 의한 영향을 가장 많이 받는 센서는 지자기 센서이다. 지자기 센서는 가장 높은 자기력을 발산하는 방향을 자북으로 인지하는데, 인접한 위치에 지구 자기력보다 강한 자성체가 있으면 자기장이 왜곡되어 측정된다. 이러한 현상은 2 종류로 분류하는데, 첫 번째로 스마트폰 내부 스피커 등에 존재하는 영구자석에 의한 영향을 받는 하드 아이언 효과 (Hard Iron Effect; HIE) 및 두 번째로 스마트폰 외부의 전자기기, 건축 철골 구조 등으로 인해 영향을 받는 소프트 아이언 효과 (Soft Iron Effect; SIE)이다. HIE는 스마트폰 구조 설계 시 오프셋 (Offset)을 측정 한 후 제거하여 문제를 해결한다. SIE는 사용자가 스마트폰을 8자로 흔들어 보정하는 방법을 사용하면 일시적으로 완화되지만, 보행 경로 따라 환경이 변화하는 상황에서는 영구적인 해결 방법은 아니다. 지자기 센서가 주변 환경으로 인해 변동성이 심해지면 스마트폰 사용자의 방위각 ψ 의 정확한 추정이 불가능해 측위 성능이 감소한다^[14].

스마트폰에 내장된 자이로스코프 센서는 사용자의 회전을 감지하기 위해 코리올리의 힘 (Coriolis Force)를 사용하여 각속도를 측정한다^[15].

$$F_{Coriolis} = 2m(\vec{v} \times \vec{\Omega}). \quad (22)$$

여기서, m 은 센서에 존재하는 물체의 질량, \vec{v} 는 물체의 속도, $\vec{\Omega}$ 는 각속도를 의미한다. 측정된 각속도는 식 (16)을 사용하여 회전 시간에 따른 방향각을 추정한다. 각속도를 적분하는 과정에서 사용자의 보행 경로에 따라 드리프트 (Drift) 문제로 인해 방향각에 누적 오차가 발생한다^[13, 16].

기존의 문제점을 해소하고 높은 정확도를 가진 방향을 도출하기 위해, 각 센서의 특성을 고려하고 잡음을 감소시키는 필터를 적용해 그림 3의 가속계, 지자

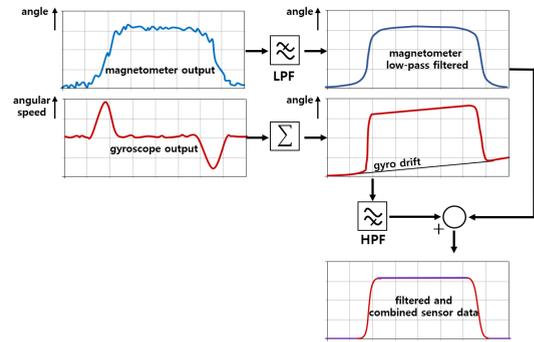
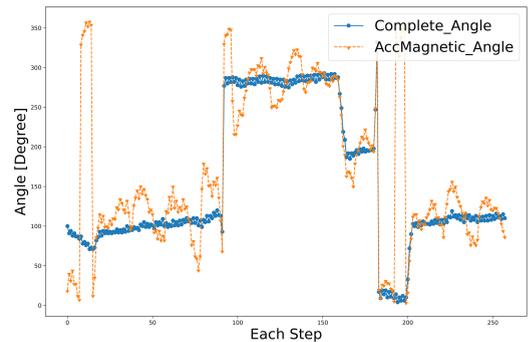
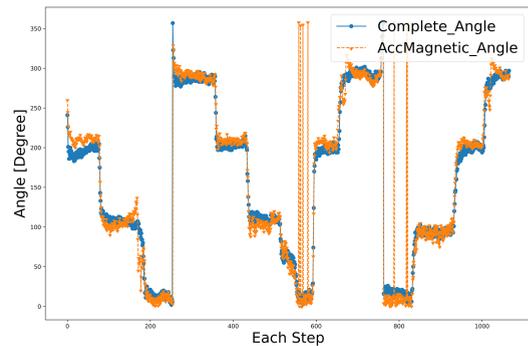


그림 3. 센서값의 필터 적용 및 상보필터 구조[18]
Fig. 3. Filter application of sensor values and complementary filter structure[18]

기, 자이로스코프 센서값을 결합하여 방향을 추정하는 CF 방식이 존재한다^[7,8]. CF는 고주파 영역에서 좋은 응답 특성을 가지는 자이로스코프 센서에 HPF (High Pass Filter)를 적용하고, 저주파 영역에서 응답 특성이 좋은 가속도 센서에 LPF (Low Pass Filter)를 적용한 값을 결합하여 아래와 같이 각도 CA_k 를 산출한



(a) Indoor



(b) Outdoor

그림 4. 가속계, 지자기 방위각과 CF 방위각의 실내외 비교 그래프
Fig. 4. Graph of indoor and outdoor comparisons of accelerometer, magnetic azimuth, and CF azimuth

다¹⁷⁾.

$$CA_k = \beta M + (1 - \beta)N$$

$$M = (\omega_{i,k} \Delta t + CA_{k-1}), N = [\phi_k \theta_k \psi_k]^T \quad (23)$$

여기서, β 는 CF에 적용되는 가중치 값이다.

그림 4는 CF의 가중치 β 를 0.97로 적용하여 결합한 센서값을 방위각 측정에 사용했을 때, 실제 스마트폰에서 안정적인 방위각을 도출하는지 비교 확인하기 위한 측정 결과이다. 측정 환경은 방위각의 변동성의 차이를 확인하기 위해 사용자는 일정 걸음 동안 고정된 방향을 향해 걸었다. 그림 4(a)는 실내에서의 측정 결과인데, 건물 철골구조와 자성체의 존재로 보행 경로에 따라서 지자기 센서값의 변동이 증가하여 측정된 방위각 (주황색) 또한 불안정한 것을 확인할 수 있었고, CF (파란색)를 사용해 측정된 방위각이 안정화되는 것을 확인하였다. 그림 4(b)는 실외에서 안정적인 가속계 지자기 방위각과 CF 방위각을 비교하여 유효성을 확인하였다.

IV. 제안하는 DL-PDR 기법

걸음 사이의 센서 데이터를 지속적으로 샘플링하여 이상치를 감쇄시키는 기존의 필터링 기법에서는 스마트폰 내부의 저장 공간과 계산 자원을 상당히 사용해 지속적인 측위 방법의 문제가 발생하고, 딥러닝 기법을 적용한 기존의 PDR 기법에서 모델을 학습하기 위해 라벨 데이터의 Ground-truth를 사람이 직접 결정하여 발생하는 데이터의 생성 비용 및 객관성 문제가 발생한다. 본 장에서는 기존 PDR 기법에서 발생하는 문제점을 해결하기 위해 본 논문에서 제안하는 데이터 처리 이외에 별도의 설정이 필요 없는 딥러닝 기반의 PDR 기법에 대해 논의한다. 제안하는 DL-PDR 기법의 학습 시 레이블 (Label) 데이터로 사용될 객관적이고 자동으로 측정되는 GPS 데이터의 Ground-truth 측정 과정과 성능개선 시나리오를 서술하고, 이를 사용자 이동 변화량으로 대응하고 걸음을 감지할 때만 센서 데이터를 수집하는 시스템을 사용하여 측위 할 수 있도록 훈련 데이터 구성, 수집 과정 및 수집된 데이터를 학습에 적합한 데이터로 변형시키는 전처리 방식 및 모델 훈련 과정을 기술한다.

4.1 실외 환경 GPS 측위 데이터

스마트폰에서 GPS 신호를 사용해 측위를 하기 위

해 지구로부터 약 20,000km 상공에 위치한 인공위성의 신호를 수신 받을 수 있는 실외 공간에서 사용자의 위치를 추정한다. 스마트폰에서 사용하는 GPS 측위 방식인 A-GPS는 스마트폰을 GPS 연산 서버와 연결해 GPS 시작 속도를 향상시키고, 인공위성과의 데이터 링크가 고정되기까지 소요되는 TTFT (Time to First Fix)를 줄이기 위한 위치 획득 체계를 사용한다.

사용자의 걸음에 따라 수신된 GPS 신호를 사용한 위치 추정은 아래의 식에 따라 계산된다¹⁹⁾.

$$\vec{r}_j^k = c(T_{u,j}^k - T_{s,j}^k), \quad (24)$$

$$|\vec{r}_j^k| = \sqrt{(x_j^k - x_u^k)^2 + (y_j^k - y_u^k)^2 + (z_j^k - z_u^k)^2} \quad (25)$$

$$\vec{u}^k = [x_u^k \ y_u^k \ z_u^k] + \epsilon^k. \quad (26)$$

여기서, \vec{r}_j^k 는 k번째 걸음에서 사용자가 받은 j번째 GPS 위성과 사용자 사이의 벡터이고, $T_{s,j}^k$ 는 위성에서 신호를 송신한 시간, $T_{u,j}^k$ 는 사용자가 신호를 수신받은 시간, c 는 빛의 속도이다. 위치를 추정하기 위해서 최소 4개 이상의 위성에서 신호를 수신받아야 하고, 최종적인 사용자의 위치 벡터 \vec{u}^k 는 통신 채널 환경 및 위성 시계 오차 등에 의해 오차 ϵ^k 가 발생한다. 추정된 사용자 벡터 \vec{u}^k 를 이용해 지구 좌표계의 위도 (Latitude)와 경도 (Longitude) 값으로 변환한다.

4.2 DL-PDR 기법의 성능개선 시나리오

그림 5는 본 논문에서 제안하는 DL-PDR 기법의 성능개선 시나리오를 도시하였는데, 스마트폰 사용자가 실외에서 탐색 이동 경로를 연속적으로 걸었을 때, 기존의 PDR 기법에서는 센서값의 문제로 인해 붉은

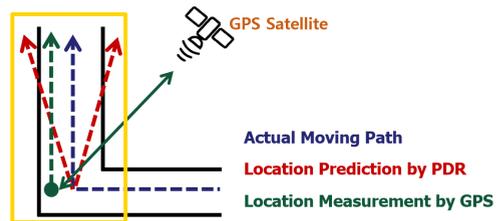


그림 5. DL-PDR 성능개선 시나리오
Fig. 5. DL-PDR Performance improvement scenario

색 경로와 같이 위치가 추정된다.

식 (26)의 오차 ϵ^k 는 연속적인 두 걸음에서 무선통신 채널 환경과 발생하는 잡음이 유사해 오차의 관계가 $\epsilon^k \approx \epsilon^{k+1}$ 으로 가정하면, GPS 위치는 실제 위치와는 오차가 발생하지만, 사용자 벡터의 차 $\vec{u}^{k+1} - \vec{u}^k$ 의 이동 방향과 거리는 실제 사용자와 유사한 녹색 경로와 같이 추정된다. DL-PDR 기법은 그림 5의 노란색 영역에서 결합이 있는 센서값으로 인해 발생하는 기존의 PDR 데이터를 비교적 정상적인 GPS로 측정된 위치의 변화량으로 입력력 데이터를 구성하여, DL 모델이 회귀 (Regression) 예측이 가능하도록 학습시켜 이동 경로에 따라 발생하는 센서의 문제점을 해결한다.

4.3 훈련데이터 구성 및 수집 과정

인공지능 (Artificial Intelligence) 기술의 근간이 되는 기계학습 (Machine Learning)과 DL 기법은 훈련데이터를 어떤 방식으로 구성하는지에 따라 모델의 학습결과와 실제 성능에 중대한 영향을 미친다. 특히, 지도 학습의 경우에는 입력 특성과 출력 레이블의 관계성에 따라 모델 훈련 후 결과값의 유효성도 변화한다.

DL-PDR에 사용되는 훈련데이터의 입력 특성은 사용자의 이동 변화량을 극좌표계 (Polar Coordinate)로 표현 가능한 스마트폰 IMU의 3축에서 측정된 가속도, 지자기, 자이로스코프 센서값으로 구성하였고, 출력 레이블은 사용자의 이동 변화량을 직교좌표계 (Orthogonal Coordinate)로 표현 가능한 GPS 신호의 위도와 경도의 변화량으로 구성하였다. 그림 6은 DL-PDR의 훈련데이터 수집 과정을 도시하였는데, 스마트폰 사용자가 GPS 신호를 수신받을 수 있는 실외

에서 걸을 때, 사용자의 걸음 이동이 감지되면, 걸음마다 IMU 센서값과 위도, 경도 값을 스마트폰 내부 DB에 저장한다. 실제 알고리즘 개발을 위한 데이터는 서울시 동작구, 관악구, 그리고 광진구에서 수집되었다.

4.4 데이터 전처리 및 DL-PDR 모델 학습

4.4.1 데이터 전처리

수집된 스마트폰 IMU 및 GPS 데이터는 DL의 회귀 모델 중 하나인 MLP (Multi Layer Perceptron) 모델 학습에 사용된다. 수집된 Raw 데이터는 학습에 적합한 형태로 구성되기 위해 전처리 과정이 요구된다.

GPS의 위도와 경도는 스마트폰에서 최대 소수점 13자리 (단위: °)로 측정되며, 출력 레이블 Y 로 구성하기 위한 걸음 사이의 변화량은 다음과 같이 계산된다.

$$\Delta Lat_k = Latitude_{k+1} - Latitude_k, \quad (27)$$

$$\Delta Long_k = Longitude_{k+1} - Longitude_k, \quad (28)$$

$$Y_k = [\Delta Lat_k \ \Delta Long_k]^T. \quad (29)$$

여기서 계산되는 변화량은 매우 작은 값이고, 이 값을 회귀 모델을 훈련하는데 적합하지 않아 지리좌표의 거리를 cm 단위로 확대해 문제를 해결하였다. 기존의 위도와 경도값을 cm 로 계산하기 용이한 (단위: ° ' ")단위로 변환하고 길이와 Y_k 는 다음과 같이 변환된다²⁰⁾.

$$1''_{lat} = 2\pi R/360^2 = 30.83m, \quad (30)$$

$$1''_{long} = 2\pi R \cos \phi / 360^2 = 24.72[m], \quad (31)$$

$$Y_k = [\Delta Lat_k 1''_{lat} \ \Delta Long_k 1''_{long}]^T. \quad (32)$$

여기서, R 은 측정된 지구의 반지름 약 $6,378 km$ 이고, ϕ 는 대한민국 서울 기준의 위도 37° 이다. 이는 지구 둘레를 기준으로 위도의 간격은 위치에 상관없이 같지만, 경도의 경우에는 위도에 따라 간격이 변화한다.

잡음 성분이 많이 포함된 데이터를 사용하여 일반화(Generalization)된 학습 모델을 얻기 위해선 모델을 단순화하거나, 입력 특성의 개수를 줄이는 방법을 사

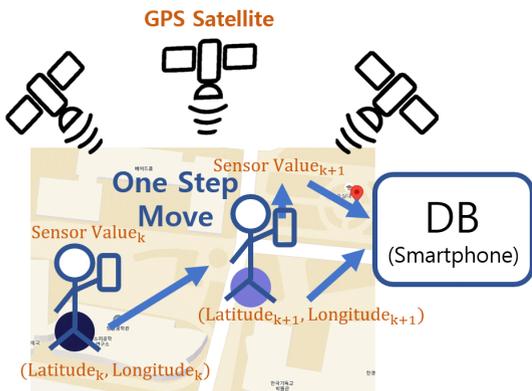


그림 6. DL-PDR 훈련을 위한 데이터수집 과정
Fig. 6. Data gathering process for DL-PDR training

용해야 한다^[21]. IMU 데이터에는 잡음 성분이 상당히 포함되어 있어, 적절한 형태로 특성을 결합하여 특성 개수를 줄여야 한다. 두 걸음에서의 가속도와 자이로 스코프의 크기, CA의 중간값을 사용해 보폭과 방향을 추론하는데 필요한 3가지 주요성분으로 압축했다. 또한, 입력 특성 X_k 의 서로 다른 물리량을 정규화(Normalization)하기 위해 다음과 같이 재구성하였다.

$$M(s_k) = (s_k + s_{k+1})/2, \quad (33)$$

$$NF_k = (M(|F_{A_k}|) - |F_A|_\mu) / |F_A|_\sigma, \quad (34)$$

$$N\omega_k = (M(|\omega_k|) - |\omega|_\mu) / |\omega|_\sigma, \quad (35)$$

$$NCA_k = M(CA_k) / 360, \quad (36)$$

$$X_k = [NF_{A_k} \ N\omega_k \ NCA_{z_k}]. \quad (37)$$

여기서, $M(\cdot)$ 은 중간값 계산에 사용한 함수이고, $|\cdot|_\mu$, $|\cdot|_\sigma$ 는 수집된 전체 데이터에서 계산된 평균과 표준 편차값이다.

그림 7은 수집된 데이터에서 GPS 값으로 계산된 보폭과 방위각에 따른 데이터 분포 형태를 도시하였다. 본 논문에서는 GPS에서 발생하는 오차가 $\epsilon^k \approx \epsilon^{k+1}$ 으로 가정하였는데, 채널 환경과 잡음의 변화가 일정하지 않은 공간에서 수집된 데이터는 보폭이 너무 작거나 크게 계산돼, 해당 데이터를 학습

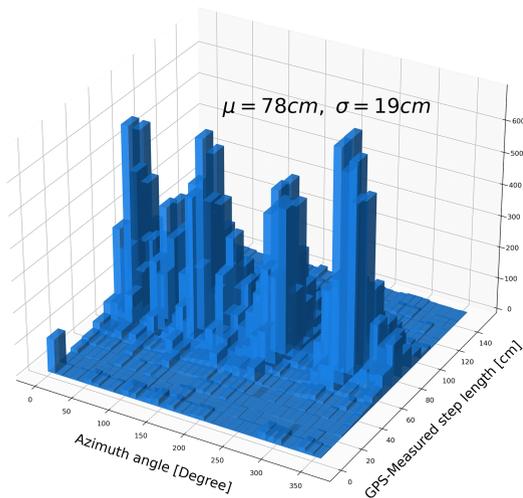


그림 7. 방위각과 보폭에 따른 데이터 분포
Fig. 7. Distribution of data by azimuth and step length

데이터로 사용하게 되면 모델의 측위 성능에 문제가 발생할 수 있다. 따라서, 측정된 평균 보폭 $\mu = 78cm$ 을 기준으로 $\pm 1\sigma$ 이내의 데이터를 선택하여 출력 레이블 Y 의 이상 데이터를 제거하였다.

그림 8은 선택된 데이터에서 입력 특성 X 의 이상 데이터를 확인하고 제거하기 위해, 출력 레이블 Y 의 데이터와 Y 데이터에 해당하는 스마트폰 센서로 측정된 방위각 NCA_{z_k} 를 점의 색으로의 표시한 비교 그래프를 도시하였다. GCS로 측정된 NCA_{z_k} 와 Y 의 방위각과 비교하기 위해, Y 로 계산된 각도를 아래 식에 따라 GCS 기준의 방위각으로 변환하였다.

$$\psi_{Y_k} = \tan^{-1} \left(\frac{\Delta Lat_k}{\Delta Long_k} \right) \frac{180}{\pi}, \quad (38)$$

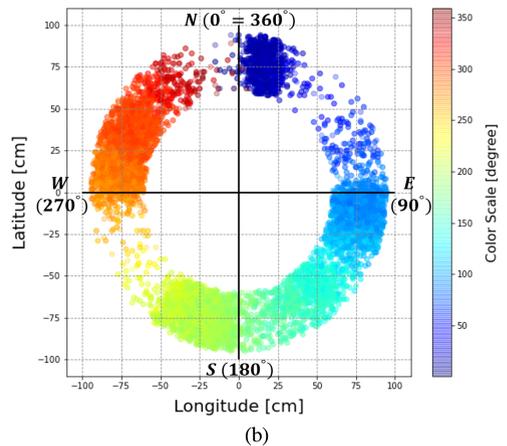
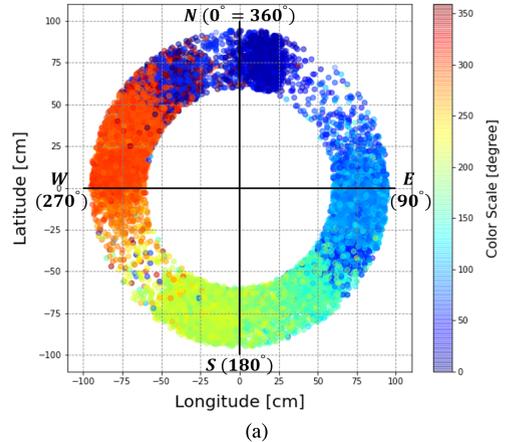


그림 8. NCA_{z_k} 와 ψ_{Y_k} 의 비교를 통한 데이터 정제 그래프
Fig. 8. Data refining graph with comparison of NCA_{z_k} and ψ_{Y_k}

$$\psi_{Y_k} = \begin{cases} 90^\circ + |\psi_{Y_k}|, & \text{if } -180^\circ \leq \psi_{Y_k} < 0^\circ \\ 90^\circ - \psi_{Y_k}, & \text{if } 0^\circ \leq \psi_{Y_k} \leq 90^\circ \\ 360^\circ - \psi_{Y_k} \bmod 90, & \text{if } 90^\circ < \psi_{Y_k} \leq 180^\circ \end{cases} \quad (39)$$

여기서, 식 (38)에서 계산된 각도 ψ_{Y_k} 는 $[-180^\circ, 180^\circ]$ 사이의 범위로 반환되며, 식 (39)에 따라 GCS 기준의 방위각으로 변환한다.

그림 8(a)에서 보행자의 이동에 따라 스마트폰이 흔들리거나 IMU 센서의 한계로 인한 오차가 많이 포함된 방위각 NCA_{z_k} 데이터를 확인할 수 있었고, 본문에서는 두 방위각의 차 $|\psi_{Y_k} - NCA_{z_k} \text{ RIGHT}|$ 가 15° 이상이면 데이터를 삭제하여 그림 8(b)의 정제 결과를 얻었다. 총 수집된 약 3만 6천 개의 데이터 중 선택된 정상 데이터는 약 1만 3천 1백 개로 축약되었다.

4.4.2 DL-PDR 모델 학습

회귀 예측은 입력 특성인 독립변수와 출력 레이블인 종속변수 간의 관계성을 계산하여 독립변수의 변화에 따라 종속변수를 예측한다. DL-PDR은 3개의 독립변수와 종속변수 2개 간의 관계성을 학습하기 위해, DL은 일반적으로 주어진 문제를 함수 근사 문제, 즉 회귀 문제 (Regression Problem) 또는 분류 문제 (Classification Problem)로 접근할 수 있다. 본 연구에서는 IMU 기반 측위를 회귀 문제로 다루며, 이를 위해 그림 9와 같은 전형적인 형태의 MLP 모델을 사용한다. 표 1은 MLP 모델에 사용된 매개변수 (Parameter)를 나타내었고, 깊이에 따른 모델의 일반화 및 측위 성능을 비교해보기 위해 은닉층 (Hidden Layer)를 제외한 나머지 성분은 같게 설정하였으며,

표 1. DL-PDR 모델에 사용된 매개변수
Table 1. Parameters used in DL-PDR models

Model parameter	Simple model	Complex model
Number of hidden layer	2	7
Number of weight params	1,330	11,154
Activation function	Elu	
Loss function	RMSE	
Optimizer	Adam	
Epoch	100	

활성화 함수와 손실 함수는 아래와 같다^[22-23].

$$\text{Elu}(x) = \begin{cases} a(e^x - 1), & \text{if } x < 0 \\ x, & \text{if } x \geq 0 \end{cases}, \quad (40)$$

$$L(y, \hat{y}) = \sqrt{\frac{1}{n} \sum_{i=1}^n (y - \hat{y})^2}. \quad (41)$$

여기서, 모델의 비선형성을 가질 수 있게 사용되는 활성화 함수 $\text{Elu}(\cdot)$ 는 x 가 0이하의 값을 가져도 출력 값을 가지고 미분이 가능해 음수값이 입력되어도 은닉층의 노드 (Node)들이 죽는 현상이 없으며, MLP 모델에 손실 함수 $L(\cdot)$ 을 RMSE (Root Mean Squard Error)로 적용하면 모델의 회귀 예측이 가능해진다.

학습은 그림 10과 같이 손실 함수값을 줄이는 방향으로 진행된다. 4.4.1. 절에서 언급한 데이터를 선택한 경우와 전체 데이터를 사용한 학습 결과를 비교하기 위해, 학습을 반복 진행함에 따라 계산된 훈련데이터와 평가데이터의 손실 함수값을 도시하였다. 훈련데이터 중 10%를 임의로 선택한 후, 훈련데이터에서 제외하여 평가 데이터로 사용하였다. 학습이 종료된 후, 전체 데이터를 사용해서 얻은 손실 함수값과 선택한 경우의 손실 함수값의 차이는 약 2.5배 (15cm)로 상당히 크게 나타났고, 선택한 데이터의 학습 결과가 더 작게 도출되는 것을 확인하였다. 또한, 모델 복잡도가 증가함에 따라 쉽게 발생할 수 있는 모델의 과적합 (Overfitting) 현상은 모델이 훈련데이터에만 예측이 잘 되도록 학습되어 훈련데이터와 평가데이터의 손실 함수값의 차이가 훈련이 진행되면서 점점 커질 때 모델이 과적합 되었다고 할 수 있다. 하지만, DL-PDR MLP 모델에 학습 결과인 그림 10을 보면, 학습데이터와 평가데이터로 얻은 손실 함수값이 수렴하고 있어 과적합 현상이 발생하지 않음을 확인하였다.

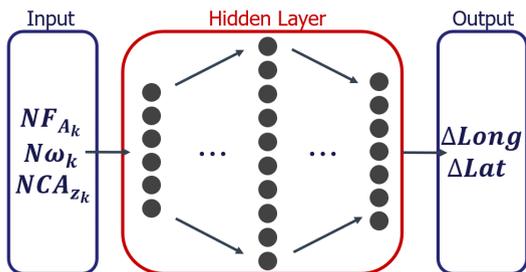
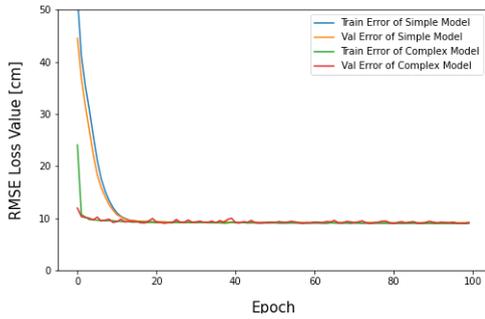
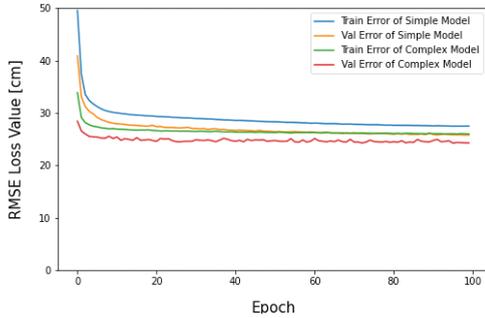


그림 9. DL-PDR MLP 모델 개요
Fig. 9. DL-PDR MLP model overview



(a) Progress learning with selected data



(b) Progress learning with all data

그림 10. 모델 복잡도 및 사용데이터에 따른 학습 결과
Fig. 10. Learning outcomes by model complexity and usage data

제안하는 기법의 추가적인 학습 성능개선과 모델의 객관성을 확보하기 위해서는 실외에서 걸으면서 학습 데이터를 축적하거나 DL-PDR 기법에 사용 가능한 데이터 증가 (Augmentation) 알고리즘을 개발하여 데이터양을 늘리는 방식을 사용하거나, 다른 적합한 DL 모델을 적용한다면 성능개선이 추가적으로 이뤄질 수 있다고 판단된다.

V. 실험 결과

제안된 DL-PDR 기법의 성능을 검증하기 위해 데이터 수집 응용 프로그램을 Android에서 구축하였고 실험기기인 삼성전자의 Galaxy S8로 학습데이터 축적 및 측위 실험에 사용하였다. 측위 모델을 학습시키기 위한 데이터 전처리 및 DL-PDR 모델은 Python과 스마트폰에 이식이 쉬운 Google사의 오픈 프레임워크 TensorFlow로 구축하였다. 실내의 공간에서 연속 측위 시 제안하는 DL-PDR 기법의 측위 안정성과 객관적인 측정 결과를 위해 훈련데이터를 수집할 때 사용 장소가 아니고, 실내의 연속 측위 실험이 가능하며 사용자 이동 경로의 다양성과 강당으로서 넓은 공간 및 다수의 가구가 배치되어 있어 다양한 외란 환경이 내

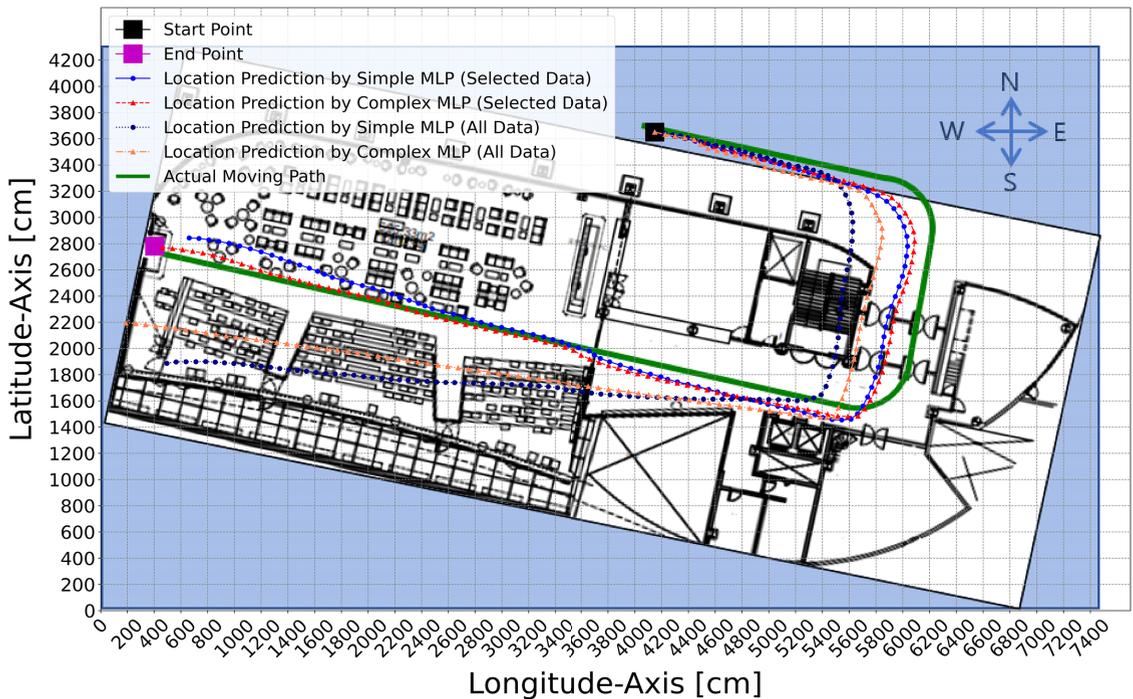


그림 11. 형남공학관 2층에서 실제 측정 결과
Fig. 11. Actual measurement results on the second floor of Hyungnam Engineering Building.

재되어 있는 숭실대학교 형남공학관 2층에서 실험을 진행하였다. 그림 11의 실외 시작 지점 (검은색 점)에서 실내 종료 지점 (보라색 점)까지 약 103m의 거리를 초록색 경로의 방향과 유사하게 이동하였으며, 실험기기의 화면은 천장을 향한 상태로 이동하며 발생한 모든 정보를 실험기기인 Galaxy S8에 저장하고 측위에는 IMU 센서 데이터만 사용됐다.

제안하는 PDR 기법의 모델 복잡도와 훈련에 사용된 데이터에 따라 구분된 4개의 모델을 사용한 측위 결과를 비교해보기 위해 그림 11에 보행자의 실제 경로와 측정 결과를 도시하였다. 모델 복잡도에 따라 측정된 결과는 보폭의 차이는 존재하였지만, 이동 방향성은 거의 일치하였다. 보폭 차이가 발생하는 원인은 훈련에 사용된 데이터에 포함된 잡음 성분으로 인해 발생하는 문제로 판단된다. 훈련에 사용 가능한 모든 데이터를 사용한 모델의 측위 결과 (남색, 주황색 경로)는 종료 지점을 향하는 추적 경로가 실제 이동 방향과 일치하지 않는 문제점을 발견하였다. 해당 문제는 종료 지점으로 걸어가갈 때 측정된 평균 방위각이 약 290° 이었는데, 입력 특성의 이상 데이터를 삭제하기 위해 사용된 그림 8(a)를 보면 290° 방위각 부분에 다른 방위각 데이터가 많이 혼재된 문제로 인해 정확도 감소가 발생하는 것으로 판단된다. 이와 반대로 이상 데이터를 삭제시킨 데이터로 훈련한 모델의 측위 결과 (빨강, 파랑 경로)에서는 모델의 복잡도에 따라 차이는 있지만, 측위 성능은 안정적이고 높은 것을 확인할 수 있었다.

VI. 결 론

본 논문에서는 기존의 PDR 기법에서 발생하는 센서 드리프트 문제, 사용자 보폭 추정 문제로 인해 측위 성능이 감소하는 문제를 해결하기 위해, GPS 데이터로 지도 학습을 진행한 MLP 모델을 사용해 측위 성능 향상 목적의 딥러닝 기반 PDR 기법을 제안하였다. 실험결과로부터 확인한 제안된 DL-PDR 기법의 측위 결과와 실제 이동 경로를 비교하였을 때 방향성과 보폭 추정 결과가 높은 안정성과 정확성을 가진 것을 확인하였고, 외부에서 걸으면 쉽게 얻을 수 있는 데이터 수집 시스템을 활용해 데이터 증가에 따른 추가적인 측위 성능 향상도 기대할 수 있다. 향후에는 추가적인 데이터 수집에 따른 DL-PDR의 성능개선을 위해 데이터에 포함된 잡음 요소를 줄이기 위한 알고리즘 개발, 수집된 데이터를 활용하여 PDR에 적용할

수 있는 다양한 DL 알고리즘과 기존에 연구된 PDR 기법과 비교하여 제안하는 기법의 정량적 개선 여부에 관한 연구를 진행할 예정이다.

References

- [1] J. W. Kim, H. J. Jang, D. H. Hwang, and C. Park, "A step, stride and heading determination for the pedestrian navigation system," *J. Global Positioning Syst.*, vol. 3, no. 1-2, pp. 273-279, 2004.
- [2] H. Weinberg, "Using the ADXL202 in pedometer and personal navigation applications," *Analog Devices Appl.*, Note AN-602, 2002.
- [3] J. Scarlet, "Enhancing the performance of pedometers using a single accelerometer," *Analog Devices Appl.*, Note AN-900, 2005.
- [4] 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.
- [5] F. Zampella, M. Khider, P. Robertson, and A. Jimenez, "Unscented Kalman filter and magnetic angular rate update (MARU) for an improved pedestrian dead-reckoning," in *Proc. IEEE/ION PLANS 2012*, pp. 129-139, Myrtle Beach, USA, Apr. 2012.
- [6] H. Li, H. Guo, Y. Qi, L. Deng, and M. Yu, "Research on multi-sensor pedestrian dead reckoning method with UKF algorithm," *Measurement*, vol. 169, pp. 108524, Feb. 2021.
- [7] G. Milette and A. Stroud, *Professional Android Sensor Programming*, Ch. 7, John Wiley & Sons, 2012.
- [8] H. G. Min, J. H. Yoon, J. H. Kim, S.-H. Kwon, and E. T. Jeung, "Design of complementary filter using least square method," *J. ICROS*, vol. 17, no. 2, pp. 125-130, Feb. 2011.
- [9] Y. Wang, Z. Li, J. Gau, and L. Zhao, "Deep neural network-based Wi-Fi/pedestrian dead reckoning indoor positioning system using

- adaptive robust factor graph model,” *IET Radar, Sonar & Nav.*, vol. 14, no. 1, pp. 36-47, Jan. 2019.
- [10] I. Klein and O. Asraf, “StepNet—Deep learning approaches for step length estimation,” *IEEE Access*, vol. 8, pp. 85706-85713, May 2020.
- [11] C. Chen, P. Zhao, C. X. Lu, W. Wang, A. Markham, and N. Trigoni, “Deep-learning-based pedestrian inertial navigation: Methods, data set, and on-device inference,” *IEEE IoT J.*, vol. 7, no. 5, pp. 4431-4441, May 2018.
- [12] J. W. Lee, *Android Sensor Story*, Chs. 4-6, Freelec, 2014.
- [13] A. D. King, “Inertial navigation - Forty years of evolution,” *GEC Rev.*, vol. 13, no. 3, pp. 140-149, 1998.
- [14] L. Árvai and S. Homolya, “Filtering methods for indoor magnetic compass,” in *Proc. ICCCC 2020*, pp. 1-5, Tatra, Slovakia, Oct. 2020.
- [15] V. Marotto, A. Serra, D. Carbouni, M. Sole, T. Dessi, and A. Manchinu, “Orientation analysis through a gyroscope sensor for indoor navigation systems,” in *Proc. IFSA Sensordevice 2013*, pp. 85-90, Barcelona, Spain, Aug. 2013.
- [16] 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.
- [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] P. Lawitzki, “*Android sensor fusion tutorial*,” available at <https://www.codeproject.com/Articles/729759/Android-Sensor-Fusion-Tutorial>[Accessed: 23-Jul.-2021].
- [19] C. J. Hegarty, *Understanding GPS/GNSS: Principles and Applications*, Ch. 2, Artech House, 2019.
- [20] A. Géron, *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems*, Ch. 1-2, O’Reilly Media, 2019.
- [21] A. A. B. Ariffin, N. H. A. Aziz, and K. A. Othman, “Implementation of GPS for location tracking,” in *Proc. IEEE ICSGRC 2011*, pp. 77-81, Shah Alam, Malaysia, Jun. 2011.
- [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, Dec. 2005.
- [23] D. A. Clevert, T. Unterthiner, and S. Hochreiter, “Fast and accurate deep network learning by exponential linear units (elus),” arXiv, pp. arXiv:1511.07289, Nov. 2015.

김 관 수 (Kwan-Soo Kim)



2020년 2월 : 숭실대학교 컴퓨
터공학 학사
2020년 2월~현재 : 숭실대학교
정보통신공학과 석사과정
<관심분야> 실내 측위, 인공지
능
[ORCID:0000-0003-2376-3636]

신 요 안 (Yoan Shin)

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