



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

기계학습 기반의 IMU 보행 데이터와
Wi-Fi Fingerprinting을 이용한
실내 위치 추정

2023

성신여자대학교 대학원
미래융합기술공학과
이 동 규

기계학습 기반의 IMU 보행 데이터와
Wi-Fi Fingerprinting을 이용한
실내 위치 추정

유 재 현 교수 지도

이 논문을 석사 학위 논문으로 제출함

2023년 06월

성신여자대학교 대학원

미래융합기술공학과

이 동 규

인 준 서

이 동 규의 석사학위 논문으로 인준함

2023년 06월

심사위원장 변 해 원 (서명 또는 인)

심 사 위 원 오 장 민 (서명 또는 인)

심 사 위 원 유 재 현 (서명 또는 인)

성신여자대학교 대학원

논문 개요

정보통신 기술의 발전과 실내 위치 정보 시장의 밝은 전망으로, 위치 기반 서비스에 대한 수요와 관심이 높아지고 있다. 위치추정에 일반적으로 사용하는 GPS는 실내에서의 수신 강도 및 수신 대역 문제로 실내에서 사용하기 적합하지 않다. 이에, 실내 위치추정을 위해 다양한 기술이 연구되고 있고, 대표적으로 저전력 블루투스 비콘, 초광대역, 관성 측정 장치, Wi-Fi 등이 있다. 특히, IMU 센서를 이용한 측위 방법은 전자기기 대부분에 센서가 내장되어 있고, 주기적인 변화를 인식하여 연속적인 보행자의 위치를 추정할 수 있다. 그러나, 센서의 누적 오차와 낮은 정확도로, 다른 측위 기술과의 결합이 필수적이다. Wi-Fi를 이용한 측위 방법 중 Fingerprinting을 이용한 측위 방법은 Wi-Fi AP의 위치를 알 필요가 없고 건물 대부분에 Wi-Fi AP가 설치되어 있어, 추가적인 인프라 구성 비용이 들지 않는다. 그러나 데이터 사전 수집 비용이 비교적 크고 주기적인 데이터 갱신이 필요하다.

본 논문은 기계학습 기반의 IMU 센서 데이터 위치추정 모델을 구성하여 보행자의 위치를 실시간으로 추정하다가, 기존 Wi-Fi를 이용한 추정 방법보다 더욱 효율적으로 구성된 모델이 실내에 임의로 정한 랜드마크를 식별할 때마다 파티클 필터를 이용하여 위치를 보정 한다. 이처럼, Wi-Fi 추정 모델을 기존 방법이 아닌, 효율적인 방법으로도 융합 알고리즘을 통해 높은 정확도의 위치추정 결과를 얻을 수 있는 방법에 대해 제안하였고, 실제 실내에서 보행한 데이터로 결과를 분석하였다.

목 차

논문개요

I. 서론	1
1. 연구 배경 및 필요성	1
2. 논문의 구성	4
II. 실내 측위 기술에 대한 분석	5
1. 실내 측위 기술	5
2. 관련 연구	6
1) Wi-Fi 기반 측위 기술	6
2) IMU 기반 측위 기술	8
3) 융합 측위 기술	9
III. 제안 알고리즘	11
1. 알고리즘 아키텍처	11
2. Wi-Fi 추정 모델	12
1) 경로 추정을 위한 기존 방법	12
2) 경로 추정을 위해 제안하는 방법	15
2-1) Wi-Fi 데이터 수집	16
2-2) Wi-Fi 데이터 전처리	17
2-3) Wi-Fi 데이터 경로 추정	24
3. IMU 추정 모델	26

1) IMU 데이터 수집	26
2) IMU 데이터 전처리 및 학습	27
4. 파티클 필터	30
IV. 실험 결과	32
1. Wi-Fi 추정 기존 방법과 제안하는 방법 비교	32
1) 실험환경	32
2) 실험 결과	33
2. IMU 모델 추정 결과	39
3. Wi-Fi, IMU 융합 모델 추정 결과	40
V. 결론	42
1. 요약	42
2. 연구 한계 및 추후 연구 방안	42

참고문헌

ABSTRACT

부록

그림 목 차

【그림 3-1】	시스템 아키텍처	11
【그림 3-2】	성신여자대학교 수정관 4층	14
【그림 3-3】	코엑스 몰 B1층	15
【그림 3-4】	특징 공간 내 \hat{d}_1 과 \hat{d}_2 클래스 간 유클리드 거리	23
【그림 3-5】	특징 공간 내 \hat{d}_1 과 \hat{d}_3 클래스 간 유클리드 거리	24
【그림 3-6】	학습 데이터 일부	27
【그림 3-7】	IMU 데이터 구성	28
【그림 4-1】	성신여자대학교 실험 결과	35
【그림 4-2】	코엑스 몰 실험 결과	36
【그림 4-3】	IMU 모델 추정 보행 궤적	39
【그림 4-4】	최종 결과	40

표 목 차

【표 2-1】 실내 측위 기술 장단점	5
【표 3-1】 파티클 필터 알고리즘	31
【표 4-1】 Wi-Fi 추정 모델 평가 기준	33
【표 4-2】 Wi-Fi 추정 기존 방법과 제안하는 방법의 실험 환경과 결과	37

I. 서 론

1. 연구 배경 및 필요성

실내에서 무선인터넷 사용자에게 위치에 따른 특정 정보를 제공하는 무선 콘텐츠 서비스를 가리키는, 위치 기반 서비스(LBS: Location Based Service)는 정보통신 기술과 다양한 네트워크 인프라의 급속한 발전으로 관심과 수요가 높아지고 있다.

미국 연방 통신 위원회 (FCCL: Federal Communication Commission)에 따르면, 실외뿐만 아니라 실내에서도 미국 내 모든 곳에서 이동전화로 긴급구조 요청 시 통화자의 위치를 제공하도록 권고하고 있다¹⁾. 실내에서 발생하는 화재나 긴급 상황 발생 시, 인명 파악과 구조자의 안전을 보장하기 위해 실내 위치 기술의 발전을 도모하기 위한 것으로 볼 수 있다.

또한, 연구개발 특구진흥재단(INNOPOLIS)에서 제공한 실내 위치 정보 시장 보고서에 따르면, 전 세계 실내 위치 정보 시장은 2020년 61억 4,800만 달러에서 연평균 성장률 22.5%로 증가하여, 2025년에는 1,669억 7,900만 달러에 이를 것으로, 전망하였다²⁾. 이는 현재 위치 기반 서비스에 대한 관심과 수요가 증가하고 있음을 보여주고 있으며, 다양한 분야의 산업과 서비스에서 점차 많은 영향을 미칠 것으로 전망할 수 있다.

위치 기반 서비스 중 측위 기술(LDT: Location Determination Technology)에서 일반적으로 범지구위치결정시스템(GPS: Global Positioning System)를 사용자의 위치를 추정하는 기술로 가장 많이 사용한다. 하지만, GPS는 수신

1) Proposes new indoor requirements and revisions to existing E911 rules
2) 연구개발특구진흥재단(2021). 글로벌 시장 동향 보고서, 실내 위치 정보

전파 강도와 수신 대역 문제로 실내에서의 위치 정확도가 현저히 떨어짐에 따라, 실내보다 실외에서 사용하기에 더 적합하다.

이러한 실내 환경에서 위치를 추정하기 위해 다양한 방법이 연구되고 있으며, 무선 주파수 인식 기술 (RFID: Radio Frequency Identification)³⁾을 이용한 추정 방법, 저전력 블루투스 비컨 (BLE: Bluetooth Low Energy) Beacon⁴⁾, 초광대역 (UWB: Ultra-Wide Band)⁵⁾, 관성 측정 장치 (IMU: Inertial Measurement Unit)⁶⁾, Wi-Fi (Wireless-Fidelity)⁷⁾⁸⁾⁹⁾¹⁰⁾를 이용한 방법 등

-
- 3) Lu, C., Uchiyama, H., Thomas, D., Shimada, A., & Taniguchi, R. 2019, Indoor Positioning System Based on Chest-Mounted IMU, Sensors, 19, 420.
 - 4) Jin, G. Y., Lu, X. Y., & Park, M. S. 2006, An indoor localization mechanism using active RFID tag. International Conference on Sensor Networks, Ubiquitous, and Trustworthy Computing (SUTC'06), IEEE, 05-07 June 2006, Taichung, Taiwan. <https://doi.org/10.1109/SUTC.2006.1636157>
 - 5) Dabove, P., Di Pietra, V., Piras, M., Jabbar A. A., & Kazim, S. A. 2018, Indoor positioning using Ultra-wide band (UWB) technologies: Positioning accuracies and sensors' performances, IEEE/ION Position, Location and Navigation Symposium (PLANS), 23-26 April 2018, Monterey, CA, USA, pp.175-184. <https://doi.org/10.1109/PLANS.2018.8373379>
 - 6) Zhuang, Y., Yang, J., Li, Y., Qi, L., & El-Sheimy, N. 2016, Smartphone-based indoor localization with bluetooth low energy beacons, Sensors, 16, 596. <https://doi.org/10.3390/s16050596>
 - 7) Hansen, R., Wind, R., Jensen, C. S., & Thomsen, B. 2010, Algorithmic strategies for adapting to environmental changes in 802.11 location fingerprinting, in Proc. IEEE Indoor Positioning and Indoor Navigation (IPIN), 15-17 September 2010, Zurich, Switzerland, pp.1-10. <https://doi.org/10.1109/IPIN.2010.5648270>
 - 8) Leu, J.-S. & Tzeng, H.-J. 2012, Received signal strength fingerprint and footprint assisted indoor positioning based on ambient Wi-Fi signals, in Proc. IEEE Veh. Technol. Conf. (VTC Spring), 06-09 May 2012, Yokohama, Japan, pp.1-5. <https://doi.org/10.1109/VETECS.2012.6239883>
 - 9) So, J., Lee, J. Y., Yoon, C. H., & Park, H. 2013, An improved location estimation method for wifi fingerprint-based indoor localization,

이 연구되고 있다.

특히, Wi-Fi를 이용한 추정 방법은 건물 대부분과 공공시설에 무선 AP(Access Point)가 이미 구축되어 있어, 추가적인 인프라 구축 비용이 필요하지 않고, 사람들 대부분이 보유하고 있는 스마트폰으로 구현이 가능하다.

IMU를 이용한 추정 방법 또한, 스마트폰에 IMU 센서가 내장되어, 추정 기술을 사용하기에 추가적인 비용이 필요하지 않다.

이에 본 논문에서는 실내 측위 방법 중 인공 신경망을 이용하여 지상 실측 레이블과 IMU 보행 데이터로 구성된 학습 데이터를 학습하여 위치추정 모델을 구축하고 동시에, 기존 Fingerprinting 기반 Wi-Fi 추정 기술보다 효율적인 동적 수집 기술과 자동 라벨링 알고리즘을 이용하여 위치추정 모델을 각각 구축한다¹¹⁾¹²⁾. 실내 보행자의 스마트폰을 통해 보행자의 현재 위치에서의 Wi-Fi Fingerprinting과 보행 IMU 센서값을 통해 각각의 모델에서 추정된 값을 파티클 필터를 이용하여 보정한 후 실내에서 보행자의 위치를 추정하는 알고리즘을 제안한다.

International Journal of Software Engineering, and Its Applications, 7, 77-86. <https://www.earticle.net/Article/A208533>

10) Mendoza-Silva, G. M., Costa, A. C., Torres-Sospedra, J., Painho, M., & Huerta, J. 2022, Environment-aware regression for indoor localization based on WiFi fingerprinting, *IEEE Sensors Journal*, 22, 4978-4988. <https://doi.org/10.1109/JSEN.2021.3073878>

11) Kaemarungsi, K. 2005, Efficient design of indoor positioning systems based on location fingerprinting, *IEEE*, In 2005 International Conference on Wireless Networks, Communications and Mobile Computing, 13-16 June 2005, Maui, HI, USA, pp.181-186. <https://doi.org/10.1109/WIRLES.2005.1549406>

12) Mainetti, L., Patrono, L., & Sergi, I. 2014, A survey on indoor positioning systems, *IEEE*, 22nd international conference on software, telecommunications and computer networks (SoftCOM), 17-19 September 2014, Split, Croatia, pp.111-120. <https://doi.org/10.1109/SOFTCOM.2014.7039067>

2. 논문의 구성

본 논문의 구성은 다음과 같다. 2장에서는 실내 측위 기술들에 대해 살펴보고, 3장에서는 본 논문에서 제안하는 알고리즘을 서술하고, 4장에서는 제안하는 알고리즘의 실험 결과, 5장에서는 본 논문에 대한 결론과 향후 연구 방향을 서술한다.

Ⅱ. 실내 측위 기술에 대한 분석

1. 실내 측위 기술

다양하게 활용되고 있는 측위 기술 중 대표적인 GPS는 실내에서의 사용이 제한되어, 실내 환경에 맞는 위치 기술이 필요하다. 대표적으로 무선 주파수 인식 기술을 이용한 추정 방법, 저전력 블루투스 비컨, 초광대역, 관성 측정 장치, Wi-Fi를 이용한 방법 등이 있다. 【표 2-1】은 실내 측위 기술들의 장단점에 대해 나타내었다¹³⁾.

【표 2-1】 실내 측위 기술 장단점

기반 기술	장점	단점
블루투스 비컨	<ul style="list-style-type: none"> - 설치 비용이 저렴함 - 센서 배치 수를 추가함에 따라 정확도가 향상됨 - 낮은 소비 전력 - 대부분의 전자기기에 내장됨 	<ul style="list-style-type: none"> - 동적 환경에서 낮은 정확도 - 적용 범위가 제한적임
초광대역 기반	<ul style="list-style-type: none"> - 레이더 신호와 유사한 특징으로 거리 측정에 활용 - 낮은 소비 전력 - 15cm 이내의 매우 높은 위치 정확도 	<ul style="list-style-type: none"> - 높은 기기 비용 - 간섭 문제 발생으로 인한 추정 불가

13) 실내 위치 기반 서비스 기술개발 및 표준화 동향(2014), 유재준, 조영수, 전자통신동향분석, pp.51 - 61

무선 주파수 기반	<ul style="list-style-type: none"> - 오차 범위가 작음 - 신호 거리를 늘릴 수 있음 	<ul style="list-style-type: none"> - 신호 도달 거리가 짧음 - 추가적인 설치 비용 필요
초음파 기반	<ul style="list-style-type: none"> - 높은 추정 정확도 - 3차원 측위 가능 	<ul style="list-style-type: none"> - 설치 비용이 큼 - 간섭 문제 발생
적외선 기반	<ul style="list-style-type: none"> - 짧은 인식 거리로 정확한 측위 가능 - 상용화 솔루션이 많음 	<ul style="list-style-type: none"> - 서비스 범위 제한적 - 초반 설치 비용, 유지비용이 큼

2. 관련 연구

1) Wi-Fi 기반 측위 기술

Wi-Fi를 이용한 위치추정 방법은 대표적으로 기준점 (Cell-ID) 기반 추정 방법과 지문(Fingerprinting) 인식 기반 방법, 다변 (Multilateral) 측위, 전파 예측 모델 기반 방법 등이 있다.

기준점 측위 방법은 무선 통신을 기반으로 하는 측위 방식은 모두 사용 가능한 측위 방식으로, 수신된 신호 중 가장 신호가 강한 Wi-Fi AP를 이용하여 위치를 추정하는 방법이다. 해당 방법의 정확도는 실내공간에 Wi-Fi AP의 배치된 밀도에 따라 가변적이지만, 일반적으로 약 50m 정도의 큰 오차를 가지고 있어, 실사용하기에 정확도가 매우 낮다.

다변 측위 방법은 Wi-Fi AP로부터 수신되는 신호의 세기를 전파모델링을 통해 AP와의 거리로 환산하고, 다수의 AP로부터의 거리 정보들을 이용하여 보행자의 위치를 계산하는 방법으로, TDOA(Time Difference Of Arrival),

TOA(Time Of Arrival), AOA(Angle Of Arrival) 등이 있다.

비교적 간단한 수학적 모델과 수신된 신호를 이용하여 위치 정보를 얻을 수 있는 장점이 있지만, 전파의 반사, 흡수, 굴절, 차단 등의 문제가 발생할 수 있어, 수신 신호의 오차가 크고, Wi-Fi AP의 정확한 위치를 알아야, 추정이 가능하다.

지문 인식 기반 방법은 추정을 위해 2가지 단계가 필요하다. 첫 번째 단계는 데이터 수집 단계로, 실내공간에 임의로 정한 일정한 간격으로 위치를 정하고 해당 위치에 레이블을 정한다. 그리고 각 좌표에서 주변 AP로부터 수신되는 Wi-Fi 정보들과 임의로 정한 레이블을 결합하여 저장한다. 저장한 데이터들을 통해 실내공간에 대한 전파맵(radio-map)을 구성한다. 두 번째 단계는 현재 보행자의 위치에서의 Wi-Fi 정보를 전파맵과 비교하여 전파맵에서 가장 유사한 특징을 가지는 레이블로 보행자의 위치를 추정한다.

지문 인식 기반 방법은 Wi-Fi AP의 위치를 알 필요가 없고 상대적으로 서비스 범위가 넓으며, 대부분의 건물에 Wi-Fi AP가 이미 구축되어 있어, 추가적인 인프라 설치 비용이 거의 필요하지 않다. 또한, 전파맵 구성 단계에 투자하는 비용에 따라 비교적 높은 정확도를 기대할 수 있고 복잡한 실내 환경에서도 상대적으로 안정적이다. 하지만, 전파맵을 구성하기 위한, 데이터 사전 수집 단계의 비용이 크고 실내 환경이나 AP의 위치가 변하게 될 경우, 전파맵 갱신을 위해 추가적인 데이터 수집이 필요하다¹⁴⁾.

14) 실내 위치기반서비스 이슈 및 표준화(2015), 유재준, 박상준, 정보와 통신: 한국통신학회지, pp.74 - 80

2) IMU 기반 측위 기술

IMU 기반 측위 기술은 센서 기반 측위 기술 중 하나이다. MEMS(Micro-Electro-Mechanical Systems) 센서의 보급으로 스마트폰에 기압계, 자자기계, 가속도계, 자이로스코프 등의 센서가 내장되며 주목받기 시작했고, 대표적으로 IMU 센서값을 이용한 보행자 추측 방법 (PDR: Pedestrian Dead Reckoning)과 기계학습을 통한 추측 방법 등이 있다. 보행자 추측 방법은 보행 수 추정, 보폭 추정, 보행 방향 추정으로 구성되어 있다.

보행 수 추정은 센서값의 주기적인 변화를 인식하여 추정하고, 보폭 추정은 센서값의 변화량과 보폭 주기, 보행자의 특성 등의 특징을 관계식을 통하여 추정한다. 보행 방향 추정은 자이로스코프와 자자기계를 이용하여 추정한다. 자이로스코프는 상대적 방향을 추정할 수 있고 자자기계는 절대 방향을 추정할 수 있다. 각각의 센서는 주변 환경에 따라 오차가 크게 나타날 수 있으므로, 두 센서값의 결합을 통하여 보행 방향을 추정한다. 하지만, 센서값에 계속해서 오차가 누적되고 MEMS의 낮은 정확도, 예측이 힘든 보행자의 특성 등의 단점들로 인해, Wi-Fi, 비컨 등과 결합한 측위 기술이 필요하다.

IMU 센서값의 기계학습을 이용한 보행자 위치추정 방법은 IMU 센서값을 입력으로 하고 보행자의 위치를 출력으로 하는 순환 신경망 (RNN: Recurrent Neural Network) 이나 컨볼루션 신경망 (CNN: Convolution Neural Network) 등의 기계학습 인공 신경망 모델을 사용하는 방법이다.

충분한 양의 데이터를 학습에 사용한다면, 높은 예측 성능을 기대할 수 있고, 학습 데이터에 없는 데이터도 추정할 수 있다. 또한, 수작업 없이 인공지능 모델이 IMU 센서값의 특징을 추출하고 연속 궤적을 추정할 수 있어, 이전 방법들을 능가한다. 하지만, 보행자의 다양한 자세로부터의 보행 특징을 추출하기 위해서는 많은 양의 데이터가 필요하고, 기계학습 모델을 설계하고 최적화하는 것은 전문적인 지식과 노하우를 필요로 한다.

3) 융합 측위 기술

복잡하고 변화하는 실내 환경에서 보행자와 같이 움직이는 물체의 위치를 고 정밀하게 추정하는 것은 어려운 일이다. 따라서, 더 높은 정확도를 달성하기 위해 다양한 측위 기술의 융합을 통한 추정은 불가피하다.

15)는 초광대역과 비전 기반의 추정 기술을 융합하여 PCA(Principal Component Analysis) 기반 칼만 필터링 알고리즘이 기존 칼만 필터링에 비교 하여 평균 제곱 오차 31.8%가 감소하였음을 보였고, 16)는 Wi-Fi와 LiDAR(Light Detection and Ranging)를 융합하여 실내 위치를 추정하였다.

하지만, 이처럼 다양한 센서의 융합 들 중, Wi-Fi fingerprinting 기반 측위 기술과 IMU 기반 측위 기술을 결합한 형태의 알고리즘은 정확성과 보편성 등 여러 가지 측면에서 가장 훌륭한 조합으로 평가받고 있어,¹⁷⁾¹⁸⁾¹⁹⁾ 가장 활발히 연구가 진행되고 있다.

20)은 WKNN (Weighted K Nearest Neighbors) 알고리즘과 ESKF (Error-State Kalman Filter) 알고리즘 기반으로 Wi-Fi와 IMU를 융합하여

15) Peng, Pingping, et al. "An indoor positioning method based on UWB and visual fusion." *Sensors* 22.4 (2022): 1394.

16) Arun, Aditya, et al. "P2slam: Bearing based wifi slam for indoor robots." *IEEE Robotics and Automation Letters* 7.2 (2022): 3326-3333.

17) Ashraf, I.; Hur, S.; Park, Y. Smartphone Sensor Based Indoor Positioning: Current Status, Opportunities, and Future Challenges. *Electronics* 2020, 9, 891. <https://doi.org/10.3390/electronics9060891>

18) Ruizhi, Chen, and C. H. E. N. Liang. "Indoor Positioning with Smartphones: The State-of-the-art and the Challenges." *Acta Geodaetica et Cartographica Sinica* 46.10 (2017): 1316.

19) Nguyen, Khuong An, et al. "A review of smartphones based indoor positioning: Challenges and applications." *IET Cyber Systems and Robotics* 3.1 (2021): 1-30.

20) Li, Z.; Zhang, Y. Constrained ESKF for UAV Positioning in Indoor Corridor Environment Based on IMU and WiFi. *Sensors* 2022, 22, 391. <https://doi.org/10.3390/s22010391>

실내 환경에서 무인 항공기의 위치를 추정하였다. 실험결과 융합 이전과 비교해 성능을 개선하였음을 보였다. 그러나, 실험 공간이 매우 협소하고 곡선 운동이 비교적 적어, 회전 운동 시 오차가 더욱 증가하는 기존 PDR 방법을 사용하였음에도 불구하고, 오차가 작아 보이는 경향이 있다. 21)와 22)는 기존 Wi-Fi fingerprinting 방법과 IMU 데이터 기반 PDR을 EKF (Extended Kalman Filter)를 이용해 보정하여 위치를 추정하였고, 보정 이전보다 성능이 향상됨을 보였다. 그러나, 기존 Wi-Fi fingerprinting 기반 방법을 그대로 사용하고 있어, 더욱 효율적인 Wi-Fi 기반 추정에 대한 연구가 필요하다.

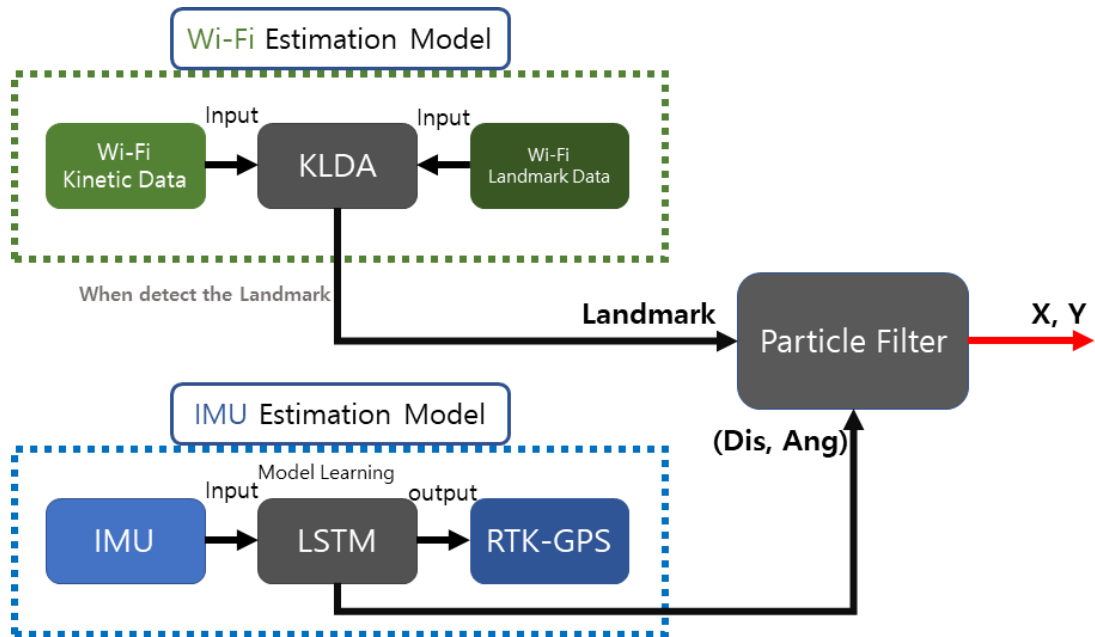
본 논문은 데이터 수집 비용이 크고, 규모가 큰 수집 공간에서는 수집이 불가능에 가깝지만, 비교적 낮은 정확도를 가지는 기존 Wi-Fi fingerprinting 방법을 랜드마크를 이용한 동적 수집 기술과 자동 라벨링 기술을 통하여 수집 비용과 전처리 비용을 크게 줄이고 특정 공간에 대한 추정 정확도를 크게 높이는 방법에 대해 제안한다. 기존 Wi-Fi 추정 방법과 제안하는 Wi-Fi 추정 방법을 실험을 통해 비교하고 RTK GPS (Real Time Kinematic, GPS)를 통해 얻은 지상 실측 레이블과 스마트폰에 내장된 IMU 센서를 통해 얻은 IMU 센서값으로 인공 신경망을 학습하여 구축한 IMU 추정 모델과 융합한 결과를 통하여 위치추정 정확도의 성능 향상을 보였다.

21) Wang, Qianqiu, et al. "Fusion Algorithm of WiFi and IMU for Indoor Positioning." 2022 3rd International Conference on Information Science, Parallel and Distributed Systems (ISPDS). IEEE, 2022.

22) Wang, Xiaobing, et al. "WiFi-PDR indoor fusion positioning based on EKF." 2022 5th World Conference on Mechanical Engineering and Intelligent Manufacturing (WCMEIM). IEEE, 2022.

Ⅲ. 제안 알고리즘

1. 알고리즘 아키텍처



【그림 3-1】 시스템 아키텍처

다음 【그림 3-1】은 본 논문이 제안하는 알고리즘의 아키텍처이다. IMU 추정 모델이 연속적인 위치를 추정하고, 실내공간에 임의로 정한 랜드마크 (Landmark) 지점에 보행자가 위치하여, Wi-Fi 모델이 랜드마크를 감지할 때, Wi-Fi 모델로 추정한 위치값과 IMU 모델이 추정한 위치값을 파티클 필터 (PF: Particle Filter)를 이용하여 결합하고 최종적으로 보행자의 위치를 추정하는 구조이다.

2. Wi-Fi 추정 모델

본 장에서는 기존 Wi-Fi fingerprinting 방법과 같이 특정 좌표로 위치를 추정하지는 않지만, 실내공간에서 특정 경로 또는 랜드마크로 위치를 추정하지만, 레이블 없이 이동하며 데이터를 수집하는 동적 수집 기술과 자동 라벨링 기술을 통하여 수집 비용과 전처리 비용을 크게 줄이고 특정 공간에 대한 추정 정확도를 크게 높이는 방법에 대해 제안한다.

제안하는 방법은 다음과 같다. 실내공간 교차로 부근에 임의로 랜드마크를 지정하여 랜드마크의 위치 라벨과 Wi-Fi fingerprinting을 수집한다. 랜드마크를 제외한 실내공간을 이동하며 라벨이 없는 Wi-Fi fingerprinting을 수집하고 이후 알고리즘을 통해 자동으로 라벨링을 하여 보행자의 이동 경로를 추정한다. 제안하는 방법과 기존 방법의 비교를 위해, 두 방법 모두 수행할 수 있는 비교적 규모가 작은 공간에서 두 방법을 비교하였고 기존 방법으로 추정이 거의 불가능에 가까운 규모의 큰 공간에서도 제안하는 방법으로 경로 추정이 가능함을 보였다.


1) 경로 추정을 위한 기존 방법

본 장에서 Wi-Fi fingerprinting 기반의 실내 경로 추정 시 가장 일반적으로 사용하는 방법인, PCA (Principal Component Analysis)을 이용하여 데이터를 처리하고 K-NN (K-Nearest Neighbor)을 이용하여 위치와 경로를 추정하는 방법을 이용하여 【그림 3-2】(a)의 위치를 추정하는 과정에 대해 서술한다²³⁾²⁴⁾.

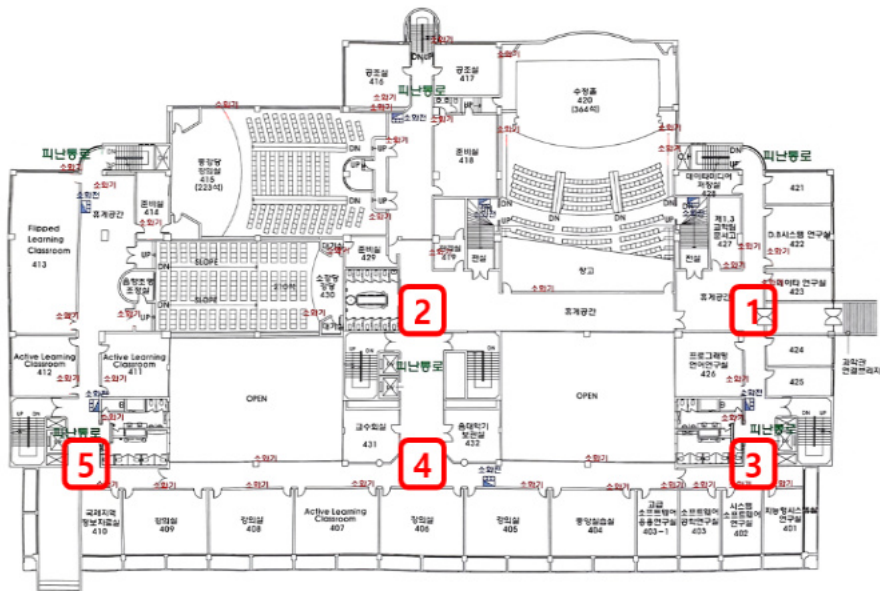
23) Shang, Shuang, and Lixing Wang. "Overview of WiFi fingerprinting based indoor positioning." IET Communications 16.7 (2022): 725-733.

데이터 수집 과정은 다음과 같다. 학습 데이터는 수집 공간인 【그림 3-2】 (a)에서 보행자가 수집 도구를 들고 미리 지정한 89개의 좌표에 서서 좌표와 수신 신호 강도 지표 (RSSI: Received Signal Strength Indicator), 기본 서비스 세트 ID (BSSID: Basic Service Set Identifier) 쌍을 각각의 좌표에서 20개가 저장되도록 하여 얻었다. 테스트 데이터는 【그림 3-2】 (b)에 나타난 특정 지역 번호 1, 3, 4, 5, 4, 2, 1의 순으로 이동하며 데이터를 수집하였고, 총 60개가 수집되었다. 데이터 전처리 과정은 다음과 같다. 학습 데이터와 테스트 데이터 모두에서 수집된 BSSID를 중복 없이 나열하고, 나열된 순서에 맞게 학습 데이터와 테스트 데이터 각각의 RSSI를 재배열한다. 재배열 시 특정 BSSID에 대해 수집된 RSSI가 없는 경우, 가장 작은 가중치 값인 -100을 배열한다. 재배열된 학습 데이터 중 같은 좌표에서 수집한 RSSI 값들은 평균 내어, $(89(\text{좌표 개수}) \times \text{중복 없이 나열한 BSSID의 수})$ 의 학습 데이터와 $(60 \times \text{중복 없이 나열한 BSSID의 수})$ 의 테스트 데이터를 얻고, PCA를 이용하여 데이터 차원의 크기를 축소한다. 전 처리 과정을 거친 학습 데이터를 K-NN을 이용하여 학습하고 테스트 데이터의 위치와 경로를 추정한다.

24) Yoo, Jaehyun. "Multiple Fingerprinting Localization by an Artificial Neural Network." *Sensors* 22.19 (2022): 7505.

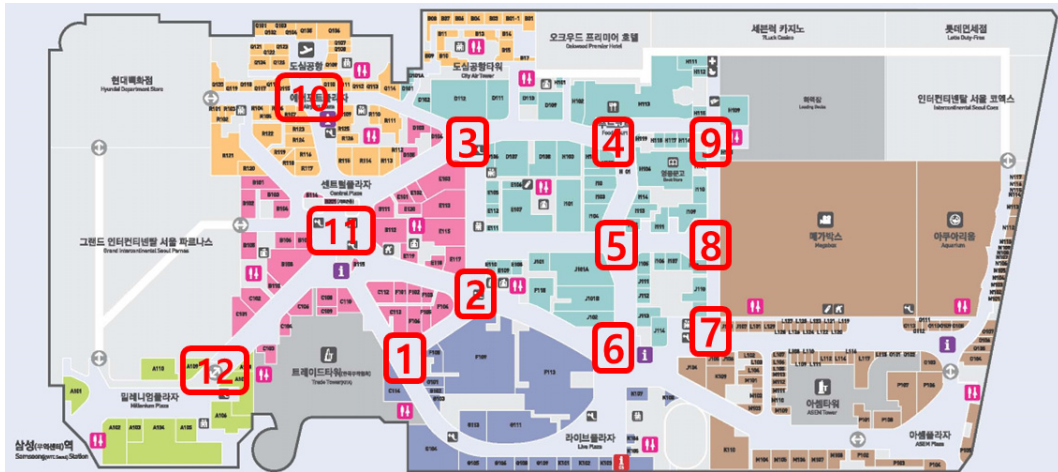


(a) 기존 방법



(b) 본 논문이 제안하는 방법

【그림 3-2】 성신여자대학교 수정관 4층



【그림 3-3】 코엑스 몰 B1층

2) 경로 추정을 위해 제안하는 방법

본 장에서는 랜드마크와 랜드마크를 경유하며 라벨없이 수집한 데이터를 KLDA (Kernel Linear Discriminant Analysis)을 이용하여 클러스터링 (Clustering)하고 랜드마크 사이에 위치한 경로 데이터로 라벨링하는 과정을 거쳐 K-NN을 이용하여 경로를 추정하는 과정을 서술한다. 전체 과정은 데이터 수집 단계와 데이터 전 처리, 추정 단계로 나뉘고, 각 단계에서 수행하는 것은 다음과 같다.

- 데이터 수집 단계:

- (1) 수집 공간 내 복도 교차로 부근을 랜드마크로 설정.
- (2) 데이터(D_1): 랜드마크에 수집 도구를 배치하여 레이블 (특징 지역을 나타내는 번호)와 Wi-Fi Fingerprinting 를 수집하여 구축.

- (3) 학습 데이터(D_2): 각 랜드마크를 최소 한 번씩 경유하며 레이블 없이 Wi-Fi Fingerprinting 수집하여 구축.
- (4) 테스트 데이터(D_3): 실내공간을 무작위로 이동하며 구축.

- 데이터 전 처리 단계:

- (1) 수집한 데이터(D_1, D_2, D_3) 재배열.
- (2) KLDA(Kernel Linear Discriminant Analysis)를 이용하여 재배열한 D_1, D_2, D_3 를 $\hat{D}_1, \hat{D}_2, \hat{D}_3$ 로 처리.
- (3) KLDA의 특징 공간(feature space) 내에서 \hat{D}_1 의 각 클래스와 \hat{D}_2 의 유클리드 거리를 구하고 값의 계곡 지점(valley point)를 구함.
- (4) 각 계곡 지점 사이 데이터(\hat{D}_2)를 해당 랜드마크 사이 경로로 라벨링, 계곡 지점 인근 데이터(\hat{D}_2)를 랜드마크 번호로 라벨링.

- 추정 단계:

- 1) 라벨링한 학습 데이터(\hat{D}_2)를 K-NN (K-Nearest Neighbor)을 이용하여 학습하고 테스트 데이터(\hat{D}_3)를 추정.

2-1) Wi-Fi 데이터 수집

데이터 수집 공간은 【그림 3-2】와 같이 성신여자대학교 수정관 4층과 【그림 3-3】의 삼성역 스타필드 코엑스몰 B1 층으로, 일반적으로 사람이 보행할 수 있는 공간 중 교차로 부근을 랜드마크(1~5)로 지정하여 그림에 나타내었다.

데이터 수집 방법은 다음과 같다. 총 3종류의 데이터(D_1, D_2, D_3)을 구축하였고,

D_1 은 사람이 정지한 상태로 스마트폰을 들고 있거나 삼각대를 이용하여 스마트폰을 고정한 상태로 랜드마크를 나타내는 라벨과 Wi-Fi Fingerprinting(RSSI, BSSID)를 각 랜드마크에서 【그림 3-2】에서는 100개씩 수집하여 총 500개, 【그림 3-3】에서는 200개씩 총 2400개의 데이터 쌍을 수집하여 구축하였다. D_2 는 각각의 랜드마크 사이에 이동 가능한 모든 경로를 최소 한 번 이상 경유하며 라벨없이 Wi-Fi fingerprinting을 수집하여 얻었다.

D_3 은 결과 분석을 위한 테스트 데이터로, 실내공간을 무작위로 이동하며 Wi-Fi fingerprinting을 수집하였고 이동 중 랜드마크에 도착할 때마다 타임 스탬프(time stamp)를 저장하여 이후 결과 분석에 사용하도록 하였다.

2-2) Wi-Fi 데이터 전처리

데이터 전처리 단계에서는 세부적으로 데이터 재배열, KLDA 적용, 경로 데이터 라벨링 단계로 구성되어 있으며, 나열한 순서대로 서술한다.

데이터 재배열 단계에서 수행하는 내용은 다음과 같다. 수집한 데이터(D_1, D_2, D_3)의 BSSID에서 특정 빈도수 이하로 수집된 데이터를 제거하고 중복없이 하나의 벡터로 나열한다. 중복없이 나열한 BSSID에 대해 나열된 순서와 동일하게 D_1, D_2, D_3 의 각각의 RSSI를 재배열한다. 재배열 중 특정 BSSID에 대해 수집된 값이 없는 경우, 가장 작은 가중치를 나타내는 값이 “-100”을 배치한다.

KLDA 적용 단계에서 사용하는 KLDA는 비선형 함수를 이용하여 각 데이터 클래스의 분산을 최소화하고 데이터 클래스 간의 분산은 최대화하는 특징 벡터(ω)에 데이터를 투영하여 데이터의 차원을 축소한다. 동시에 데이터를 각 클래스끼리 나누어 데이터 클러스터링도 함께 적용된다. KLDA 적용 단계는 라벨이 없는 데이터 (D_2)을 특징 지역 사이에 위치한 경로 데이터로 라벨링하기 위해

D_1, D_2 순으로 KLDA를 이용하여 처리하고 처리한 \hat{D}_2 와 \hat{D}_1 의 특정 클래스 간의 유클리드 거리를 이용하여 D_2 을 각각의 경로 데이터로 클러스터링 과정으로, 다음과 같다.

데이터 재배열 단계에서 처리한 데이터, D_1, D_2, D_3 을 식 (1)로 각각 정의한다. n 은 수집된 Wi-Fi AP 개수로, BSSID를 중복없이 나열한 벡터의 차원 수와 같다. $rssi_{dk}$ ($k = 1, \dots, n$)는 n 개의 Wi-Fi AP 중 k 번째 AP에서 얻은 RSSI 스칼라값이고, c 는 데이터 클래스 수로, 랜드마크 수와 같고 L_1, \dots, L_c 는 랜드마크에서 얻은 데이터의 개수이고, ℓ_2, ℓ_3 은 D_2, D_3 을 각각 수집한 데이터 개수이다.

$$\begin{aligned}
 D_1 &= \begin{bmatrix} rssi_{L_{11}}, & rssi_{L_{12}}, & rssi_{L_{13}}, & \dots, & rssi_{L_{1n}} \\ & & \vdots & & \\ rssi_{L_{c1}}, & rssi_{L_{c2}}, & rssi_{L_{c3}}, & \dots, & rssi_{L_{cn}} \end{bmatrix} \in R^{L \times n}, \quad (L = \sum_{i=1}^c L_i) \\
 D_2 &= \begin{bmatrix} rssi_{\ell_{21}}, & rssi_{\ell_{22}}, & rssi_{\ell_{23}}, & \dots, & rssi_{\ell_{2n}} \\ & & \vdots & & \\ rssi_{\ell_{31}}, & rssi_{\ell_{32}}, & rssi_{\ell_{33}}, & \dots, & rssi_{\ell_{3n}} \end{bmatrix} \in R^{\ell_2 \times n} \\
 D_3 &= \begin{bmatrix} rssi_{\ell_{31}}, & rssi_{\ell_{32}}, & rssi_{\ell_{33}}, & \dots, & rssi_{\ell_{3n}} \\ & & \vdots & & \\ rssi_{\ell_{31}}, & rssi_{\ell_{32}}, & rssi_{\ell_{33}}, & \dots, & rssi_{\ell_{3n}} \end{bmatrix} \in R^{\ell_3 \times n} \quad (1)
 \end{aligned}$$

KLDA의 커널은 가우시안 커널 (Gaussian Kernel)을 사용하였으며, ϕ 는 특징 공간 (F , feature space)에 대한 비선형 매핑 함수이다. 특징 공간에서 식 (2)를 최대화하는 벡터(ω)가 식 (2)의 최적해가 된다. 여기서, $\omega \in F$ 와 S_B^ϕ, S_W^ϕ 는 F 의 대응행렬이다. 특징 공간은 D_1 을 KLDA를 이용하여 차원을 축소하고 축소된 각 차원의 스칼라 값을 하나의 축의 값으로 하여 나타낸 공간을 말한다.

$$\mathcal{J}(\omega) = \frac{\omega^T S_B^\phi \omega}{\omega^T S_W^\phi \omega} \quad (2)$$

식 (2)의 S_B^ϕ 와 S_W^ϕ 그리고 m_i^ϕ 는 식 (3)과 같다.

$$m_i^\phi = \frac{1}{n} \sum_{x \in X} x_k, \text{ with } (X = D_1(i, \{1, 2, \dots, n\}))$$

$$S_B^\phi = (m_1^\phi - m_2^\phi - \dots - m_c^\phi)(m_1^\phi - m_2^\phi - \dots - m_c^\phi)^T$$

$$S_W^\phi = \sum_{i=1}^L \sum_{x \in X} (\phi(x) - m_i^\phi)(\phi(x) - m_i^\phi)^T \quad (3)$$

Mika (1999)²⁵⁾의 계산과정에 따라 식 (3)을 이용하여 식 (2)의 최적해를 구하는 과정을 거치면, 식 (4)를 얻을 수 있고, 식 (4)는 $Av = \lambda v$ 형태로 일반적인 고유값 문제(Eigenvalue problem) Parlett (1998)²⁶⁾의 풀이 과정으로 ω 를 구하여 식 (5)와 같이 ω 에 D_1, D_2, D_3 을 각각 투영하여 $\acute{D}_1, \acute{D}_2, \acute{D}_3$ 을 얻는다.

$$(S_W^\phi)^T S_B^\phi \omega = \lambda \omega \quad (4)$$

$$\acute{D}_1 = (\omega \cdot \Phi(D_1)) = \sum_{i=1}^n \omega_i \cdot k(D_{1i}, D_1)$$

$$\acute{D}_2 = (\omega \cdot \Phi(D_2)) = \sum_{i=1}^n \omega_i \cdot k(D_{1i}, D_2)$$

25) Mika, S., Ratsch, G., Weston, J., Scholkopf, B., Mullers, K. R. 1999, Fisher discriminant analysis with kernels, Neural networks for signal processing IX: Proceedings of the 1999 IEEE Signal Processing Society Workshop (Cat. No.98TH8468), 25 August 1999, Madison, WI, USA. <https://doi.org/10.1109/NNSP.1999.788121>

26) Parlett, B. N. 1998, The symmetric eigenvalue problem (Philadelphia: Society for industrial and Applied Mathematics). <https://doi.org/10.1137/1.9781611971163>

$$\dot{D}_3 = (\omega \cdot \Phi(D_3)) = \sum_{i=1}^n \omega_i \cdot k(D_{1i}, D_3) \quad (5)$$

경로 데이터 라벨링 단계에서는 \dot{D}_2 을 랜드마크 사이의 경로로 라벨링 과정에 대해 서술하고 과정은 다음과 같다.

【그림 3-4】은 특징 공간상에서 \dot{D}_1 의 각 클래스의 평균값과 \dot{D}_2 간의 유클리드 거리 (Euclidean distance)를 나타낸 그래프이다.


【그림 3-4】(a)은 【그림 3-2】에서 수집한 데이터의 유클리드 거리를 나타내고 【그림 3-4】(b)은 【그림 3-4】(a)를 가우시안 필터 (Gaussian filter)를 이용해 값을 스무딩 (smoothing)하여 나타낸 그래프이다. 【그림 3-4】(c)은 【그림 3-3】에서 수집한 데이터의 유클리드 거리를 나타내고, 【그림 3-4】(d)은 【그림 3-4】(c)를 가우시안 필터를 이용하여 값을 스무딩한 그래프이다. 다음으로, 【그림 3-4】(b)와 【그림 3-4】(d)에 적절히 정한 임계 값(threshold) 이하의 값들 중 식 (6)을 사용하여 계곡 지점 (valley point)을 찾아 표시하였다. 식 (6)은 특징 공간상에서 \dot{D}_1 의 각 클래스와 \dot{D}_2 간의 유클리드 거리를 구한 값들의 집합을 순서대로 나열한 값을 Ed 로 정의하고 n 은 Ed 의 수, 계곡 지점의 데이터는 Ed_v 라고 정의한다.

$$Ed = (Ed_1, Ed_2, \dots, Ed_n)$$


$$Ed_v = Ed_k \quad (\text{when, } Ed_{k-1} < Ed_k < Ed_{k+1} \quad (1 < k < n)) \quad (6)$$

계곡 지점 데이터는 보행자가 하나의 랜드마크와 가장 근접했을 때 수집된 데이터라 할 수 있다. 그리고 계곡 지점 사이의 데이터들은 보행자가 두 곳의 랜드마크 사이를 이동할 때 수집된 데이터라고 할 수 있다. 그러므로, 각 계곡 지점 사이에 존재하는 \dot{D}_2 데이터들을 두 랜드마크 사이 경로 데이터로 라벨링한


다. 그리고, \hat{D}_2 의 데이터 중 각 계곡 지점과 인접한 데이터를 랜드마크 라벨로 라벨링한다. 【그림 3-5】는 랜드마크 공간 상에서 \hat{D}_1 의 각 클래스와 \hat{D}_3 간의 유클리드 거리를 나타낸다. 【그림 3-5】(a), (b)는 각각 【그림 3-2】과 【그림 3-3】에서 수집한 데이터의 유클리드 거리로, 가우시안 필터를 사용해 값을 스무딩하여 나타낸 그래프이다.




(a) 성신여자대학교 수정관 4층



(b) (a)의 값을 스무딩한 결과




(c) 코엑스몰 B1층




(d) (c)의 값을 스무딩한 결과

【그림 3-4】 특징 공간 내 \hat{D}_1 과 \hat{D}_2 클래스 간 유클리드 거리



(a) 성신여자대학교



(b) 코엑스 물

【그림 3-5】 특징 공간 내 \hat{D}_1 과 \hat{D}_3 클래스 간 유클리드 거리

2-3) Wi-Fi 데이터 경로 추정

본 장은 Wi-Fi 데이터를 앞선 단계들을 거쳐 처리하고, K-NN 알고리즘을 이용하여 실내 보행자가 위치한 경로 또는 랜드마크를 추정하는 과정을 서술한다.

식 (7)에 나타난 K-NN 알고리즘을 이용하여 \hat{D}_2 을 학습하고 \hat{D}_3 의 이동 경로를 예측한다. N 은 하나의 \hat{D}_3 데이터와 모든 \hat{D}_2 데이터와의 유클리드 거리를 구해 나열한 벡터이다. N 의 값들을 오름차순으로 나열한 후 가장 작은 수부터 적절히 선택한 변수까지의 원소들의 레이블 중 가장 빈도가 많은 레이블로 \hat{D}_3 의 경로를 예측한다.

$$\begin{aligned}
\hat{D}_2 &= \begin{bmatrix} a_{11}, & a_{12}, & \cdots, & a_{1M} \\ & \vdots & & \\ a_{\ell_2 1}, & a_{\ell_2 2}, & \cdots, & a_{\ell_2 M} \end{bmatrix} \in R^{\ell_2 \times M} \\
\hat{D}_3 &= \begin{bmatrix} b_{11}, & b_{12}, & \cdots, & b_{1M} \\ & \vdots & & \\ b_{\ell_3 1}, & b_{\ell_3 2}, & \cdots, & b_{\ell_3 M} \end{bmatrix} \in R^{\ell_3 \times M} \\
N_j &= \sqrt{\sum_{i=1}^M (a_{ji} - b_{1i})^2}, \quad (j = 1, 2, \dots, \ell_2) \\
N &= (N_1, N_2, \dots, N_{\ell_2}) \in R^{\ell_2} \tag{7}
\end{aligned}$$

또한, 식 (7)를 통해 추정한 라벨이 랜드마크일 때, 해당 랜드마크에서 도달할 수 있는 경로로만 추정하거나 가장 최근에 추정한 랜드마크에서 이동 가능한 경로만 추정하도록 보정 알고리즘을 사용하였다.

3. IMU 추정 모델

기존 IMU를 이용한 위치추정 방법은 영속도 검출(Zero Velocity Detection), 카메라(vision sensor)와 결합 등이 있다. 영속도 검출은 사람 발에 IMU 센서를 부착하여 속도가 0일 때를 감지하여 위치를 추정하는 방법으로, 대략적인 추측으로 위치를 추정하여 오차가 크고 누적되는 센서 오차에 대해 무방비다. 카메라 센서와 결합하는 방법은 복잡한 시간 동기화와 보정이 필요하다는 등 요구되는 조건이 다양하다. 그러므로, 본 논문에서는 현재 IMU를 이용한 추정 방법 중 기존 추정 방법의 단점들을 해결한, 기계학습 모델을 이용하여 IMU 센서값을 학습하고 위치를 추정하는 방법을 사용한다.

본 장은 【그림 3-1】에 나타난 IMU 추정 모델을 구성하는 과정에 대해 서술한다. 과정은 학습 데이터 수집, 데이터 전처리 및 학습, 추정의 단계로 구성되어 있으며, 나열한 순서대로 서술한다.

1) IMU 데이터 수집


본 모델의 인공지능 모델 학습을 위한 데이터는 입력 데이터에 해당하는 IMU 센서값과 출력 데이터에 해당하며 입력 데이터의 레이블인, 위치 좌표로 구성되어 있다. 입력 데이터와 출력 데이터는 같은 장소, 같은 사람이 수집하지만, 다른 두 개의 기기를 이용하여 수집하였다.

입력 데이터는, 스마트폰에 내장되어있는 IMU 센서를 이용하였고, 보행자가 실외에서 스마트폰을 보행자 전방에 손으로 들고 수집하였다. IMU 센서값들 중 가속도 (acceleration) 센서와 자이로스코프 (gyroscope) 센서의 센서값을 사용하였고, 200[Hz]의 주기로 데이터를 수집하였다. 각각의 센서값은 3개의 축 (X, Y, Z축)을 가지고 있고, 하나의 데이터를 수집할 때마다, 수집 시간

(time stamp)도 함께 저장하여, 데이터는 총 7개의 차원을 가진다.

출력 데이터는, 기준국의 반송파 위상에 대한 보정치를 이용하여 이동국에서 실시간으로 정확한 위도, 경도 정보를 제공하는, RTK GPS를 이용하였다. 1[Hz]의 주기로 위치 정보를 수집하였고, 기기를 보행자와 최대한 가깝게 유지하며, 수집하였다. 데이터는 주기마다 수집된 위도, 경도와 수집 시간(time stamp) 형태로, 3개의 차원을 가진다.

【그림 3-3-1】은 성신여자대학교 운동장에서 수집한 학습 데이터의 일부로, 약 20분 동안 수집한 데이터이며, RTK GPS를 통해 수집한 위도, 경도 좌표를 표시한 것이다. 【그림 3-3-1】과 유사한 형태로 총 4개의 보행 데이터를 구축하였고 보행 길이는 약 2[km]이다²⁷⁾.



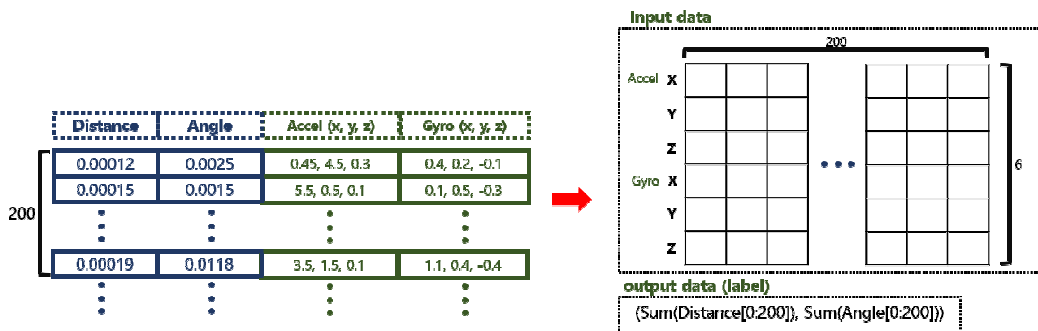
【그림 3-6】 학습 데이터 일부

27) OxIOD: The Dataset for Deep Inertial Odometry (2018), Changhao Chen, Peijun Zhao, Chris Xiaoxuan Lu, Wei Wang, Andrew Markham, Niki Trigoni, <https://arxiv.org/abs/1809.07491>

2) IMU 데이터 전처리 및 학습

RTK GPS를 이용하여 얻은 출력 데이터는 전 세계를 기준으로 하는 절대 좌표 위도, 경도로 나타나 있어, 상대적인 이동 데이터로의 변환이 필요하다. 그러므로, 위도와 경도를 변위(變位)와 각 변위(角變位)의 형태로 변환한다.

입력 데이터와 출력 데이터는 각기 다른 장치를 통하여 수집하였고, 수집 주기 또한 다르다. 그러므로, 데이터 수집 시 함께 수집한 시간을 통하여 데이터를 동기화하였다. 동기화 후, RTK GPS의 이전 데이터와 다음 데이터 사이에 존재하는 IMU 센서값의 수 만큼 변위와 각 변위의 값을 나누어 해당 값들을 IMU 센서 데이터들의 레이블로 메겨 주었다. 그리고 【그림 3-7】 과 같이 데이터를 200개씩 잘라 가속도와 자이로 센서 데이터는 6×200 형태의 입력데이터로, 변위와 각 변위를 각각 합하여 2차원의 출력 데이터로 변환하였다. 해당 방법처럼 전체 데이터를 10 step 간격으로 처리하였다.



【그림 3-7】 IMU 데이터 구성

앞서 구성한 IMU 데이터와 같이 시계열 데이터를 처리하는 모델 중 대표적

인 모델인, RNN (Recurrent Neural Network)은 이전 시점의 출력값이 다음 시점의 입력값으로 전달되는 구조를 가지고, 이러한 구조는 시계열 데이터를 처리하는 데 적합하지만, 시계열이 길어질수록 이전의 입력값이 현재 출력값에 미치는 영향이 적어져, 장기 의존성 문제가 발생한다. 이러한 문제를 해결하기 위한 모델이 LSTM (Long Short-Term Memory)이다. LSTM은 각 시점에서 새로운 입력값과 이전 시점의 출력값을 이용하여 새로운 정보를 추가하고, 이전 정보를 보존하며 필요한 정보를 삭제하는 방법을 도입한 모델이다. 본 논문에서는 IMU 데이터를 학습하기 위한 모델로, 장기 의존성 모델링 능력과 시계열 데이터 처리 능력이 우수한 LSTM 모델을 사용하였다. 학습 시, 손실함수는 평균 제곱 오차 (MSE, Mean Squared Error)를 사용하였고, 최적화 함수는 Adam (Adaptive Moment Estimation)을 사용하였다. 그리고, epoch, batch_size, learning_rate 등의 파라미터는 학습을 진행하며 적절히 변경하였다²⁸⁾.

28) RoNIN: Robust Neural Inertial Navigation in the Wild: Benchmark, Evaluations, and New Methods (2019), Hang Yan, Sachini Herath, Yasutaka Furukawa, <https://arxiv.org/abs/1905.12853>

4. 파티클 필터

파티클 필터 (Particle Filter)는 trial and error에 기반 시뮬레이션을 통한 예측 기술의 하나로, SMC (Sequential Monte Carlo) 방법이라고도 하며, non-linear, non-Gaussian 시스템에서도 잘 동작한다.

본 논문에서는 IMU 모델을 통하여 보행자의 위치를 추정하다가, Wi-Fi 모델을 통하여 랜드마크를 식별했을 때, 파티클 필터를 이용하여 위치를 보정한다.

【표 3-1】은 파티클 필터 알고리즘을 나타낸다. $t-1$ 은 Wi-Fi 모델이 랜드마크를 식별하기 직전, t 는 랜드마크를 식별했을 때의 시간을 나타낸다. x 는 IMU 모델을 통하여 얻은 위치 좌표에 가우시안 (Gaussian) 랜덤 변수를 더한 값으로, 파티클이다. w 는 파티클의 가중치이고, z_t 는 IMU 추정 모델의 파티클과 Wi-Fi 모델이 추정한 랜드마크 좌표와의 거리 차이이다. 랜드마크 좌표는 지도상에 위치한 랜드마크의 위치 좌표로, 【그림 3-2】에 표시한 각각의 랜드마크의 위치이다. S 는 파티클의 집합이고, η 은 확률 밀도함수의 정규화 상수, n 은 파티클의 수이다.

【표 3-1】 파티클 필터 알고리즘

Algorithm Particle_Filter	$\{S_{t-1} = \langle x_{t-1}^j, w_{t-1}^j \rangle, u_t, z_t\}$
1. $S_t = \emptyset, \eta = 0$	
2. For $i = 1, \dots, n$	Resample (generate i new sample)
3. Sample index $j(i)$ from the discrete distribution given by w_{t-1}	
4. Sample x_t^i from $p(x_t x_{t-1}, u_t)$ using $x_{t-1}^{j(i)}$ and u_t Control	
5. $w_t^i = p(z_t x_t^i)$	Compute importance weight (reweight)
6. $\eta = \eta + w_t^i$	Update normalization factor
7. $S_t = S_t \cup \{\langle x_t^i, w_t^i \rangle\}$	Insert
8. For $i = 1, \dots, n$	
9. $w_t^i = w_t^i / \eta$	Normalize weights

IV. 실험 결과

1. Wi-Fi 추정 기존 방법과 제안하는 방법 비교

1) 실험환경

본 장에서는 두 곳의 실내공간에서 실험을 진행하여 Wi-Fi fingerprinting을 이용한 경로 추정 방법의 기존 방법과 본 논문에서 제안하는 방법을 비교 분석하였다.

첫 번째 실험환경은 【그림 3-2】 과 같이 성신여자대학교 수정관 4층으로, $3,400m^2$ 의 비교적 협소한 실내공간이다. 【그림 3-2】 (a)는 기존 추정 방법을 수행하기 위해, 실내공간에 약 $2m$ 간격으로 좌표를 설정하여 나타내었다. 【그림 3-2】 (b)는 본 논문에서 제안하는 방법을 수행하기 위해, 복도 교차로 부근에 임의로 총 5개의 랜드마크를 설정하였다. 이동 경로는 【그림 3-2】 (b)에서 각각의 랜드마크 사이 복도에 해당하고, 총 10개이다.

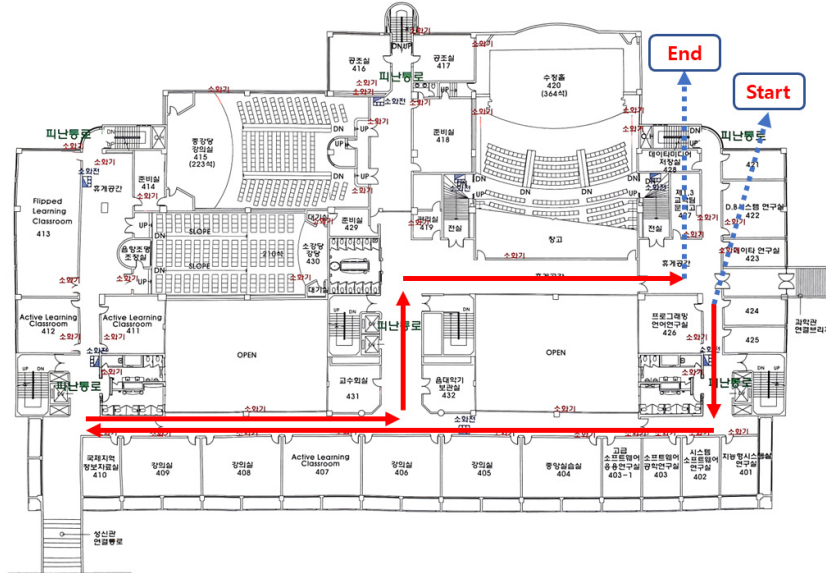
두 번째 실험환경은 【그림 3-3】 와 같이 코엑스 몰 B1 층으로, $119,008.8m^2$ 의 비교적 넓은 실내공간이다. 두 번째 실험 공간은 기존 추정 방법을 사용하기에 거의 불가능에 가까운 규모의 실내공간으로, 본 논문에서 제안하는 방법의 추정 여부를 확인하기 위해 설정하였다. 실험을 위해 복도 교차로 부근에 임의로 총 12개(1~12)의 랜드마크를 설정하였고, 경로는 31개이다. 기존 추정 방법을 첫 번째 실험환경에서 진행하였고, 제안하는 추정 방법은 실험환경 두 곳 모두에서 진행하였다.

2) 실험 결과


【표 4-1】 Wi-Fi 추정 모델 평가 기준

Step	True	Some of case that are considered correct						Some of cases wrong	
		case 1	case 2	case 3	case 4	case 5	case 6		
1	between 1 and 3 (1, 3)	(1, 3)	(1, 3)	(1, 3)	(1, 3)	(1, 3)	(1, 3)	(1, 3)	(1, 3)
2	(1, 3)	(1, 3)	(1, 3)	(1, 3)	(1, 3)	(1, 3)	(1, 3)	Land 3	(1, 3)
3	(1, 3)	(1, 3)	(1, 3)	(1, 3)	(1, 3)	(1, 3)	(1, 3)	(3, 4)	(1, 3)
4	(1, 3)	Land 3	(1, 3)	(1, 3)	(1, 3)	Land 3	(1, 3)	(3, 4)	Land 3
5	(1, 3)	(3, 4)	Land 3	(1, 3)	(1, 3)	Land 3	Land 3	(3, 4)	(3, 4)
6	Land 3	(3, 4)	(3, 4)	Land 3	(1, 3)	Land 3	Land 3	(3, 4)	Land 3
7	(3, 4)	(3, 4)	(3, 4)	(3, 4)	Land 3	Land 3	(3, 4)	(3, 4)	(3, 4)
8	(3, 4)	(3, 4)	(3, 4)	(3, 4)	(3, 4)	Land 3	(3, 4)	(3, 4)	(3, 4)
9	(3, 4)	(3, 4)	(3, 4)	(3, 4)	(3, 4)	(3, 4)	(3, 4)	(3, 4)	(3, 4)
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮

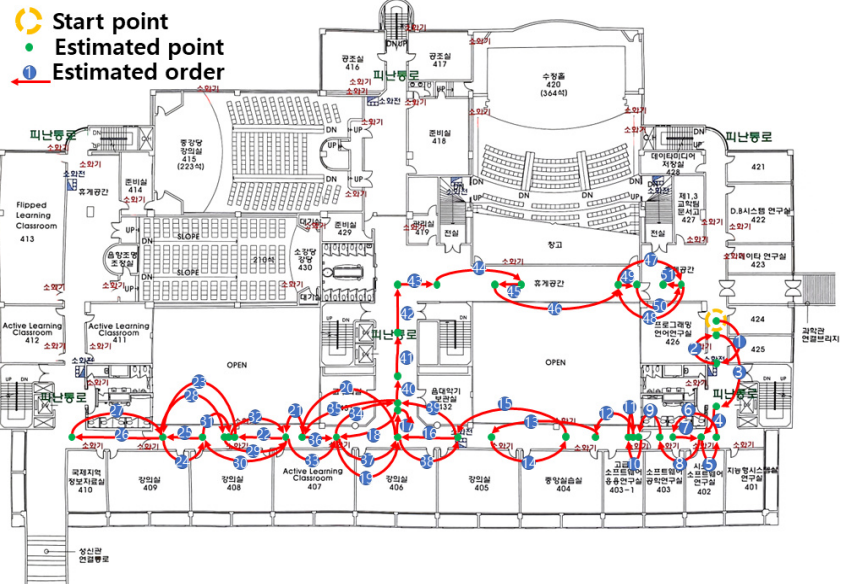
【표 4-1】은 제안하는 방법을 이용하여 추정한 이동 경로를 평가하기 위한 기준표로, Land 1(랜드마크 1)에서 Land 3, Land 4로 이동한 결과를 평가한 예시이다. True는 테스트 데이터 수집 시 실제 이동한 경로로, 데이터 수집 시, 랜드마크를 지나칠 때마다 저장한 타임스탬프를 기준으로 정하였고, 실제 랜드마크 도착 시간과의 오차가 존재하기 때문에 예측 가능 구간을 설정하였다. 성신여대에서는 2개, 코엑스 몰에서는 3개의 Step을 예측 가능 구간으로 설정하였다. 예측 가능 구간 내에 Land 3을 예측 또는 연달아 예측한 후 다음 경로를 예측했을 때, 옳게 예측한 것으로 평가하였다. some of cases wrong은 틀리게 예측한 예로, 예측 가능 구간 외에서 랜드마크를 예측하거나 예측 가능 구간 내에서 불연속적으로 랜드마크를 예측했을 때를 틀리게 예측한 것으로 평가하였다.



(a) 테스트 데이터 실제 궤적



(b) 기존 방법으로 추정된 경로



(c) 제안하는 방법으로 추정된 경로

【그림 4-1】 성신여자대학교 실험 결과

【그림 4-1】(a)은 성신여대에서 수집한 테스트 데이터의 실제 이동 경로이다. 【그림 4-1】(b), (c)의 초록색 점은 추정된 좌표를 표시한 것이고, 파란색 동그란 점선은 첫 번째로 추정된 좌표를 표시한 것이며, 빨간 화살표와 번호는 추정된 좌표의 순서를 나타낸 것이다. 【그림 4-1】(b)은 기존 방법으로 테스트 데이터의 경로를 추정한 결과이고, 【그림 4-1】(c)은 제안하는 방법으로 테스트 데이터의 경로를 추정하고, 식 (5)의 \hat{D}_1 와 식 (7)의 \hat{D}_3 간의 유클리드 거리를 실내 지도 비율에 맞게 표시한 것이다.

【그림 4-2】 (a)는 코엑스 물에서 수집한 테스트 데이터의 실제 이동 경로를 나타내고, 【그림 4-2】 (b)는 【그림 4-1】 (c)과 같이 제안하는 방법으로 추정된 테스트 데이터의 경로를 실내 지도에 표시한 것이다.

【표 4-2】 Wi-Fi 추정 기존 방법과 제안하는 방법의 실험 환경과 결과

Environment	Sungshin		Coex	
Area(m^2)	3,400		119,008.8	
Method	Existing	Proposed	Existing	Proposed
Number of data	1,780	500	64,000 (presumption)	2,400
Accuracy(%)	79.7	90.2	-	81.4

【표 4-2】는 실험 환경과 각각의 다른 환경에서 기존 방법과 제안하는 방법으로 실험을 진행하여 얻은 결과를 나타낸다. 【그림 4-1】 (b)와 같이 성신여자대학교에서 기존 방법으로 추정된 결과 1,780개의 데이터를 수집하여 학습하고 59개의 테스트 데이터를 추정된 결과 47개를 옳게 예측하여 79.7%의 정확도를 얻었다. 또한 【그림 4-1】 (c)과 같이 성신여자대학교에서 제안하는 방법으로 500개의 데이터를 수집하여 학습하고 51개의 테스트 데이터를 추정된 결과 46개를 옳게 예측하여 90.2%의 정확도를 얻었다. 【그림 4-2】 (b)와 같이 코엑스 물에서 제안하는 방법으로 290개의 테스트 데이터를 추정된 결과 236개를 옳게 예측하여 81.4%의 정확도를 얻었다.

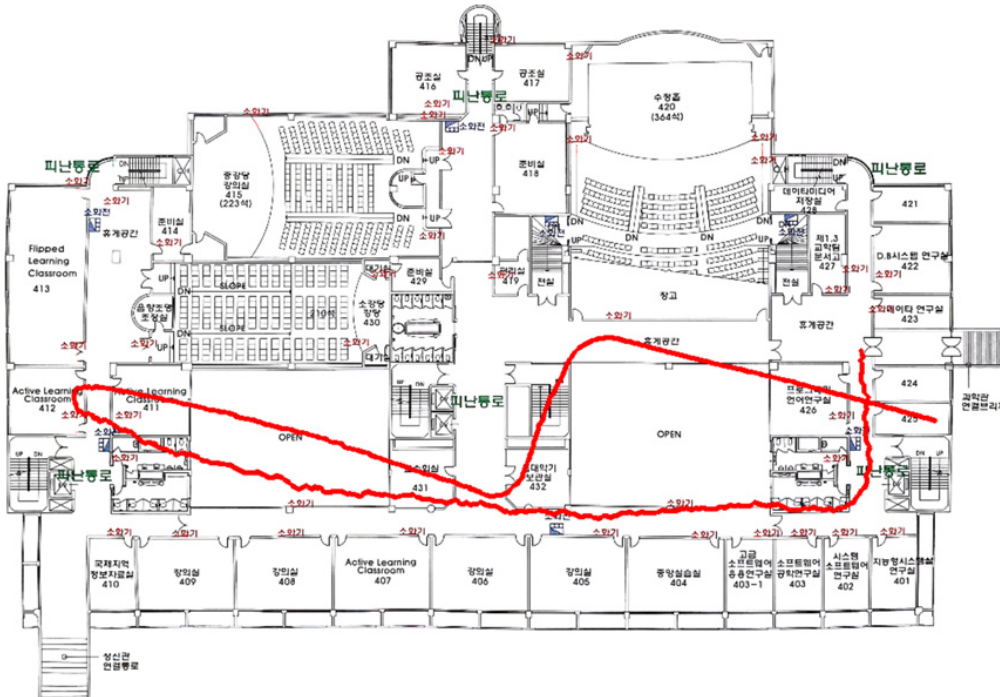
제안하는 방법과 기존 추정 방법을 성신여자대학교에서 추정된 결과 약 3.5배의 더 많은 학습 데이터를 수집한 기존 방법이 더 낮은 정확도를 보였다.

본 실험에서 기존 방법으로 코엑스 물을 추정하기 불가능에 가까운 이유는 다음과 같다. 성신여자대학교에서 기존 방법 추정 시, 통로 일부만 좌표를 설정하여 89개의 좌표가 필요로 했다. 코엑스 물이 성신여자대학교과 비교하여 35배 큰 면적을 가지고 있어, 약 3,200개의 좌표가 필요하다고 가정한다면,

한 좌표당 20개의 데이터를 수집하여, 64,000개를 수집해야 하고 수집 시간은 약 3,200분이 필요하고, 좌표 설정 시간 등을 포함하면 실로 더 많은 시간이 필요할 것이다. 더불어, 실험을 진행하더라도, 제안한 방법에 비해 더 높은 추정 결과를 기대하기 어려워 비효율적인 방법이라고 할 수 있다.

2. IMU 모델 추정 결과

【그림 4-3】은 【그림 3-2】에서 수집한 테스트 IMU 데이터로 학습한 LSTM 모델로 추정한 결과이다. LSTM 모델로 변위(*Dis*)와 각 변위(*Ang*)를 얻고, 식 (8)을 이용하여 좌표를 구하고 지도에 표시하였다.



【그림 4-3】 IMU 모델 추정한 보행 궤적

$$\begin{aligned}
 x &= Dis \times \sin(Ang) \\
 y &= Dis \times \cos(Ang)
 \end{aligned}
 \tag{8}$$

초기 위치와 초기 방향을 실제 초기 위치와 방향으로 일치한 후 궤적을 표시하였고 교차로 부근에서의 회전과 이동 거리가 보정이 필요하다는 것을 결과

여 위치를 보정 하였기 때문이다.

【그림 4-3】의 결과 중 누적된 위치 오차값으로 실제 위치한 곳과 차이가 있었던 랜드마크 4, 5 부근이 【그림 4-4】에서는 보행자가 실제 위치한 곳과 비교적 일치하였고, RMSE 1.98[m]로, 융합 이전의 IMU 모델보다 정확도가 약 2.9배 상승하였다.

V. 결 론

1. 요약

본 논문에서 제안한 Wi-Fi Fingerprinting을 이용한 위치추정 모델은 실내에 임의로 정한 랜드마크와 동적 데이터 수집, 자동 라벨링 기술을 이용하여 기존 Wi-Fi Fingerprinting 추정 방법의 많은 수집 비용에 대한 문제점을 해결 하였고, 보다 효율적이고, 다른 센서 데이터와 융합하기에 적절한 모델임을 실험을 통해 보였다. 또한, 실제 보행을 통해 얻은 IMU 센서 데이터와 RTK GPS를 이용한 지상 실측 레이블을 통해 구축한 IMU 모델을 제안하는 Wi-Fi 모델과의 융합 추정에서도 위치추정 정확도를 높인다는 것을 실험을 통해 증명하였다.

2. 연구 한계 및 추후 연구 방안

본 논문이 제안하는 알고리즘의 결과, 랜드마크를 통해 IMU 모델이 추정한 위치를 성공적으로 보정하여 위치를 추정하였다. 그러나, 랜드마크 2, 5 부근에서 실내 보행자가 실제로 이동할 수 없는 위치로 추정한 결과들이 존재하고, 이는 실험 결과 RMSE를 크게 떨어뜨리는 주요한 원인으로 짚을 수 있다.

이와 같은 문제점은 실내 맵 정보에 맞게 보행자가 실제 이동할 수 없는 곳으로 위치를 추정할 시, 가장 가까운 이동 가능한 곳으로 위치를 보정하는 알고리즘을 사용하여 보정할 수 있다.

이에, 향후 연구에서는 해당 문제점을 해결하기 위한 알고리즘을 개발하여,

본 연구의 오차를 크게 낮추기 위한 연구를 진행할 예정이다.

참 고 문 헌

- 1) Proposes new indoor requirements and revisions to existing E911 rules
- 2) 연구개발특구진흥재단(2021). 글로벌 시장 동향 보고서, 실내 위치 정보
- 3) Lu, C., Uchiyama, H., Thomas, D., Shimada, A., & Taniguchi, R. 2019, Indoor Positioning System Based on Chest-Mounted IMU, Sensors, 19, 420.
- 4) Jin, G. Y., Lu, X. Y., & Park, M. S. 2006, An indoor localization mechanism using active RFID tag. International Conference on Sensor Networks, Ubiquitous, and Trustworthy Computing (SUTC'06), IEEE, 05-07 June 2006, Taichung, Taiwan.
<https://doi.org/10.1109/SUTC.2006.1636157>
- 5) Dabove, P., Di Pietra, V., Piras, M., Jabbar A. A., & Kazim, S. A. 2018, Indoor positioning using Ultra-wide band (UWB) technologies: Positioning accuracies and sensors' performances, IEEE/ION Position, Location and Navigation Symposium (PLANS), 23-26 April 2018, Monterey, CA, USA, pp.175-184.
<https://doi.org/10.1109/PLANS.2018.8373379>
- 6) Zhuang, Y., Yang, J., Li, Y., Qi, L., & El-Sheimy, N. 2016, Smartphone-based indoor localization with bluetooth low energy beacons, Sensors, 16, 596. <https://doi.org/10.3390/s16050596>
- 7) Hansen, R., Wind, R., Jensen, C. S., & Thomsen, B. 2010, Algorithmic strategies for adapting to environmental changes in

- 802.11 location fingerprinting, in Proc. IEEE Indoor Positioning and Indoor Navigation (IPIN), 15-17 September 2010, Zurich, Switzerland, pp.1-10. <https://doi.org/10.1109/IPIN.2010.5648270>
- 8) Leu, J.-S. & Tzeng, H.-J. 2012, Received signal strength fingerprint and footprint assisted indoor positioning based on ambient Wi-Fi signals, in Proc. IEEE Veh. Technol. Conf. (VTC Spring), 06-09 May 2012, Yokohama, Japan, pp.1-5. <https://doi.org/10.1109/VETECS.2012.6239883>
- 9) So, J., Lee, J. Y., Yoon, C. H., & Park, H. 2013, An improved location estimation method for wifi fingerprint-based indoor localization, International Journal of Software Engineering, and Its Applications, 7, 77-86. <https://www.earticle.net/Article/A208533>
- 10) Mendoza-Silva, G. M., Costa, A. C., Torres-Sospedra, J., Painho, M., & Huerta, J. 2022, Environment-aware regression for indoor localization based on WiFi fingerprinting, IEEE Sensors Journal, 22, 4978-4988. <https://doi.org/10.1109/JSEN.2021.3073878>
- 11) Kaemarungsi, K. 2005, Efficient design of indoor positioning systems based on location fingerprinting, IEEE, In 2005 International Conference on Wireless Networks, Communications and Mobile Computing, 13-16 June 2005, Maui, HI, USA, pp.181-186. <https://doi.org/10.1109/WIRLES.2005.1549406>
- 12) Mainetti, L., Patrono, L., & Sergi, I. 2014, A survey on indoor positioning systems, IEEE, 22nd international conference on software, telecommunications and computer networks (SoftCOM), 17-19 September 2014, Split, Croatia, pp.111-120.

<https://doi.org/10.1109/SOFTCOM.2014.7039067>

- 13) 실내 위치 기반 서비스 기술개발 및 표준화 동향(2014), 유재준, 조영수, 전자통신동향분석, pp.51 - 61
- 14) 실내 위치기반서비스 이슈 및 표준화(2015), 유재준, 박상준, 정보와 통신: 한국통신학회지, pp.74 - 80
- 15) Ashraf, I.; Hur, S.; Park, Y. Smartphone Sensor Based Indoor Positioning: Current Status, Opportunities, and Future Challenges. Electronics 2020, 9, 891. <https://doi.org/10.3390/electronics9060891>
- 16) Ruizhi, Chen, and C. H. E. N. Liang. "Indoor Positioning with Smartphones: The State-of-the-art and the Challenges." Acta Geodaetica et Cartographica Sinica 46.10 (2017): 1316.
- 17) Nguyen, Khuong An, et al. "A review of smartphones-based indoor positioning: Challenges and applications." IET Cyber-Systems and Robotics 3.1 (2021): 1-30.
- 18) Keller, J. M., Gray, M. R., & Givens, J. A. 1985, A fuzzy k-nearest neighbor algorithm, IEEE transactions on systems, man, and cybernetics, SMC-15, 580-585. <https://doi.org/10.1109/TSMC.1985.6313426>
- 19) Mika, S., Ratsch, G., Weston, J., Scholkopf, B., Mullers, K. R. 1999, Fisher discriminant analysis with kernels, Neural networks for signal processing IX: Proceedings of the 1999 IEEE Signal Processing Society Workshop (Cat. No.98TH8468), 25 August 1999, Madison, WI, USA. <https://doi.org/10.1109/NNSP.1999.788121>
- 20) Parlett, B. N. 1998, The symmetric eigenvalue problem (Philadelphia: Society for industrial and Applied Mathematics).

<https://doi.org/10.1137/1.9781611971163>

- 21) OxIOD: The Dataset for Deep Inertial Odometry (2018), Changhao Chen, Peijun Zhao, Chris Xiaoxuan Lu, Wei Wang, Andrew Markham, Niki Trigoni, <https://arxiv.org/abs/1809.07491>
- 22) RoNIN: Robust Neural Inertial Navigation in the Wild: Benchmark, Evaluations, and New Methods (2019), Hang Yan, Sachini Herath, Yasutaka Furukawa, <https://arxiv.org/abs/1905.12853>
- 23) Shang, Shuang, and Lixing Wang. "Overview of WiFi fingerprinting-based indoor positioning." IET Communications 16.7 (2022): 725-733.
- 24) Yoo, Jaehyun. "Multiple Fingerprinting Localization by an Artificial Neural Network." Sensors 22.19 (2022): 7505.

ABSTRACT

Indoor location estimation using IMU walking data based on machine learning and Wi-Fi Fingerprinting



Donggyu Lee
Department of Future Convergence
Technology Engineering
Graduate School of
Sungshin University

Due to the COVID-19 pandemic, the need for home health care is increasing, and the smart health care market is developing further. So many The location estimation model using Wi-Fi Fingerprinting proposed in this paper solved many collection costs of existing Wi-Fi Fingerprinting estimation methods using indoor random landmarks, dynamic data collection, and automatic labeling technology, and experiments showed that it is a more efficient and suitable model for convergence with other sensor data. Furthermore, experiments demonstrated that the location estimation accuracy is improved in convergence estimation between IMU sensor data obtained through actual walking and th Wi-Fi model that proposes the IMU model built through ground truth labels using RTK GPS.