



저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.

다음과 같은 조건을 따라야 합니다:



저작자표시. 귀하는 원저작자를 표시하여야 합니다.



비영리. 귀하는 이 저작물을 영리 목적으로 이용할 수 없습니다.



변경금지. 귀하는 이 저작물을 개작, 변형 또는 가공할 수 없습니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리는 위의 내용에 의하여 영향을 받지 않습니다.

이것은 [이용허락규약\(Legal Code\)](#)을 이해하기 쉽게 요약한 것입니다.

[Disclaimer](#)

유 재 현 교수 지도
석사학위 청구논문

관성센서와 무선신호를 이용한
기계학습 기반 실내 위치 측정

2024

성신여자대학교 대학원
미래융합기술공학과
주 찬 영

관성 센서와 무선신호를 이용한
기계학습 기반 실내 위치 측정

유 재 현 교수 지도

이 논문을 석사학위논문으로 제출함

2023년 11월

성신여자대학교 대학원


미래융합기술공학과


주 찬 영


인 준 서

주찬영의 석사학위 논문으로 인준함

2023년 11월

심사위원장 오 장 민 (서명 또는 인) 

심사위원 유 재 현 (서명 또는 인) 

심사위원 김 우 진 (서명 또는 인) 

성신여자대학교 대학원

논문 개요

스마트폰의 발전과 위치 기반 서비스 (LBS: location-based service)가 증가함에 따라 전통적인 Global Navigation Satellite System (GNSS)의 신호가 도달하지 못하는 실내 환경에서의 측위 기술에 대한 수요가 증가하고 있다. 실내 측위를 위해 bluetooth low energy (BLE), ultra-wideband (UWB), Wifi 등 다양한 무선신호를 활용한 기술들이 연구되어왔다. 그 중, 현대의 실내 건물 대부분에는 Wifi access point (AP)가 설치되어 있어 Wifi received signal strength indicator (RSSI) 지문 데이터는 실내 위치 측위를 위한 중요한 센서 데이터 유형 중 하나로 고려되어왔다. 그러나 Wifi RSSI 측정값과 해당 위치의 쌍으로 이루어진 지문 데이터는 위치값을 라벨링하는 데 많은 수고와 시간이 많이 소요된다.

본 논문에서는 정적인 지문 데이터베이스 구축의 제한 사항을 극복하기 위해 실제 위치 데이터 없이 Wifi RSSI 위치추정 모델의 학습 기술을 제안한다. 실제 위치 대신 inertial measurements unit (IMU) 데이터를 사용하여 가상의 위치를 계산한다. 가상의 위치들 사이의 기하학적 관계를 목적함수로 모델링하여 초기 위치와 절대 방향 정보 없이 딥러닝 학습을 구현한다. 스마트폰을 손에 쥔 채 보행하는 단순한 방법으로 데이터를 수집할 수 있게 함으로써, 데이터 수집 효율성을 크게 개선할 수 있다.

학교나 지하철, 백화점 등 현대의 건물 대부분에는 Wifi AP가 설치되어 있으나 공사현장, 물류창고 등 아직 인프라가 형성되어 있지 않거나 외부 인프라와 단절되어있는 공간은 측위를 위한 적절한 양의 Wifi AP가 설치되어 있지 않다. 본 논문에서는 Wifi 무선신호의 음영 구역에 BLE 비콘을 설치하고 BLE RSSI와 Wifi RSSI를 통합함으로써 측위의 음영 구역을 최

소화하고 성능을 개선한다.

본 논문에서 제안한 학습 기법은 성신여자대학교 수정관 4층과 COEX 1층에서 검증되었다. 제안한 방법으로 학습한 모델의 출력 분포가 실제 지도에 매핑될 수 있음을 보였고, 지문 기반 측위 방법과 제안한 방법으로 학습한 측위 모델의 정확도를 비교하였다. 또한, 파티클 필터를 통해 AI-IMU 위치추정과 Wifi RSSI 위치추정을 융합하여 얻은 궤적이 실제 이동 궤적과 흡사함을 보였다. 더 나아가, Wifi와 BLE RSSI 통합 모델을 한 물류창고에서 검증하였고, 각각의 무선신호를 통합함으로써 성능이 개선됨을 확인하였다.

목 차

논문개요

I. 서론	1
II. 이론적 배경	4
1. 지문 기반 위치 측위	4
2. RSSI 특징 추출	5
1) PCA	5
2) 오토엔코더	7
3. 측위 기법	8
1) k-NN	8
2) 딥러닝	9
4. AI-IMU	9
III. 가상의 위치 좌표를 이용한 딥러닝 학습	11
1. 학습데이터 구성	11
2. 목적함수	14
IV. 파티클 필터	17
V. 실험 및 평가	20
1. 위치추정	20

1) 실험 환경	20
2) 제안한 모델 학습	22
3) 실험 결과	28
2. 파티클 필터	31
1) 실험 환경	31
2) 실험 결과	31
3. Wifi BLE 통합	35
1) 실험 환경	35
2) 실험 결과	36
VI. 결론	38

참고문헌

ABSTRACT

부 록

그림 목 차

[그림 2-1] 지문 기반 위치 측위 데이터 구성	4
[그림 2-2] PCA가 찾는 새로운 축의 시각화	6
[그림 2-3] 오토엔코더 구조	8
[그림 3-1] 제안하는 학습데이터 구성에 대한 컨셉	12
[그림 3-2] Wifi 시계열 데이터 집합의 시각화	14
[그림 3-3] 학습 알고리즘 플로우차트	16
[그림 5-1] 성신여자대학교 수정관 4층 보행 데이터 AI-IMU 궤적	22
[그림 5-2] 성신여자대학교 수정관 4층에서 제안한 모델의 학습 경과에 따른 학습데이터 분포	23
[그림 5-3] 성신여자대학교 수정관 4층 지도에 매핑한 제안한 모델의 학습데이터 분포	24
[그림 5-4] COEX 1층 보행 데이터 AI-IMU 궤적	25
[그림 5-5] COEX 1층에서 제안한 모델의 학습 경과에 따른 학습데이터 분포	27
[그림 5-6] COEX 1층 지도에 매핑한 제안한 모델의 학습데이터 분포 ..	28
[그림 5-7] 성신여자대학교 수정관 4층 테스트 지문 데이터의 CDF	29
[그림 5-8] 성신여자대학교 수정관 4층 테스트 지문 데이터의 분포, RP는 검정색, 지문 기반 측위 결과는 파란색, 제안한 모델의 결과는 빨간색 원으로 표시	30
[그림 5-9] 성신여자대학교 수정관 4층 파티클 필터에 의한 궤적. 보행자의 궤적은 빨간색 선, IMU 파티클은 파란색, Wifi 파티클은 초록색 원으로 표시	33

[그림 5-10] 파티클 필터 궤적, 실제 궤적은 검정색 점선, 파티클 필터 궤적은 빨간색 실선, 시작 위치는 원, 도착 위치는 X로 표시	34
[그림 5-11] 물류창고의 Wifi AP 및 비콘 설치 위치	36
[그림 5-12] Wifi BLE 통합 모델 CDF	37

표 목 차

[표 3-1] 제안한 위치추정 모델 학습 알고리즘	16
[표 5-1] 성신여자대학교 수정관 4층에서 사용된 오토엔코더 구조	21
[표 5-2] 성신여자대학교 수정관 4층에서 사용된 위치추정 모델 구조	21
[표 5-3] 성신여자대학교 수정관 4층 테스트 지문 데이터 측위 오차	29
[표 5-4] 성신여자대학교 수정관 4층 파티클 필터 측위 오차	33
[표 5-5] 물류창고 테스트 데이터 측위 오차	37

I. 서론

실외 공간의 위치추정은 Global Navigation Satellite System (GNSS)과 같은 범지구적 위성 항법 시스템을 사용하지만, 실내 환경에선 위성의 신호가 도달하지 못하여 실내 환경에 적합한 위치추정 기술의 개발이 필요하다. 전통적으로 무선 신호를 이용한 실내 위치추정에는 time of arrival (ToA)¹⁾, angle of arrival (AoA)²⁾ 및 received signal strength indicator (RSSI) 지문 기반 측위 방법³⁾이 사용된다. ToA와 AoA방법은 사전에 설치한 비콘에서 송신한 신호와 전파모형을 이용하여 송수신 거리, 각도를 구해 위치를 추정한다. 이 방법은 비콘 설치 비용과 배터리 교체 등과 같은 유지 보수가 필요하다.

반면 현대의 건물 대부분에 설치된 Wifi 공유기의 RSSI를 사용하는 방법은 초기 장비 구축에 비용이 들지 않는다는 장점이 있다. Wifi 지문 방법은 일정한 간격마다 주변 공유들로부터 수집한 신호 세기와 위칫값으로 이루어진 지문 데이터베이스를 구축하여 패턴을 분석한 후, 현재 신호 세기와 데이터베이스를 비교하여 위치를 추정한다. 지문 데이터의 패턴 분석을 위해 k-nearest neighbor (k-NN), random forest, 심층 신경망과 같은 기법들이 사용되어왔다. 하지만 Wifi 지문 기반 측위 방법은 지문 데이터베이스를 구축하는 데 많은 시간을 소모한다. 또한, 움직이는 대상체의 위치를

-
- 1) T. Feigl, et al., "Robust ToA-estimation using convolutional neural networks on randomized channel models," International Conference on Indoor Positioning and Indoor Navigation, 2021.
 - 2) W. Xiong, et al., "Two efficient and easy-to-use NLOS mitigation solutions to indoor 3-D AOA-based localization," International Conference on Indoor Positioning and Indoor Navigation, 2021.
 - 3) J.Yoo and K. H. Johansson "Semi-supervised learning for mobile robot localization using wireless signal strengths," International Conference on Indoor Positioning and Indoor Navigation, 2017.

추적하고자 하는 동적인 환경에 비해 지문 데이터는 정적으로 수집되기 때문에 측위 성능에 제한이 있다.

기존 데이터베이스 구축 비용을 줄이기 위한 다양한 연구가 진행되었다. 초기 radio map 구축 비용 감소 및 정확도 향상을 위한 Voronoi tessellation 기반 보간 방법⁴⁾, pedestrian dead reckoning 기반 병합 방법⁵⁾, crowdsourcing 방법⁶⁾⁷⁾ 또는 generative adversarial networks (GAN) 기반 방법⁸⁾⁹⁾ 등이 있다. 그러나, 이러한 방법들은 실내 환경에 대한 사전정보를 필요로 하거나, 신호 세기와 위치값으로 이루어진 전통적인 초기 radio map을 필요로 하거나, LiDAR와 같은 별도의 장비를 필요로 한다.

본 논문에서 제안하는 학습 기법은 inertial measurement unit (IMU)으로부터 추정된 가상의 위치 좌표를 이용한 학습 알고리즘을 적용한다. 보행하며 일정 주기에 따라 자동으로 데이터를 수집하므로, 사전에 정의한 위치 좌표에서 Wifi 지문 데이터를 수집하는 기존의 방법과 비교하여 빠른 데이터 수집이 가능하다. 상대 위치 변위를 나타내는 IMU 추정과 Wifi RSSI 데이터의 기하학 모델을 딥러닝으로 학습하여 결과적으로 비지도 위치추정 모델을 얻는다.

-
- 4) M. Lee and D. Han, "Voronoi tessellation based interpolation method for Wi-Fi radio map construction," IEEE Communications Letters, vol. 16, no. 3, pp. 404-407, 2012.
 - 5) P. Brida, et al, "Algorithm for dynamic fingerprinting radio map creation using IMU measurements," Sensors, vol. 21, no. 7, 2021.
 - 6) B. Huang, et al, "An online radio map update scheme for WiFi fingerprint-based localization," IEEE Internet of Things Journal, vol. 6, no. 4, pp. 6909-6918, 2019.
 - 7) X. Du, et al, "CRCLoc: A crowdsourcing-based radio map construction method for WiFi fingerprinting localization," IEEE Internet of Things Journal, vol. 9, no. 14, pp. 12364-12377, 2021.
 - 8) J. Seong and D. Seo, "Selective unsupervised learning-based Wi-Fi fingerprint system using autoencoder and GAN," IEEE Internet of Things Journal, vol. 7, no. 3, pp. 1898-1909, 2019.
 - 9) H. Zou, et al, "Adversarial learning-enabled automatic WiFi indoor radio map construction and adaptation with mobile robot," IEEE Internet of Things Journal, vol. 7, no. 8, pp. 6946-6954, 2020.

현대의 건물 대부분에는 Wifi AP가 설치되어 있으며 bluetooth low energy (BLE), RFID, UWB와 같은 다른 무선신호에 비해 높은 비트레이트와 확장성을 가지고 상대적으로 외부 환경의 영향을 덜 받는다.¹⁰⁾ 그러나, 공사현장이나 물류창고와 같이 아직 인프라가 형성되어 있지 않거나 외부 인프라와 단절되어있는 공간은 측위를 위한 적절한 양의 Wifi AP가 설치되어 있지 않다. 이러한 공간에서 측위를 진행하기 위해 Wifi AP와 비교하여 전력 소비가 적은 BLE 비콘은 좋은 대안이 될 수 있다.¹¹⁾ 본 논문에서는 Wifi 무선신호의 음영 구역에 비콘을 설치하고 두 무선신호의 RSSI를 통합함으로써 측위의 음영 구역을 최소화하고 성능 개선이 가능함을 보인다.

본 논문의 기여는 다음과 같다. 첫째, 실내 환경에 대한 사전정보 없이 학습할 수 있다. 둘째, 수집 기기의 최소 주기로 데이터를 수집하므로 수집 시간이 짧다. 셋째, 스마트폰의 내장되어 있는 센서의 데이터만으로 학습할 수 있다. 넷째, Wifi와 BLE RSSI 통합 모델을 통해 측위 성능을 개선하였다.

본 논문의 구성은 다음과 같다. 2장은 지문 기반 위치 측위, RSSI 특징 추출 및 측위 기법, AI-IMU의 이론적 배경을 설명하고, 3장에서 제안하는 알고리즘의 학습데이터 구성과 목적함수를 설명하고, 4장에서 보행자의 궤적을 추적하기 위한 Wifi와 AI-IMU 위치추정의 후처리 방법을 설명하고, 5장에서 실험 및 평가를 기술하고, 6장에서 결론을 맺는다.

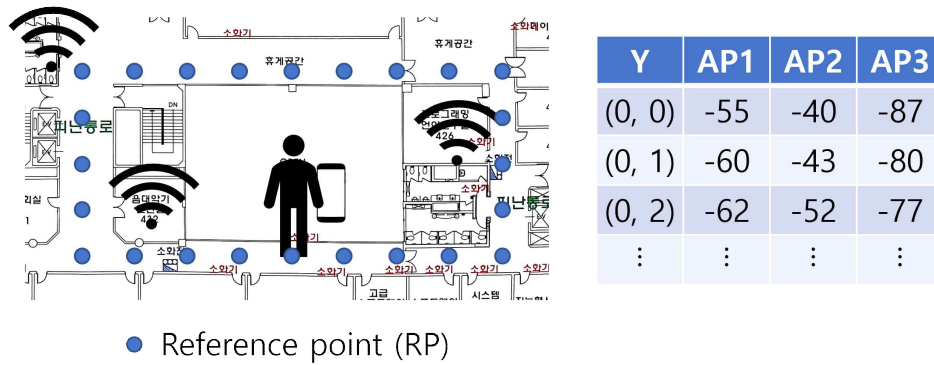
10) N. Singh, et al, "Machine Learning Based Indoor Localization Using Wi-Fi RSSI Fingerprints: An Overview," IEEE Access, vol. 9, pp. 127150-127174, 2021.

11) F.J. Aranda, et al, "Performance analysis of fingerprinting indoor positioning method with BLE," Expert Systems with Applications, vol. 202, 2022.

II. 이론적 배경

1. 지문 기반 위치 측위

기존 RSSI 지문 기반 위치 측위를 위해 지문 데이터베이스를 구축하는 과정을 [그림 2-1]에 나타내었다. 지문 데이터베이스의 구축은 측위를 진행하고자 하는 공간에 일정 간격으로 reference point (RP)를 지정하고 모든 RP에서 지문 데이터를 수집하는 절차로 이루어진다. 구축된 지문 데이터베이스는 수집한 위치와 RSSI 집합으로 나타낼 수 있다. RSSI는 대부분 -100dBm 부터 -30dBm 의 값을 가지며, 해당 RP에서 수집되지 않은 AP의 RSSI는 임의로 -100dBm 을 할당하였다.



[그림 2-1] 지문 기반 위치 측위 데이터 구성

지문 기반 측위는 구축된 지문 데이터베이스를 통한 기계학습 모델의 학습 단계와 테스트 단계로 나누어진다.

2. RSSI 특징 추출


AP m 개로부터 수집된 RSSI 집합을 식 (1)과 같이 정의한다.

$$s_i = (RSSI_i^1, RSSI_i^2, \dots, RSSI_i^m) \in R^m \quad (1)$$

수집된 RSSI는 학습을 위해 0에서 1사이의 값으로 정규화하였다. 각각의 AP의 신호가 수집되는 범위가 무한하지 않다. 따라서, 수집된 RSSI는 주변에 있는 적은 수의 AP의 신호만을 수집하기 때문에 대부분의 차원이 0의 값을 가진다. 이는 위치추정 정확도를 저하시키기 때문에 전처리를 통한 특징점 추출이 필요하다. 특징점 추출에 사용되는 기법으로는 principal component analysis (PCA), 오토엔코더 등이 있다.

1) PCA

PCA는 고차원 데이터를 저차원 공간으로 변환하는 기법으로, [그림 2-2]와 같이 m 차원 RSSI 집합에서 가장 큰 분산을 가지는 새로운 축을 첫 번째 주성분, 두 번째로 큰 분산을 가지는 새로운 축을 두 번째 주성분으로 하는 선형 좌표계로 선형 변환한다.



[그림 2-2] PCA가 찾는 새로운 축을 시각화

수집된 데이터의 총 개수가 N_s 이라고 할 때, RSSI 집합의 평균 μ 를 구한 후, 공분산 행렬 S 를 계산한다.

$$\mu = \frac{1}{N_s} \sum_{i=1}^{N_s} s_i \quad (2)$$

$$S = \frac{1}{N_s} \sum_{i=1}^{N_s} (s_i - \mu)(s_i - \mu)^T \quad (3)$$

공분산 행렬 S 의 고유값과 고유 벡터를 $\{\lambda_i\}_{i=1}^m$, $\{v_i\}_{i=1}^m$ 로 정의한다. 고유값이 크기 순서대로 정렬되어 있으며, 이에 대응하는 고유 벡터 또한 정렬되어 있다고 가정한다. 설계자가 지정한 d 개의 고유 벡터를 선택하여 변환행렬 Z 를 구한다.


$$Z = [v_1^T, v_2^T, \dots, v_d^T] \in R^{d \times m} \quad (4)$$

식 (4)의 변환행렬을 이용한 변환식 $Z \cdot r_i$ 을 통해 d 차원 특징 데이터를 구한다.

2) 오토엔코더

오토엔코더는 심층 신경망의 대표적인 비지도 학습 기법이다. [그림 2-3]은 오토엔코더의 구조를 나타낸다. 오토엔코더는 RSSI를 입력으로 d 차원의 특징 벡터로 변환하는 엔코더와, d 차원의 특징 벡터를 다시 RSSI로 복원하는 디코더로 이루어진다. 학습된 엔코더 모델 f 는 식 (5)이 변환식을 통해 식 (1)의 m 차원 데이터의 특징을 추출하여 d 차원의 벡터로 차원을 축소한다.

$$f : (RSSI_i^1, RSSI_i^2, \dots, RSSI_i^m) \mapsto X_i = (r_i^1, r_i^2, \dots, r_i^d), \quad d \ll m \quad (5)$$



[그림 2-3] 오토엔코더 구조

3. 측위 기법

1) k-NN

특징점이 추출된 데이터를 통해 위치를 추정하는 기계학습 기법에는 다양한 방법들이 있다. 그중 k-NN은 분류 또는 회귀에 사용되는 간단한 지도학습 기법 중 하나이다. k-NN은 특징 공간에서 테스트 데이터와 거리가 가장 가까운 데이터 k개를 데이터베이스에서 검색하여 테스트 데이터의 위치를 추정한다.

k-NN는 데이터베이스에 극단치나 이상치가 있는 경우 쉽게 측위 오차가 커지는 경향이 있다. 이러한 측위 성능 문제를 해결하기 위해 weighted

k-nearest neighbor 등 다양한 알고리즘이 연구되고 있다.

2) 딥러닝

다층 퍼셉트론의 은닉층을 늘린 심층 신경망을 학습시키는 알고리즘을 딥러닝이라고 한다. 심층 신경망은 여러 계층을 통해 데이터에서 점점 더 의미있는 표현을 학습한다. 입력 계층에서 입력 정보를 추출한 후 상위 정보를 다음 계층으로 전달한다. 심층 신경망은 입력층, 은닉층, 출력층의 세 가지 유형의 계층으로 구분되며, 출력층의 값과 실제 라벨과의 오차를 역전파를 통해 학습한다. RSSI 지문 데이터로 보행자의 실내 위치를 추정하기 위해 모든 레이어의 노드가 다음 레이어의 모든 노드와 이어지는 fully connected layer로 이루어진 단순한 심층 신경망 모델이 사용될 수 있다.

4. AI-IMU

IMU 센서를 이용한 위치추정은 센서의 편향과 노이즈에 취약하다. 전통적인 적분을 통한 방법은 적분 과정에서 지수적인 오차가 전파되는 단점이 있다. 누적 오차 문제를 해결하기 위해 걸음 기반 방법 pedestrian dead reckoning (PDR)이 제안되었다. 그러나, 걸음 습관이나 스마트폰 소지 방법에 따라 정확성의 편차가 크고 노이즈의 영향이 크다. 또한, 쇼핑 카트나 유모차와 같은 걸음을 검출할 수 없는 환경에서는 동작하지 못한다. 이러한 한계를 극복하기 위해 최근엔 IMU 데이터를 딥러닝 모델을 거쳐 위치를 추정하는 기술로써 IONet¹²⁾, RoNIN¹³⁾과 같은 AI-IMU가 제안되었다.

12) C. Chen, et al, "IONet: Learning to Cure the Curse of Drift in Inertial Odometry," Proceedings of the AAAI Conference on Artificial Intelligence, vol. 32, no. 1, 2018.

13) S. Herath, et al, "RoNIN: Robust Neural Inertial Navigation in the Wild: Benchmark, Evaluations, & New Methods," IEEE International Conference on Robotics and

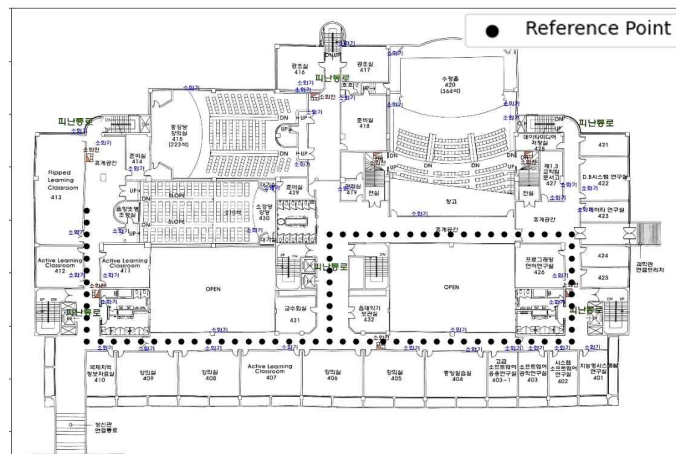
본 논문에서는 RoNIN을 AI-IMU 위치추정 모델로 사용하였다.

AI-IMU 기법을 포함한 IMU 센서를 이용한 위치추정 방법은 초기 위치를 추정할 수 없으며, 절대 방향을 알 수 없다. 본 논문에서는 IMU 궤적의 상대적인 관계를 이용한 목적함수를 정의하여 초기 위치와 절대 방향 정보 없이 딥러닝 학습을 구현한다.

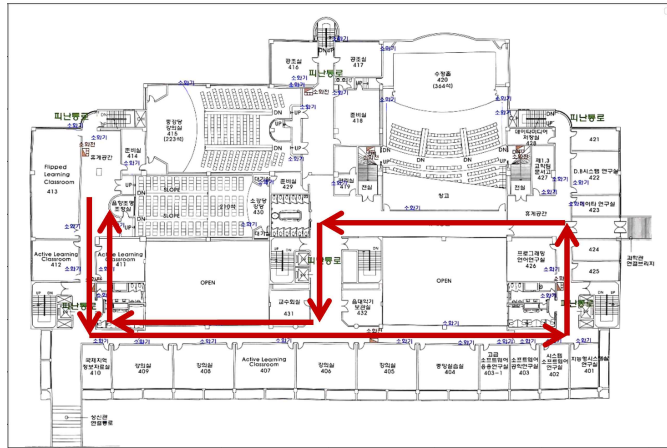
III. 가상의 위치 좌표를 이용한 딥러닝 학습

1. 학습데이터 구성

기존 지문 기반 위치 측위 방법은 데이터베이스를 구축하는데 많은 시간이 필요하다. 또한, RP를 지정하고 정해진 위치에서 데이터를 수집해야 하는 등 일정한 절차에 의해 수집되어야 한다. 이러한 문제를 해결하기 위해 지문 데이터베이스를 구축하는 것이 아닌 보행자의 AI-IMU 궤적을 이용한 기하학 모델링을 정의하여 초기 위치와 절대 방향 정보 없이 딥러닝 학습을 구현한다. [그림 3-1]은 기존 지문 기반 측위 모델의 학습데이터와 제안하는 모델의 학습데이터 구성을 나타낸다.



(a) 지문 기반 측위 모델 학습데이터



(a) 제안하는 모델 학습데이터

[그림 3-1] 제안하는 학습데이터 구성에 대한 컨셉

[그림 3-2]는 스마트폰을 손에 쥔 두명의 보행자가 걸어나니며 IMU와 RSSI를 수집하는 과정과 학습데이터 구성을 나타낸다. 보행자가 하나의 스마트폰을 통해 일정한 시간 동안 보행한 궤적으로부터 시계열 Wifi RSSI 데이터 집합 W 와 AI-IMU 궤적 A 를 수집한다. 일반적으로 Wifi RSSI 센싱 주기는 IMU 센싱 주기보다 느리므로 데이터 집합의 크기가 다르다. Wifi 특징 데이터 집합 과 AI-IMU 궤적을 다음과 같이 정의한다.

$$W = \{(r_i^1, r_i^2, \dots, r_i^d)\}_{i=1}^N \quad (6)$$

$$A = \{(x_j, y_j)\}_{j=1}^M, \quad N \ll M \quad (7)$$

이때, $N \ll M$ 인 이유는 주로 IMU의 센싱 주기는 100Hz인데 반해 Wifi RSSI 센싱 주기는 몇 초에서 수십 초이기 때문이다. 식 (6)의 특징 데이터 $(r_i^1, r_i^2, \dots, r_i^d)$ 는 오토엔코더를 통해 얻어진 특징 데이터이며, 식 (7)의 (x_j, y_j) 는 AI-IMU로부터 추정된 2차원 위치이다.

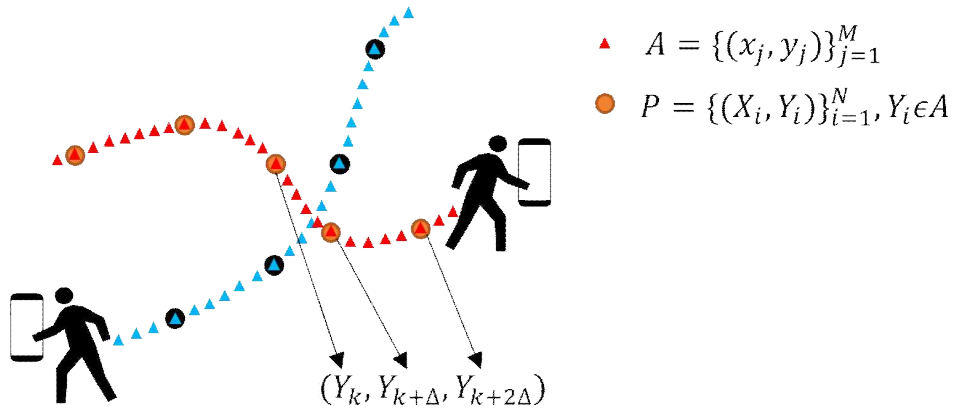
W 는 위치 정보가 없는 unlabeled 데이터이다. 따라서 제안하는 학습 방법은 위치 기반 학습데이터를 생성하기 위해 AI-IMU로부터 추정된 위치를 데이터의 가상 지문으로 정의한다. 먼저, W , A 의 데이터를 수집한 시간을 각각 $T^{WiFi} = \{t_i^{WiFi}\}_{i=1}^N$ 과 $T^{AI-IMU} = \{t_j^{AI-IMU}\}_{j=1}^M$ 로 정의한다. 이때, $N \ll M$ 이므로 T^{WiFi} 와 가장 가까운 시간 T^{AI-IMU} 에서 추정된 위치를 가상 지문의 위치로 사용하였다. 시간 T^{WiFi} 에서 AI-IMU에 의해 추정된 위치의 집합을 $Y \in A$ 라 할 때 Wifi RSSI와 IMU기반 추정 위치로 이루어진 지문 데이터 집합은 식 (8)과 같이 정의할 수 있다.

$$P = \{(X_i, Y_i)\}_{i=1}^N \quad (8)$$

이때, $Y_i = (x_i, y_i) \in R^2$ 는 AI-IMU에 의해 추정된 2차원상의 위치 집합이다.

식 (8)은 한 명의 보행자가 수집한 시계열 데이터이다. 여러 보행자가 독립적으로 n 개의 데이터 집합을 수집한 경우 식 (9)와 같이 하나의 batch 집합으로 정의할 수 있다.

$$D = \{P_1, P_2, \dots, P_n\} \quad (9)$$



[그림 3-2] Wifi 시계열 데이터 집합의 시각화

2. 목적함수

최종적으로 학습하고자 하는 위치추정 모델 $g()$ 은 식 (10)과 같이 식 (5)에 기술된 RSSI 특징 데이터를 입력으로 2차원 위치추정을 목표로 한다.

$$g: X_i \in R^d \mapsto (x_i, y_i) \in R^2 \quad (10)$$

먼저, 목적함수를 정의하기 위해 식 (9)의 데이터 집합 D 에서 시간 순서적으로 3개의 위치 데이터를 선택하여 식 (11)과 같이 표현한다.

$$Q_k = (Y_k, Y_{k+\Delta}, Y_{k+2\Delta}) \quad (11)$$

단, 순서쌍 $(Y_k, Y_{k+\Delta}, Y_{k+2\Delta})$ 는 같은 궤적 P 에서 선택한다. 연속된 세 샘플 사이의 텀은 임의의 시간 이하의 모든 경우를 포함한다. 본 논문에서는 최대

30초의 텀으로 구성하였다. 식 (11)에 대응하는 모델의 추정은 식 (12)와 같다.

$$G_k = (g(X_k), g(X_{k+\Delta}), g(X_{k+2\Delta})) \quad (12)$$

제안하는 목적함수는 식 (11)의 AI-IMU 위치와 식 (12) 사이의 오차를 표현하기 위해 세 샘플의 위치 관계를 이용한다. AI-IMU가 절대방향과 관계없이 상대좌표를 출력하므로, 두 도형의 평균 제곱 오차가 가장 작아지도록 회전시킨 후의 모양을 비교한다. 14)에 따르면 회전변환을 아래와 같은 절차로 구할 수 있다.

첫째, 위치 집합 Q_k 와 G_k 의 중심이 원점이 되도록 각각의 위치에 평균을 뺀 \hat{Q}_k 와 \hat{G}_k 를 구한다.

둘째, 2x2 공분산 행렬 $H_k = \hat{Q}_k^T \hat{G}_k$ 을 구한다.

셋째, H_k 의 SVD를 계산한다. $H_k = V_k S_k W_k^T$.

넷째, $\tilde{S}_k = \text{diag}\{s_1 = 1, s_2\}$. 이때, $\text{def}(V_k W_k^T > 0)$ 이면 $s_2 = 1$, 아니면 $s_2 = -1$.

다섯째, 회전형렬 $R_k = W_k \tilde{S}_k V_k^T$ 를 구한다.

최종 목적함수는 식 (13)과 같다.

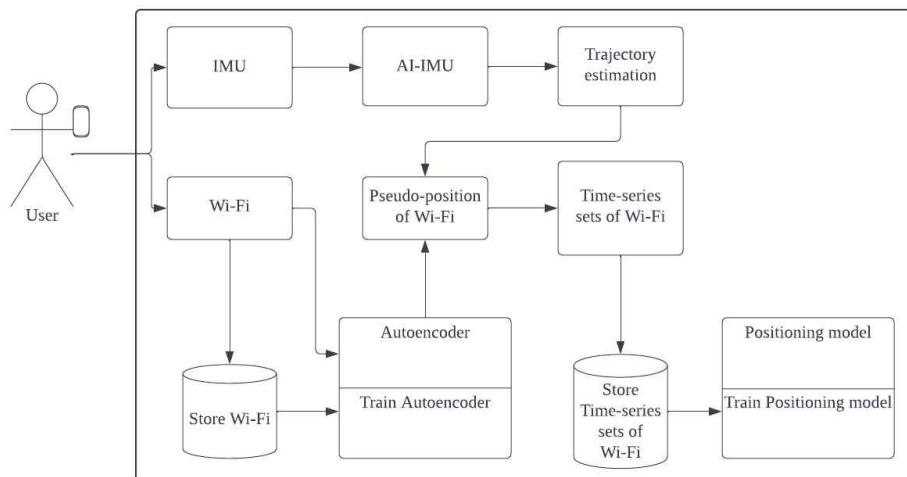
$$L = \sum_{k=1}^K \text{MSE}(Q_k - G_k R_k) \quad (13)$$

14) J. Lawrence, et al, "A purely Algebraic Justification of the Kabsch-Umeyama Algorithm," Journal of Research of the National Institute of Standards and Technology, vol. 124, pp. 1-6, 2019.

[표 3-1]은 3장에서 정의한 목적함수로 위치추정 모델을 학습하는 알고리즘을 정리한 의사코드이다. [그림 3-3]은 데이터 수집부터 위치추정 모델의 학습까지의 과정을 플로우차트로 나타낸 그림이다. 수집된 RSSI는 오토인코더에 의해 전처리되며, AI-IMU에 의해 추정된 위치들의 관계를 이용하여 위치추정 모델을 학습한다.

[표 3-1] 제안한 위치추정 모델 학습 알고리즘

Algorithm 1 Positioning model	
1:	Repeat
	Sample random minibatch of time-series sets of Wifi
2:	$\{(X_k, X_{k+\Delta}, X_{k+2\Delta})\}_{k=1}^K$ from D
	Perform feedforward for each Wifi data
3:	$\{(g(X_k), g(X_{k+\Delta}), g(X_{k+2\Delta}))\}_{k=1}^K$.
4:	Learn with the loss function of Eq. ()
5:	Until end of learning



[그림 3-3] 학습 알고리즘 플로우차트

IV. 파티클 필터

Wifi RSSI와 IMU의 센싱 주기는 각각 다르다. 또한, Wifi RSSI와 AI-IMU는 각각 절대 위치와 상대 위치를 추정한다. 다른 특성을 가진 두 센서를 융합하기 위한 필터링 알고리즘이 사용된다.

베이지스 룰에 의해 posterior probabilistic density function (PDF)는 다음과 같이 주어진다

$$p(Y_k|X_{1:k}) = \frac{p(X_k|Y_k)p(Y_k|X_{k-1})}{p(X_k|X_{k-1})} \quad (14)$$

파티클 필터는 가중치를 가진 파티클들을 통해 PDF를 추정한다. 파티클의 개수를 N_p 로 가정할 때 파티클과 가중치의 집합을 $\{Y_k^i, w_k^i\}_{i=1}^{N_p}$ 로 나타낼 수 있으며, 모든 가중치의 합은 1이 되도록 정규화된다. 각각의 Y_k^i 는 가상의 상태를 나타내며, w_k^i 는 각각의 상태에 해당하는 확률을 나타낸다. 파티클 필터에 따르면 식 (14)의 원본 PDF는 식 (15)와 같이 근사화된다.

$$p(Y_k|X_{1:k}) \approx \sum_{i=1}^{N_p} w_k^i \delta(Y_k - Y_k^i) \quad (15)$$

여기서 $\delta()$ 는 디랙 델타함수이며, 추정하는 상태 \hat{Y}_k 는 다음과 같이 주어진다.

$$\hat{Y}_k = E[Y_k|X_{1:k}] \approx \sum_{i=1}^{N_p} w_k^i Y_k^i \quad (16)$$

가중치 w_k^i 는 식 (17)의 중요도 샘플링을 통해 얻어진다.

$$w_k^i \approx w_{k-1}^i \frac{p(X_k|Y_k^i)p(Y_k^i|Y_{k-1}^i)}{q(Y_k|Y_{1:k-1}, X_{1:k})} \quad (17)$$

여기서 $p(X_k|Y_k^i)$ 는 우도이며 $p(Y_k^i|Y_{k-1}^i)$ 은 사전확률 함수이다.

우도와 사전확률을 모델링 해야 한다. 실내 측위 환경에서 사전확률 함수는 벽에 의해 다음과 같이 모델링할 수 있다.

$$p(x_k|x_{k-1}) = \begin{cases} 0, & \text{파티클이 벽을 통과하는 경우} \\ 1, & \text{파티클이 벽을 통과하지 않는 경우} \end{cases} \quad (18)$$

우도 함수의 경우 측정값이 Wifi RSSI인지 IMU인지에 따라 달라진다.

A. IMU 파티클의 우도

i번째 IMU 파티클의 상태를 $Y_k^{i,IMU} = (x_k^{i,IMU}, y_k^{i,IMU}, \theta_k^{i,IMU})$ 로 정의할 때, i번째 파티클은 다음과 같이 모델링할 수 있다.

$$\begin{aligned} x_k^{i,IMU} &= x_{k-1}^{i,IMU} + \hat{l}_k \times \cos(\theta_{k-1}^{i,IMU} + \hat{\theta}_k) \\ y_k^{i,IMU} &= y_{k-1}^{i,IMU} + \hat{l}_k \times \sin(\theta_{k-1}^{i,IMU} + \hat{\theta}_k) \\ \theta_k^{i,IMU} &= \theta_{k-1}^{i,IMU} + \hat{\theta}_k \end{aligned} \quad (19)$$

여기서 \hat{l} 은 AI-IMU의 의해 추정된 움직인 거리이며, $\hat{\theta}$ 는 헤딩 방향의 변화이다. IMU 파티클의 우도는 파티클의 평균과의 거리 오차로 정의된다.

$$p(X_k | Y_k^{i, IMU}) \sim N(|Y_k^{i, IMU} - \frac{1}{N_p} \sum_i^{N_p} [x_k^{i, IMU}, y_k^{i, IMU}]|, \sigma^2) \quad (20)$$

B. Wifi 파티클의 유도

IMU 센싱 주기가 Wifi RSSI보다 빠르다. n 번의 AI-IMU 업데이트 후의 Wifi 파티클이 전파됨을 가정한다. 이때 i 번째 Wifi 파티클의 상태는 $Y_k^{i, WiFi} = (x_k^{i, WiFi}, y_k^{i, WiFi}, \theta_k^{i, WiFi})$ 로 정의되며, 다음과 같이 모델링된다.

$$\begin{aligned} x_k^{i, WiFi} &= x_{k-n}^{i, WiFi} + \sum_{i=k-n+1}^k \hat{l}_i \times \cos(\theta_{k-1}^{i, WiFi} + \sum_{j=k-n+1}^i \hat{\theta}_j) \\ y_k^{i, WiFi} &= y_{k-n}^{i, WiFi} + \sum_{i=k-n+1}^k \hat{l}_i \times \sin(\theta_{k-1}^{i, WiFi} + \sum_{j=k-n+1}^i \hat{\theta}_j) \\ \theta_k^{i, WiFi} &= \theta_{k-n}^{i, WiFi} + \sum_{i=k-n+1}^k \hat{\theta}_i \end{aligned} \quad (21)$$

Wifi 파티클의 우도는 학습된 모델 $g()$ 와의 거리 오차로 정의된다.

$$p(X_k | Y_k^{i, WiFi}) \sim N(|Y_k^{i, WiFi} - g(X_k)|, \sigma^2) \quad (22)$$

Wifi 파티클의 리샘플링 단계에서 IMU 파티클은 Wifi 파티클과 함께 사용된다. 결과적으로, AI-IMU의 위치추정 오차는 Wifi 파티클 업데이트를 통해 보정된다.

V. 실험 및 평가

1. 위치추정

1) 실험 환경

실험은 성신여자대학교 수정관 4층과 COEX 1층 복도에서 이루어졌다. 성신여자대학교 수정관 4층은 약 80×45m 크기를 가지며, 좁은 통로로 이루어져 있다. 수정관 4층은 기존 지문 기반 실내 측위 방식과 제안한 방식으로 각각의 모델을 학습한 후 지문 데이터를 이용하여 정확도를 비교하였다. COEX 1층은 약 207×366m 크기를 가지며, 넓고 긴 통로로 이루어져 있다. 제안한 학습 방법이 충분히 큰 공간에서도 올바르게 학습이 이루어지는지 확인하기 위해 COEX에서 실험을 진행하였다.

수정관 4층은 지문 기반 측위 방식의 학습을 위해 [그림 3-1] (a)와 같이 2m 간격으로 지정한 83개의 위치에서 4가지 방향에 대하여 2대의 S21 스마트폰을 통해 총 664개의 Wifi 지문 데이터를 수집하였다. 보행 데이터의 Wifi는 5초에 하나씩 수집하였고 2대의 스마트폰을 통해 약 19분간 451개의 Wifi RSSI를 수집하였다. 테스트를 위해 83개의 위치에서 각각 2가지 방향에 대하여 총 166개의 Wifi 지문을 수집하였다. COEX 1층은 S9, S10, S20, S21 총 4대의 스마트폰을 통해 약 120분간 보행하여 5965개의 Wifi RSSI를 수집하였다.

제안한 방식과 지문 기반 측위 방식에 사용된 오토엔코더 및 위치추정 모델은 같은 구조를 가진다. 오토엔코더의 구조는 [표 5-1]과 같다. 입력 차원과 출력 차원은 건물에서 검색된 공유기 수 748과 같고 32차원의 특징

벡터로 변환한다. 은닉층의 활성화 함수로 LeakyReLU를 사용하였다. Wifi RSSI는 0과 1사이의 값으로 정규화되어 있으므로 출력층의 활성화 함수는 ReLU를 사용하였다. 최적화 함수로 adam optimizer를 사용하였고 dropout은 0.5로 학습하였다. 위치추정 모델은 [표 5-2]와 같다. 오토엔코더에 의해 변환된 특징 벡터를 입력으로 2차원 좌표를 출력한다. 은닉층의 활성화 함수로 ReLU를 사용하였다. 최적화 함수로 adam optimizer를 사용하였고 dropout은 0.2로 학습하였다. COEX 1층에 사용한 모델은 오토엔코더의 입력 차원과 출력 차원이 COEX 1층에서 검색된 공유기 수 2851로 변경된 것을 제외하고 수정관 4층에서 사용된 모델과 동일하다.

[표 5-1] 성신여자대학교 수정관 4층에서 사용된 오토엔코더 구조


Input layer	748
1 st hidden layer	256
2 nd hidden layer (Feature data)	32
3 rd hidden layer	256
Output layer	748
Learning rate	0.0001
Optimizer	Adam
Activation function	LeakyReLU, ReLU
Dropout	0.5

[표 5-2] 성신여자대학교 수정관 4층에서 사용된 위치추정 모델 구조

Input layer	32
1 st hidden layer	256
2 nd hidden layer	256
3 rd hidden layer	256
Output layer	2
Learning rate	0.0001
Optimizer	Adam
Activation function	ReLU
Dropout	0.2


2) 제안한 모델 학습

성신여자대학교 수정관 4층에서 제안한 모델을 학습하기 위해 얻은 보행 데이터의 AI-IMU 궤적은 [그림 5-1]과 같다. AI-IMU에 의한 궤적은 보행자의 초기 방향 및 절대 위치를 알 수 없다. 따라서 두 스마트폰으로 수집한 궤적은 방향이 일치하지 않으며, AI-IMU에 의한 오차가 누적됨에 따라 다른 궤적을 나타낸다.




[그림 5-1] 성신여자대학교 수정관 4층 보행 데이터 AI-IMU 궤적


초기 방향 및 절대 위치를 알 수 없는 AI-IMU 궤적의 세 지점이 이루는 상대적인 위치 관계를 이용하여 학습한 모델의 결과는 [그림 5-2]와 같이 임의의 방향으로 회전한 분포를 나타낸다. 실내 건물의 지도와 제안한 모델의 분포를 매핑하기 위해 임의의 두 지점에서 지문 데이터를 구한다. 지문 데이터 RSSI를 통해 얻은 위치를 지도상의 위치와 일치시키는 회전과 scale, bias를 구하여 적용하면 [그림 5-3]과 같이 나타난다.




(a) 1 epoch



(b) 10 epoch

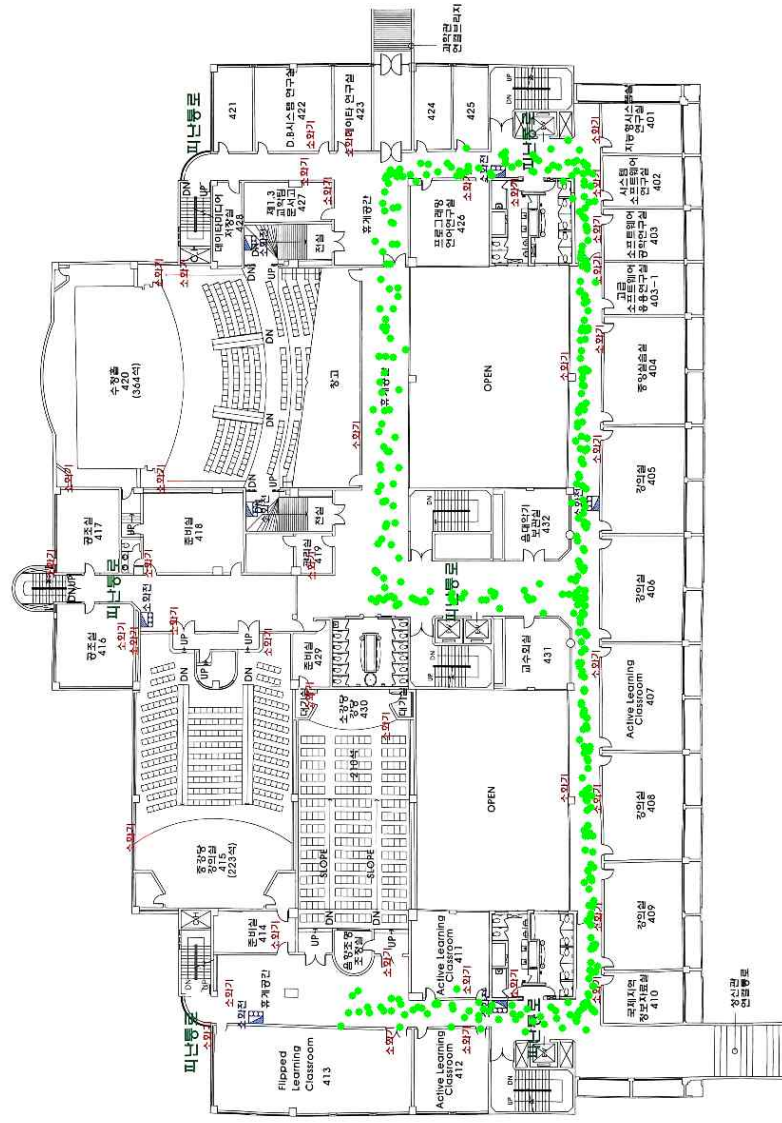


(c) 20 epoch



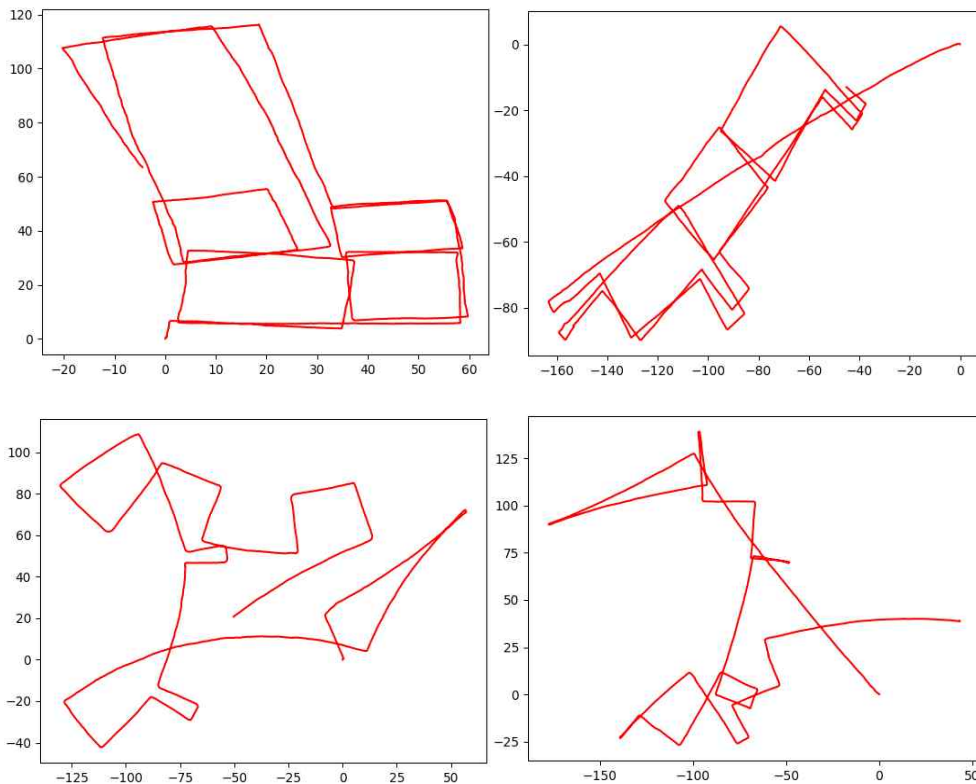
(d) 85 epoch

[그림 5-2] 성신여자대학교 수정관 4층에서 제안한 모델의 학습 경과에 따른 학습 데이터 분포



[그림 5-3] 성신여자대학교 수정관 4층 지도에 매핑한 제안한 모델의 학습데이터 분포

성신여자대학교 수정관 4층은 좁은 복도로 이루어진 작은 공간이다. 보행 데이터를 수집하는 동안 교차로를 지나는 경우가 적으며 지도 전체 면적이 작아 AI-IMU의 오차가 크게 누적되지 않는다. 반면, COEX 1층의 경우 교차로가 매우 많으며 전체 면적이 크기 때문에 보행 데이터를 수집하는 동안 AI-IMU의 오차가 크게 누적된다.




[그림 5-4] COEX 1층 보행 데이터 AI-IMU 궤적


COEX 1층 보행 데이터의 AI-IMU 궤적은 [그림 5-4]와 같다. 일정한 간격의 교차로와 짧은 통로로 이루어진 성신여자대학교 수정관 4층과 달리 짧은 시간에 많은 회전이 이루어지는 경우가 있는 반면 100m 이상 매우 긴 시간 동안 직선으로 보행하는 경우도 있다. 짧은 시간에 많이 회전한

AI-IMU 궤적의 경우 보행자의 헤딩 방향 오차가 빠르게 누적되어 제안한 모델의 학습데이터 분포 [그림 5-5] (d)에서 보이는 것과 같이 하나의 통로가 서로 다른 통로로 잘못 학습되는 문제가 있다. 반면, 100m 이상 매우 긴 시간 동안 직선으로 보행한 궤적의 경우 AI-IMU의 오차가 일정하게 누적되어 직선 통로를 특정 방향으로 휘어진 통로로 잘못 학습하는 문제가 있다.


모델의 학습데이터 분포를 지도에 매핑한 결과는 [그림 5-6]과 같다. 제안한 모델의 학습데이터 분포가 실제 지형과 비교하여 왜곡이 있음을 볼 수 있다.




(a) 1 epoch



(b) 5 epoch




(c) 10 epoch



(d) 85 epoch

[그림 5-5] COEX 1층에서 제안한 모델의 학습 경과에 따른 학습데이터 분포



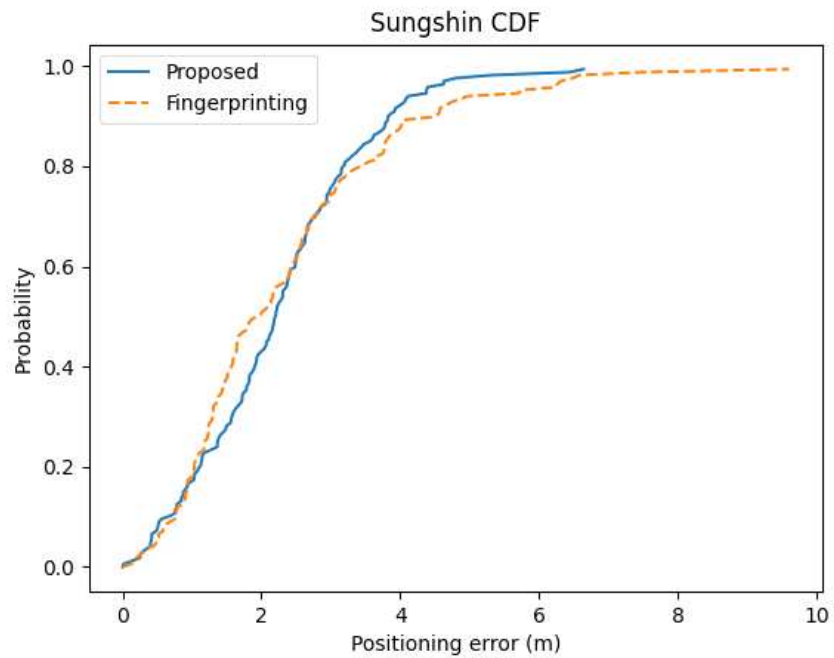
[그림 5-6] COEX 1층 지도에 매핑한 제안한 모델의 학습데이터 분포

3) 실험 결과

성신여자대학교 수정관 4층에서 테스트 지문 데이터에 의한 측위 오차를 [표 5-2]에 정리하였다. 지문 기반 측위 모델의 평균 오차가 2.312m, 중앙값은 1.939m, 최대오차는 9.608m이며 3.371m 오차가 80% 정확도로 산출되었다. 제안한 모델의 평균 오차가 2.247m, 중앙값은 2.201m, 최대오차는 6.646m이며 3.158m 오차가 80% 정확도로 산출되었다. 각 모델의 cumulative distribution function CDF는 [그림 5-7]과 같다. 지문 데이터를 이용한 평균 측위 오차는 지문 기반 위치 측위 모델이 제안한 목적함수로 학습한 모델에 비해 약 0.065m 적은 오차를 보였다.

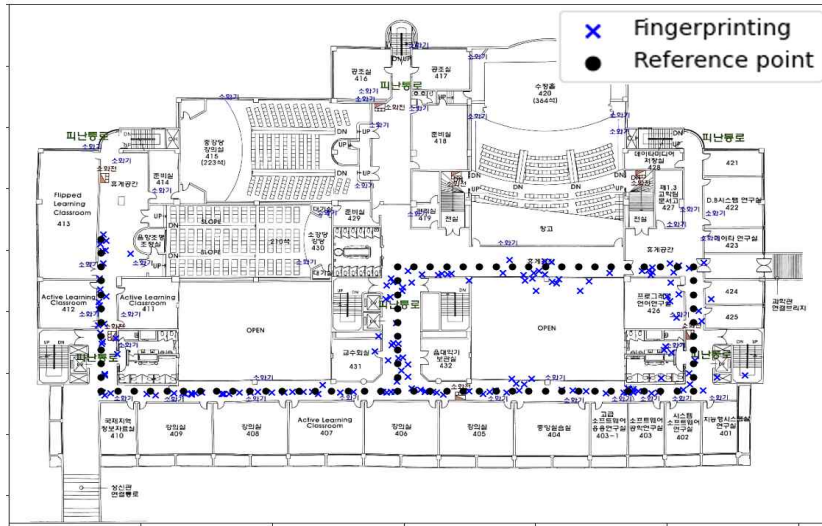
[표 5-3] 성신여자대학교 수정관 4층 테스트 지문 데이터 측위 오차

	Mean (m)	Median (m)	Max (m)	CDF 80% (m)
Fingerprinting	2.312	1.939	9.608	3.371
Proposed	2.247	2.201	6.646	3.158

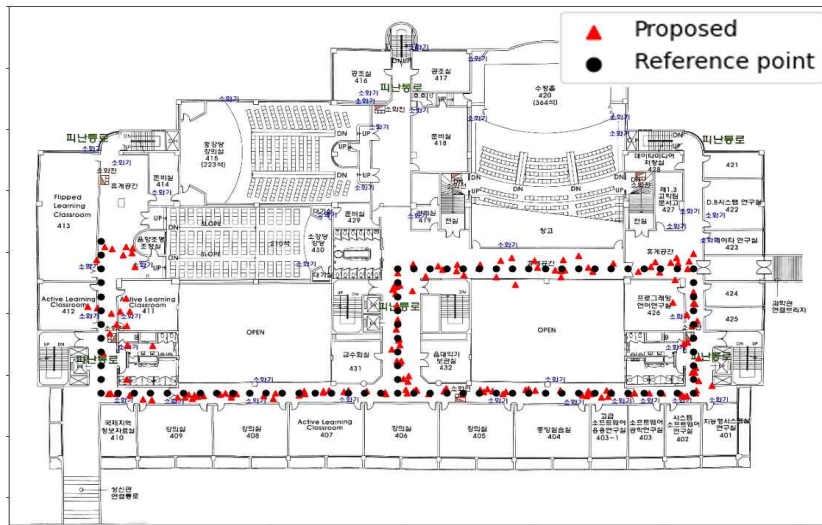


[그림 5-7] 성신여자대학교 수정관 4층 테스트 지문 데이터의 CDF

성신여자대학교 수정관 4층 테스트 지문 데이터의 분포는 [그림 5-8]과 같다. RP는 검정색, 지문 기반 측위 결과는 파란색, 제안한 모델의 결과는 빨간색 원으로 표시하였다.



(a) 지문 기반 측위



(b) 제안한 모델

[그림 5-8] 성신여자대학교 수정관 4층 테스트 지문 데이터의 분포. RP는 검정색 원, 지문 기반 측위 결과는 파란색 엑스, 제안한 모델의 결과는 빨간색 세모로 표시

2. 파티클 필터

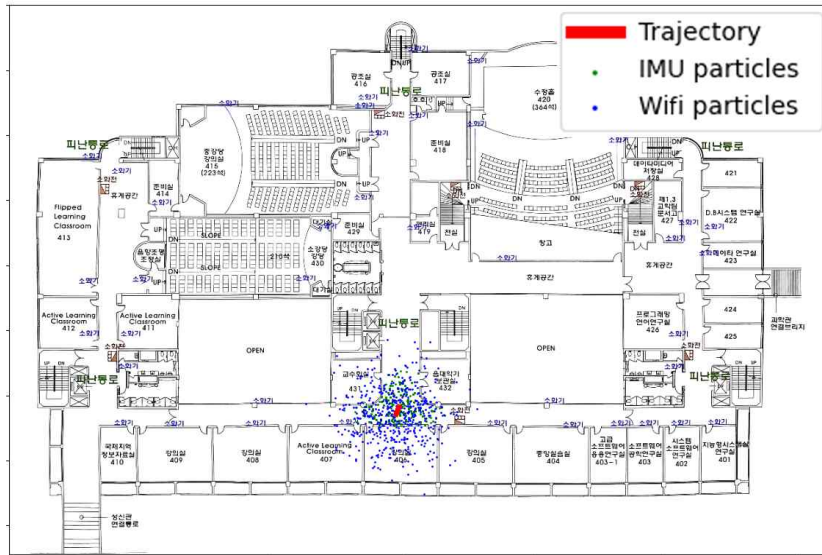
1) 실험 환경

성신여자대학교 수정관 4층에서 파티클 필터의 측위 정확도를 측정하였다. 위치추정 모델은 제안한 방법으로 학습한 모델을 사용하였다. 테스트 데이터는 보행 데이터를 수집하는 방법과 동일하게 수집하였다. 측위 오차를 계산하기 위해 교차로를 통과한 시간을 기록하였다. 실제 위치는 두 교차로 위치, 통과한 시간과 측위 시점의 시간을 이용하여 선형보간법으로 구하였다.

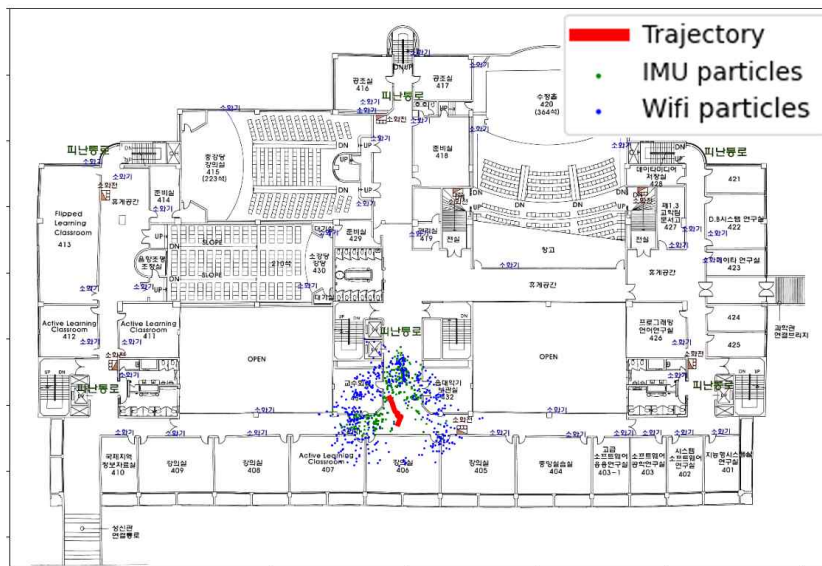
2) 실험 결과

측위 결과에 의해 파티클 필터의 보정이 이루어지는 과정은 [그림 5-9]와 같다. 우선 첫 번째 측위 결과를 기준으로 IMU 파티클과 Wifi 파티클이 생성된다. 초기화된 파티클들은 모두 랜덤한 방향을 향하므로 초기 파티클들이 AI-IMU에 의해 모든 방향으로 움직이는 것은 [그림 5-9] (b)를 통해 볼 수 있다. 이후 5초마다 위치추정 모델에 의한 측위 결과에 의해 IMU 파티클과 Wifi 파티클이 보정되며 보행자의 위치를 추정한다.

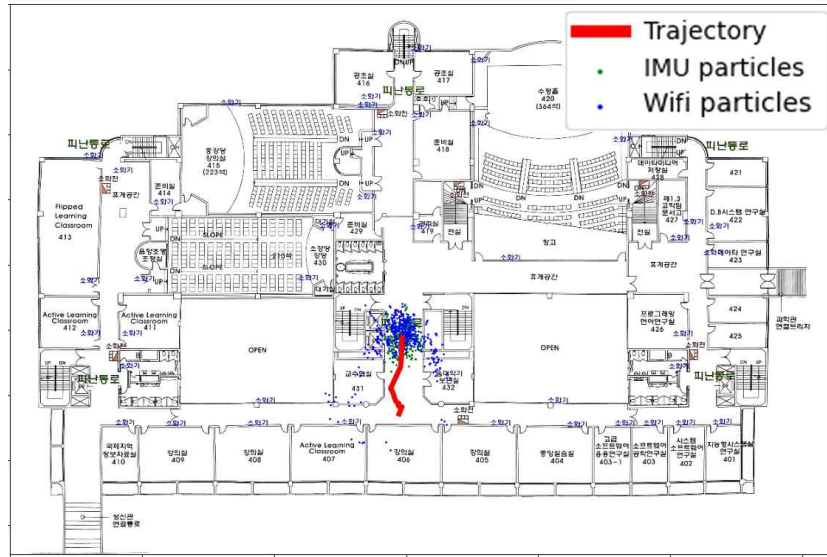
파티클 필터에 의해 추정된 궤적과 실제 궤적의 차이를 [표 5-4]에 정리하였다. 평균 오차가 1.231m, 중앙값 1.11m, 최대오차는 3.225m이며 1.903m 오차가 80% 정확도로 산출되었다. 테스트 데이터 중 두 보행 데이터의 실제 궤적과 파티클 필터의 궤적을 [그림 5-10]에 나타내었다.



(a) 첫 번째 측위 결과에 의한 파티클 초기화



(b) 두 번째 측위 결과에 의한 보정

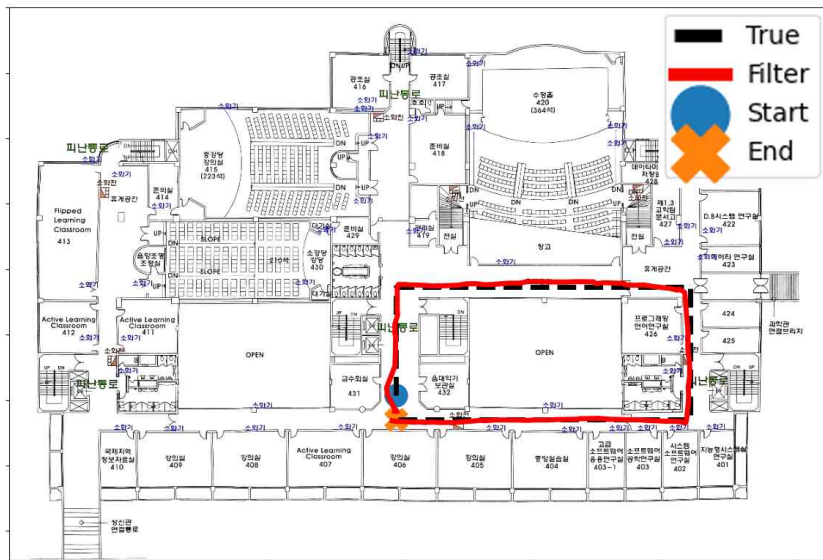
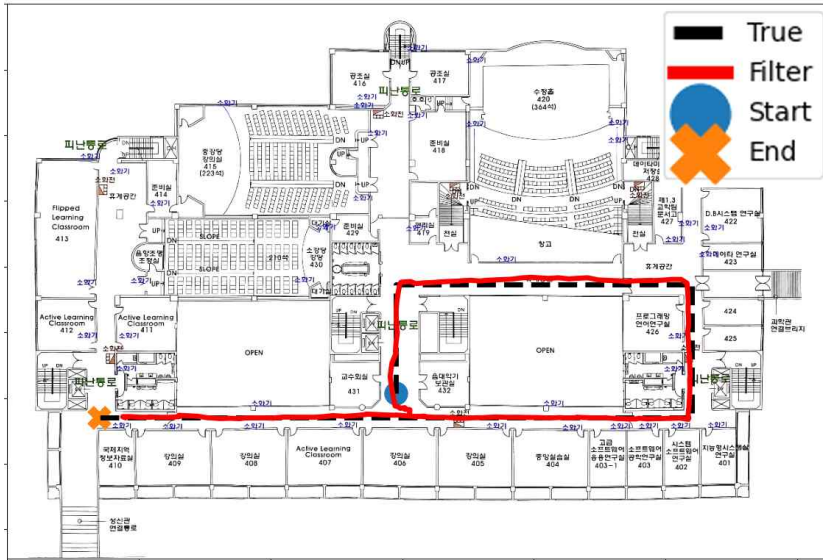


(c) 세 번째 측위 결과에 의한 보정

[그림 5-9] 성신여자대학교 수정관 4층 파티클 필터에 의한 궤적. 보행자의 궤적은 빨간색 선, IMU 파티클은 파란색, Wifi 파티클은 초록색 원으로 표시

[표 5-4] 성신여자대학교 수정관 4층 파티클 필터 측위 오차

Localization error (m)			
Mean	Median	Max	CDF 80%
1.231	1.11	3.225	1.903

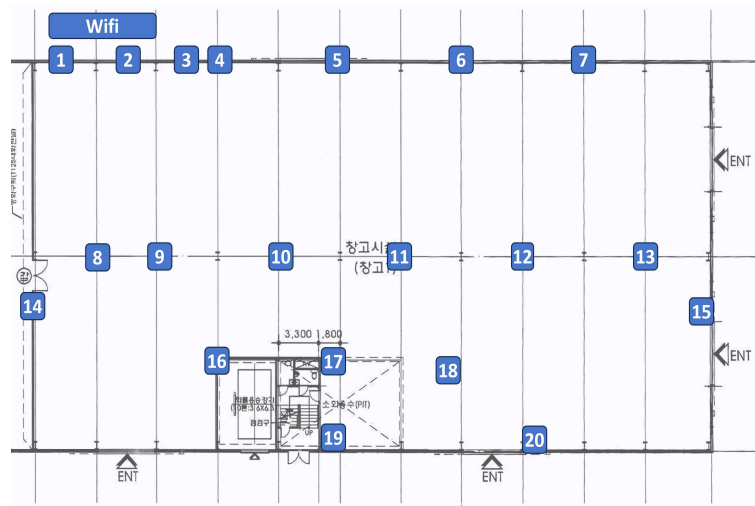


[그림 5-10] 파티클 필터 궤적. 실제 궤적은 검정색 점선, 파티클 필터 궤적은 빨간색 실선, 시작 위치는 원, 도착 위치는 X로 표시


3. Wifi BLE 통합

1) 실험 환경

Wifi와 BLE RSSI의 통합 실험은 56×30m 크기의 한 물류창고에서 이루어졌다. [그림 5-11]과 같이 20개의 Wifi AP와 27개의 비콘을 설치하였다. 위치추정 정확도를 측정하기 위해 10개의 포인트에서 각각 약 2분간 신호를 수집하였다. 모든 무선신호를 사용하여 학습한 모델과 Wifi 신호만을 사용하여 학습한 모델, BLE 신호만을 사용하여 학습한 모델 모두 5초 간격으로 위치추정을 진행하고 추정된 위치값들에 window size가 12인 이동평균 필터를 적용하였다. 그 후, 각각의 포인트별로 필터링이 적용된 위치값들의 마지막 12개의 위치값과 실제 위치와의 측위 오차를 계산하였다. 학습에 사용한 모델은 오토엔코더의 입력 차원이 사용한 AP 및 비콘 개수의 합과 같게 변경된 것을 제외하고 [표 5-1], [표 5-2]의 모델과 동일하다.



(a) Wifi 설치 위치



(b) 비콘 설치 위치

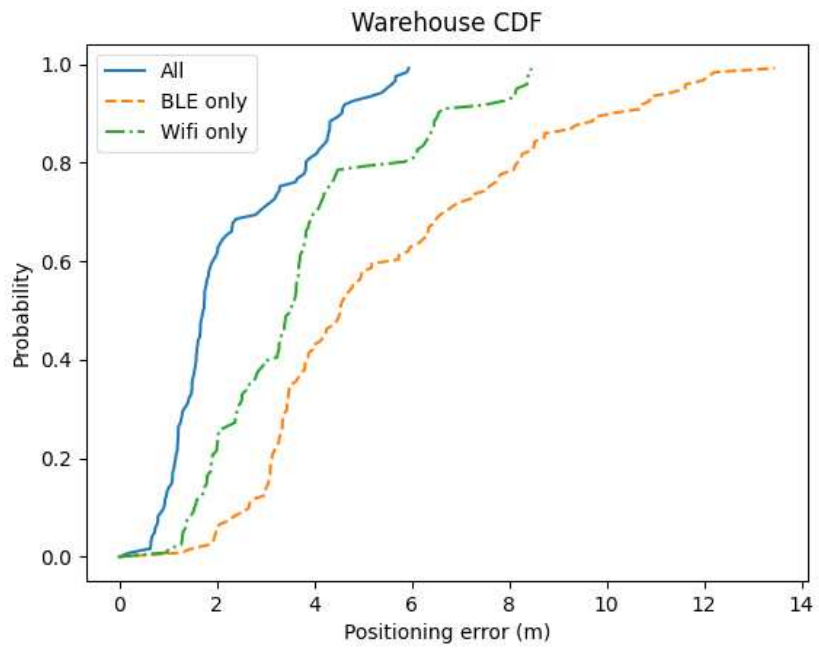
[그림 5-11] 물류창고의 Wifi AP 및 비콘 설치 위치

2) 실험 결과

물류창고의 10개 포인트에서 측정한 3가지 모델들의 측위 오차를 [표 5-5]에 정리하였다. Wifi와 BLE 통합 모델은 평균 오차가 2.3m, 중앙값은 2.261m, 최대오차는 5.941m이며 4.203m 오차가 80% 정확도로 산출되었다. 반면, BLE 신호만을 사용하여 학습한 모델은 평균 오차가 5.491m, 중앙값은 5.571m, 최대오차가 13.456m이며 10.179m 오차가 80% 정확도로 산출되었고 Wifi 신호만을 사용하여 학습한 모델은 평균 오차가 3.727m, 중앙값은 3.727m, 최대오차가 8.452m이며 6.864m 오차가 80% 정확도로 산출되었다. 각 모델의 CDF는 [그림 5-12]와 같다.

[표 5-5] 물류창고 테스트 데이터 측위 오차

	Mean (m)	Median (m)	Max (m)	CDF 80% (m)
All	2.3	2.261	5.941	4.203
BLE only	5.491	5.571	13.456	10.179
Wifi only	3.727	3.727	8.452	6.864



[그림 5-12] Wifi BLE 통합 모델 CDF

VI. 결론

기존의 지문 기반 위치 측위는 데이터베이스를 구축하기 위해 많은 시간과 비용이 든다. 본 논문은 실제 위치 정보를 수집하는 대신 AI-IMU를 통해 얻은 가상의 위치 좌표를 이용한 비지도식 학습기법을 제안했다. 실험을 통해 제안한 알고리즘의 비지도식 Wifi RSSI 위치 추정 모델의 분포가 실제 지도에 매핑될 수 있음을 보였다. 또한, 파티클 필터를 통해 AI-IMU 위치추정과 Wifi RSSI 위치추정을 융합하여 얻은 궤적이 실제 이동 궤적과 흡사함을 보였다. 더 나아가, Wifi와 BLE RSSI를 통합함으로써 측위의 음영 구역을 최소화하고 성능 개선을 이루어낼 수 있음을 보였다.

그러나 제안한 학습 기법은 모델의 학습이 AI-IMU가 추정한 궤적에 의존하기 때문에 회전이 많이 이루어지거나 매우 긴 복도를 학습하는 경우 왜곡이 발생함을 보였다. AI-IMU의 궤적의 신뢰도를 추정하고 이를 토대로 학습데이터를 선별한다면 더욱 안정적인 학습을 가능하게 할 것으로 보인다. 또한, 위치추정 모델을 CNN 또는 RNN과 같은 보다 고도화된 딥러닝 모델을 적용하여 성능을 개선할 수 있을 것이다.

참고문헌

- 1) T. Feigl, et al., "Robust ToA-estimation using convolutional neural networks on randomized channel models," International Conference on Indoor Positioning and Indoor Navigation, 2021.
- 2) W. Xiong, et al., "Two efficient and easy-to-use NLOS mitigation solutions to indoor 3-D AOA-based localization," International Conference on Indoor Positioning and Indoor Navigation, 2021.
- 3) J.Yoo and K. H. Johansson "Semi-supervised learning for mobile robot localization using wireless signal strengths," International Conference on Indoor Positioning and Indoor Navigation, 2017.
- 4) M. Lee and D. Han, "Voronoi tessellation based interpolation method for Wi-Fi radio map construction," IEEE Communications Letters, vol. 16, no. 3, pp. 404-407, 2012.
- 5) P. Brida, et al, "Algorithm for dynamic fingerprinting radio map creation using IMU measurements," Sensors, vol. 21, no. 7, 2021.
- 6) B. Huang, et al, "An online radio map update scheme for WiFi fingerprint-based localization," IEEE Internet of Things Journal, vol. 6, no. 4, pp. 6909-6918, 2019.
- 7) X. Du, et al, "CRCLoc: A crowdsourcing-based radio map construction method for WiFi fingerprinting localization," IEEE Internet of Things Journal, vol. 9, no. 14, pp. 12364-12377, 2021.
- 8) J. Seong and D. Seo, "Selective unsupervised learning-based Wi-Fi fingerprint system using autoencoder and GAN," IEEE Internet of Things Journal, vol. 7, no. 3, pp. 1898-1909, 2019.

- 9) H. Zou, et al, "Adversarial learning-enabled automatic WiFi indoor radio map construction and adaptation with mobile robot," *IEEE Internet of Things Journal*, vol. 7, no. 8, pp. 6946-6954, 2020.
- 10) N. Singh, et al, "Machine Learning Based Indoor Localization Using Wi-Fi RSSI Fingerprints: An Overview," *IEEE Access*, vol. 9, pp. 127150-127174, 2021.
- 11) F.J. Aranda, et al, "Performance analysis of fingerprinting indoor positioning method with BLE," *Expert Systems with Applications*, vol. 202, 2022.
- 12) C. Chen, et al, "IONet: Learning to Cure the Curse of Drift in Inertial Odometry," *Proceedings of the AAAI Conference on Artificial Intelligence*, vol. 32, no. 1, 2018.
- 13) S. Herath, et al, "RoNIN: Robust Neural Inertial Navigation in the Wild: Benchmark, Evaluations, & New Methods," *IEEE International Conference on Robotics and Automation*, pp. 3146-3152, 2020.
- 14) J. Lawrence, et al, "A purely Algebraic Justification of the Kabsch-Umeyama Algorithm," *Journal of Research of the National Institute of Standards and Technology*, vol. 124, pp. 1-6, 2019.

ABSTRACT

Machine learning based indoor Localization using Wifi and Inertial Sensors

Chanyeong Ju

Department of Future Convergence

Technology Engineering

Graduate School of

Sungshin University

With the advancement of smartphones and the increasing prevalence of location-based services (LBS), the demand for positioning technologies in indoor environments, where traditional Global Navigation Satellite System (GNSS) signals may not reach, has risen significantly. Various wireless technologies such as bluetooth low energy (BLE), ultra-wideband (UWB), and Wifi have been explored for indoor positioning. Due to the widespread installation of Wifi access point (AP) in the majority of indoor buildings, Wifi received signal strength indicator (RSSI) fingerprint data is considered an important sensor data type. However, the process of labeling fingerprint data, consisting of Wifi RSSI measurements and their corresponding locations, involves significant effort and time due to the need for manual

annotation of reference points.

In this paper proposes a learning technique for Wifi RSSI-based positioning model without actual location data to overcome the limitations of constructing static fingerprint databases. Pseudo positions are computed using inertial measurements unit (IMU) data instead of real location data. The geometric relationships between these pseudo positions are modeled as the objective function for deep learning training, enabling the implementation of learning without initial position and absolute orientation information. Enabling a simple way to collect data while walking with a smartphone significantly improves data collection efficiency.

In many modern buildings such as schools, subways, and department stores, Wifi AP are commonly installed. However, spaces lacking infrastructure, such as construction sites and logistics warehouses, may not have a sufficient number of Wifi AP for positioning. In this paper, we propose the installation of BLE beacons in WiFi signal shadow areas. By integrating BLE RSSI with Wifi RSSI, we aim to minimize positioning shadow areas and enhance performance.

The proposed learning technique is tested in the 4th floor of Sungshin Women's University's Sujeong Hall and the 1st floor of COEX. The paper demonstrates that the output distribution of the model trained with the proposed method can be mapped onto the actual map. The accuracy of the positioning model trained with the proposed method is compared with fingerprint-based positioning. Additionally, the fusion of AI-IMU estimation and Wifi RSSI estimation through particle filtering exhibits trajectory similarity with actual movement trajectories. Furthermore, we validated the

integrated Wifi and BLE RSSI model in a warehouse and confirmed performance improvement through the integration of each wireless signal.