

실내 위치 추정 시스템을 위한 앙상블 기법의 성능 분석

임정준*, 조정호**

Performance Analysis of Ensemble Methods for Indoor Positioning System

Jung-Jun Leem*, Chung-Ho Cho**

요약

실내 위치 추정 시스템은 자율 주행 로봇과 같은 다양한 실내 위치 기반 서비스에 적용 가능한 핵심 기술이다. 실내 환경에서 Wi-Fi 신호의 다중 경로 및 전파 간섭 현상과, IMU 센서 데이터의 잡음과 누적 오차로 인해 위치 추정 정확도를 저하시킨다. 본 연구에서는 실내 환경에서 수집된 Wi-Fi 및 IMU 센서 데이터를 대상으로 주성분분석(PCA) 적용 방식에 따른 성능 변화를 비교하였으며, 단일 모델과 앙상블 모델, 가중치 조합에 따른 성능비를 순차적으로 비교하였다. 최종적으로 단일 모델 성능은 RF(86%), XGB(87%), SVM(71%), KNN(80%)으로 1차 성능 평가를 토대로 앙상블 모델이 0.88로 향상된 위치 추정 정확도를 확인하였다. 이를 통해 Weighted Soft Voting 방법이 실내 내비게이션을 포함한 다양한 실내 위치 기반 서비스에 효과적으로 적용 가능할 것으로 기대된다.

Abstract

Indoor positioning systems are essential technologies for enabling various indoor location-based services, including autonomous robots and indoor navigation. However, indoor environments present several challenges, such as multipath propagation and radio-wave interference in Wi-Fi signals, as well as noise and cumulative errors in IMU sensor data, which degrade location estimation accuracy. This study analyzes performance variations according to different PCA application methods using Wi-Fi and IMU sensor data collected in an indoor environment. In addition, the performance of single models, ensemble models, and weighted model combinations was sequentially evaluated. The single models achieved accuracies of 86% for RF, 87% for XGB, 71% for SVM, and 80% for KNN. Based on the initial performance evaluation, the ensemble model improved the location estimation accuracy to 88%. These results indicate that the Weighted Soft Voting method can be effectively applied to various indoor location-based services, including indoor navigation.

Keywords

indoor localization, Wi-Fi fingerprinting, IMU sensor fusion, sensor data preprocessing, machine learning

* 광주대학교 광·정보통신공학과 박사과정

- ORCID: <https://orcid.org/0009-0006-3035-1970>

** 광주대학교 광·정보통신공학과 교수(교신저자)

- ORCID: <https://orcid.org/0009-0008-1529-4335>

• Received: Apr. 08, 2026 Revised: May 14, 2026 Accepted: May 17, 2026

• Corresponding Author: Chung-Ho Cho

Dept. of Optical and Information Communication Engineering, Gwangju University, Korea

Tel.: 82-31-724-4467, Email: thinkq3007@gmail.com

I. 서 론

실내 위치 추정 기술은 실내 내비게이션, 위치 기반 서비스 등 보행자 내비게이션이나 이동 경로 추적과 같은 응용 분야에서 효과적으로 활용된다.

기존의 Wi-Fi RSSI 단일 신호 기반 Fingerprinting 방식에서 벗어나 BLE, UWB, IMU, Wi-Fi CSI 등 다양한 센서와 무선 신호를 결합하는 방향으로 확장되고 있다[1]-[3]. Wi-Fi RSSI와 BLE는 기존 인프라 및 저전력 비콘을 활용할 수 있다는 장점이 있으나, 다중경로 현상과 장애물에 따른 신호 변동성으로 인해 위치 추정 정확도가 저하될 수 있다[1][3]. UWB는 시간 기반 ranging을 통해 높은 위치 정확도를 제공할 수 있지만, NLoS 환경에서는 거리 오차가 증가하는 한계가 있다[1]. 또한 IMU 기반 PDR은 사용자의 연속적인 이동 정보를 제공하여 경로 추적에 유리하지만, 시간 경과에 따라 누적 오차가 발생한다[2]-[4]. 최근에는 이러한 단일 기술의 한계를 극복하기 위해 센서 융합 및 머신러닝 기반 앙상블 학습을 활용하여 센서별 불확실성을 완화하고, 복잡한 실내 환경에서 위치 추정의 정확도와 연속성을 향상시키는 연구가 진행되고 있다[1].

이에 본 연구에서는 Wi-Fi와 IMU 센서 데이터를 융합한 실내 위치 추정 시스템을 설계하고, 단일 모델과 앙상블 모델을 다음과 같이 비교 실험을 수행하였다.

- 실내 환경에서 수집한 Wi-Fi RSSI, RTT, Packet Loss, Tx/Rx Rate와 IMU 3축 가속도 및 자이로스코프 데이터를 결합하여 실내 위치 추정을 위한 다차원 센서 융합 특징 등을 구성하였다.
- 서로 다른 단위와 범위를 갖는 Wi-Fi 및 IMU 센서 데이터에 대해 정규화 기반 전처리를 수행하고, PCA 적용 범위를 전체 특징, Wi-Fi+IMU 그룹, Wi-Fi, IMU 단독으로 구분하여 차원 축소 방식에 따른 성능 변화를 비교하였다.
- Random Forest, XGBoost, SVM, KNN 등 단일 모델의 위치 분류 성능을 비교하고, 성능 및 안정성을 고려하여 앙상블 모델을 구성하였다.
- 가중치 조합에 따른 성능 변화를 분석하여 최적의 앙상블 성능 비교 실험을 하였다.

- 반복 실험 및 신뢰구간 분석, 특징 중요도 분석, Confusion Matrix 분석을 통해 제안 모델의 성능 안정성, 핵심 특징 등을 함께 분석하였다.

본 논문의 구성은 다음과 같다. 2장에서는 관련 연구를 검토하고, 3장에서는 Wi-Fi-IMU 기반 실내 위치 추정 시스템과 데이터셋 구성을 설명한다. 4장에서는 PCA 적용 방식, 단일 모델, 앙상블 모델의 성능을 비교·분석한다. 마지막으로 5장에서는 결론 및 향후 연구 방향을 제시한다.

II. 관련 연구

2.1 Wi-Fi/IMU 기반 실내 위치 추정

Wi-Fi 기반 위치 추정은 기존 인프라를 활용할 수 있다는 장점이 있지만, 신호 반사, 감쇠, 간섭 등으로 인해 측정값이 불안정해질 수 있다[1][3]. 이를 보완하기 위해 Wi-Fi와 IMU 센서를 결합한 융합 기반 실내 위치 추정 연구가 진행되고 있다[2][4]-[6]. Wi-Fi는 위치별 절대적인 신호 패턴 정보를 제공하고, IMU는 가속도 및 각속도 정보를 통해 사용자의 이동 특성을 반영할 수 있으므로 두 센서를 함께 사용할 경우 단일 센서 기반 방식보다 향상된 위치 추정 성능을 기대할 수 있다[1][4][5]. 그러나 Wi-Fi RSSI는 dBm 단위로 측정되고 IMU 데이터는 가속도, 각속도 등 서로 다른 단위와 범위를 가지므로, 센서 융합 과정에서 데이터 스케일 차이가 발생한다. 따라서 정규화 및 표준화와 같은 전처리 과정은 Wi-Fi 및 IMU 기반 위치 추정에서 필수적으로 요구된다[7][8].

2.2 단일 모델 기반 실내 위치 추정

Wi-Fi 신호 패턴과 현재 측정된 신호를 비교하여 사용자의 위치를 추정하기 위하여 초기에는 KNN, SVM과 같은 전통적인 머신러닝 기법이 활용되었으며, 이후 Random Forest, XGBoost 등 다양한 학습 기법이 적용되고 있다[7]-[9]. KNN은 구현이 간단하지만 신호 잡음과 환경 변화에 민감하며, Random Forest는 다수의 결정 트리를 기반으로 안정적인 분류 성능을 제공하고, XGBoost는 부스팅 기반 학습

을 통해 복잡한 비선형 패턴을 효과적으로 학습할 수 있다[7]-[9]. 그러나 단일 모델 기반 방식은 실내 구조 변화, 장애물, 사람의 이동, Wi-Fi 신호 간섭 등에 의해 일반화 성능이 저하될 수 있으므로, 여러 모델의 예측 결과를 결합하여 안정성을 높이는 방법이 필요하다[7]-[9].

2.3 앙상블 기반 실내 위치 추정

앙상블 학습은 여러 개별 모델의 예측 결과를 결합하여 단일 모델의 한계를 보완하고 예측 성능과 안정성을 향상시키는 방법이다. 대표적으로 Hard Voting, Soft Voting, Weighted Soft Voting이 있으며, 각각 다수결, 예측 확률 평균, 모델별 가중치 반영 방식으로 최종 클래스를 결정한다[7]-[9]. 그러나 기존 연구는 주로 단일 모델이나 센서 융합 효과에 초점을 두었으며, 동일한 Wi-Fi, IMU 융합 데이터셋에서 다양한 Voting 방식을 비교한 연구는 부족하다. 이에 본 논문에서는 단일 모델과 앙상블 모델을 동일 조건에서 비교하고, Weighted Soft Voting의 위치 추정 성능과 안정성을 확인하고자 한다.

III. Wi-Fi·IMU 기반 실내 위치 추정 시스템

3.1 전체 시스템 구조

Wi-Fi 및 IMU 센서를 활용한 실내 위치 추정 시스템은 모바일 단말에서 IMU 센서 데이터와 Wi-Fi 신호 데이터를 엣지 노드에서 수집하여 처리하는 구조로 설계하였다[4]-[6][10]-[12].

그림 1은 실시간 데이터 수집, 데이터 전처리 및 특징 벡터 구성, 단일 분류 모델 학습, 앙상블 기반 모델 학습, 성능 평가 모듈로 구성된다.

본 시스템의 처리 흐름은 입력, 전처리, 특징 구성, 모델 학습 및 예측, 출력 단계로 구분된다. 입력 단계에서는 Wi-Fi 기반 특징과 IMU 기반 특징을 수집하고, 전처리 단계에서는 학습에 불필요한 메타 데이터를 제거한 후 센서 데이터의 단위 및 범위 차이를 보정하기 위해 정규화 및 표준화를 수행한다. 특징 구성 단계에서는 정규화된 Wi-Fi 및 IMU 데이터를 결합하여 11차원 센서 융합 특징 벡터를 생성한다. 모델 단계에서는 단일 분류 모델과 앙상블 모델을 학습하고, 예측 단계에서는 입력 샘플에 대해 학습된 모델을 이용하여 위치 클래스를 추정한다. 마지막으로 출력 단계에서는 입력 샘플에 대해 L1~L13 중 하나의 실내 위치 클래스를 최종 예측 결과로 출력한다.




그림 1. 실내 위치 추정 시스템 구조

Fig. 1. Architecture of the indoor positioning system

3.2 센서 데이터 수집 및 데이터셋 구성

그림 2는 본 연구에서 사용한 실내 데이터 수집 환경을 나타낸다. 실험 공간은 5 m × 5 m 크기로 구성하였으며, 1 m × 1 m 범위를 기준으로 총 13 개의 위치 클래스(L1~L13)를 설정하고, 각 위치 클래스에서 클래스별 샘플 수는 각 1,578개로 균등하게 분포하도록 구성하였다. 이 중 L1~L10은 개방된 공간에 배치하였으며, L11~L13은 내부 벽으로 구획된 공간에 배치하여 장애물에 따른 Wi-Fi 신호 감쇠 및 다중경로 특성이 반영되도록 하였다. 데이터 수집에는 iOS 기반 스마트폰을 사용하였으며, 각 위치 클래스에서 Wi-Fi 및 IMU 센서 데이터를 반복적으로 수집하였다[13]~[15].




그림 2. 실내 데이터 수집 환경
Fig. 2. Indoor data collection environment

표 1은 실험에서 사용된 데이터셋의 구성을 나타낸다. 총 20,515개의 샘플로 구성되며, 학습 및 테스트 데이터 분할 시 클래스별 데이터 비율이 유지되도록 층화 무작위 분할(Stratified random split) 방식을 사용하여 특정 위치 클래스가 학습 및 테스트 데이터에 편중되는 문제를 완화하고자 사용하였다.

표 1. 센서 데이터셋
Table 1. Sensor dataset

Category	Description
Total sample	20,515
Training samples	16,412
Test samples	4,103
Number of features	11
IMU feature	Accelerometer, Gyroscope
Wi-Fi feature	RSSI, RTT, Packet Loss, Tx Rate, Rx Rate
Target label	Indoor location class

최종 모델에 사용된 입력 특징은 총 11개로 Wi-Fi 기반 특징 5개와 IMU 기반 특징 6개로 구성된다. Wi-Fi 기반 특징은 RSSI, RTT, Packet Loss, Tx Rate, Rx Rate이며, IMU 기반 특징은 3축 가속도 데이터인 Acc_X, Acc_Y, Acc_Z와 3축 자이로스코프 데이터인 Gyro_X, Gyro_Y, Gyro_Z이다[16].

IV. 성능 평가

4.1 실험 환경 및 평가지표

본 연구에서는 Wi-Fi 및 IMU 센서 융합 데이터를 기반으로 실내 위치 클래스를 분류하는 실험을 수행하였다. 성능 평가는 동일한 학습 및 테스트 데이터 분할 조건에서 수행하였으며, PCA 적용 방식에 따른 성능 변화, 단일 모델의 위치 분류 성능, Random Forest와 XGBoost를 결합한 앙상블 모델의 성능, Weighted Soft Voting 가중치 조합에 따른 성능 변화를 순차적으로 비교하였다. 모델의 성능은 분류 정확도(Accuracy)를 기준으로 평가하였다.

4.2 PCA 적용 방식에 따른 성능 비교

PCA 적용 방식에 따른 입력 특징은 Wi-Fi 기반 5개(RSSI, RTT, Packet Loss, Tx Rate, Rx Rate)와 IMU 기반 6개(Acc_X, Acc_Y, Acc_Z, Gyro_X, Gyro_Y, Gyro_Z)로 구성된다. 비교 대상은 원본 특징을 사용한 ORIG, 전체 특징에 PCA를 적용한 FULL, Wi-Fi와 IMU를 그룹별로 PCA 적용한 W+I, Wi-Fi 특징에만 적용한 Wi-Fi, IMU 특징에만 적용한 IMU 방식이다. 이를 통해 차원 축소 방식에 따른 정확도를 분석하였다.

그림 3은 각 PCA 적용 방식별 PC 수 변화에 따른 분류 정확도를 나타낸다. ORIG 방식은 PCA를 적용하지 않은 기준 성능으로 0.8696의 정확도를 보였다. FULL 방식은 PC 수가 증가할수록 성능이 향상되었으나, PC 11에서도 0.8450으로 ORIG보다 낮았다. W+I 방식은 Wi-Fi와 IMU 특징을 각각 PCA 적용 후 결합한 방식으로, PC 5에서 0.8413, PC 10에서 0.8557, PC 11에서 0.8589의 정확도를 나타냈다.




그림 3. PCA 적용 방식별 성능 비교

Fig. 3. Performance comparison by PCA method

대부분의 구간에서 FULL 방식보다 높은 성능을 보여, 센서별 특징 구조를 유지한 차원 축소가 더 효과적임을 확인하였다. Wi-Fi 방식은 PC 2에서 0.8781로 가장 높은 정확도를 보였으며, 이후에도 약 0.875 수준의 안정적인 성능을 유지하였다. 이는 Wi-Fi 특징의 중복 정보와 잡음이 PCA를 통해 완화되었기 때문으로 판단된다. IMU 방식은 PC 1에서 0.5264로 낮았으나, PC 수가 증가함에 따라 성능이 향상되었고 PC 5 이후 약 0.8508 수준으로 수렴하였다. 이는 IMU 특징이 위치 분류에 활용되기 위해 일정 수 이상의 주성분이 필요함을 의미한다. 전체적으로 5차원 이상에서는 성능이 일정 수준으로 수렴하였으며, 추가적인 차원 증가에 따른 정확도 향상은 크지 않았다. 따라서 본 논문에서는 Wi-Fi PCA 적용이 가장 높았지만, 융합 기반 모델로 원본 특징 11개 정보를 유지한 상태에서 모델을 적용하여 성능 개선을 수행하였다.

4.3 단일 모델 성능 비교

Wi-Fi 및 IMU 센서 융합 데이터를 기반으로 단일 머신러닝 모델의 위치 분류 성능을 비교하였다. 비교 대상 모델은 SVM, KNN, Random Forest, XGBoost로 구성하였다. 단일 모델 성능 비교는 앙상블 모델을 적용하기 전 기준 성능을 확인하여, 앙상블 구성에 적합한 모델을 선정하기 위한 과정이다.

표 2의 단일 모델 성능 비교에서 SVM은 71%, KNN은 80%, Random Forest는 86% 정확도를 보였으며, Random Forest는 다수의 결정 트리를 기반으로 학습하기 때문에 센서 데이터에 포함된 잡음에

대해 비교적 안정적인 분류 성능을 제공한다. XGBoost는 87%의 정확도로 단일 모델 중 가장 높은 성능을 나타냈으며, Boosting 기반 학습을 통해 복잡한 비선형 관계를 효과적으로 학습하는 특성을 보였다. 본 논문에서는 안정적인 분류 특성을 가진 Random Forest, XGBoost 두 모델을 기반으로 앙상블 모델을 구성하였다.

표 2. 단일 모델 성능 비교

Table 2. Performance comparison of single models

Model	Accuracy(%)
Random Forest	86.96
XGBoost	87.89
SVM	71.39
KNN	80.97

4.4 앙상블 모델 성능 비교

Random Forest와 XGBoost를 결합한 앙상블 모델의 성능을 비교하고, Weighted Soft Voting 가중치 조합에 따른 위치 분류 성능 변화를 분석한다. 또한 특징 중요도 분석을 통해 위치 분류에 영향을 미친 주요 특징을 확인하고, Confusion Matrix를 이용하여 클래스별 분류 결과와 오분류 특성을 분석한다.

표 3은 앙상블 기법에 따른 분류 성능을 비교한 결과를 나타낸다. Hard Voting 방식의 경우 86.55%로 단일 모델보다 다소 낮은 성능을 보였으며, Soft Voting 방식에서는 87.01% 정확도를 나타냈다.

표 3. 앙상블 기법에 따른 모델 성능 비교

Table 3. Performance comparison of ensemble methods

Model	Accuracy(%)
Hard voting	86.55
Soft voting(1:1)	87.01

Hard Voting은 각 모델의 최종 예측 클래스만을 이용하여 최종 위치 클래스를 결정하므로, 모델이 출력하는 클래스별 예측 확률 정보를 반영하지 못한다. 반면 Soft Voting은 클래스별 예측 확률을 평균하여 Hard Voting보다 세밀한 의사결정이 가능하지만, 모든 모델의 기여도를 동일하게 가정한 한계가 있다. 본 연구의 단일 모델 성능 비교 결과, Random Forest는 센서 데이터의 잡음에 대해 비교적 안정적인 분류 성능을 보였으며, XGBoost는 복잡한 비선형 관계를 효과적으로 학습하여 단일 모델 중 가장 높은 정확도를 나타냈다. 따라서 두 모델의 예측 결과를 동일한 비중으로 결합하기보다는, 모델별 성능 차이를 반영하여 예측 확률에 가중치를 부여하는 Weighted Soft Voting 방식을 적용하였다. 이를 통해 모델 간 상호 보완적 특성을 유지하면서도, 검증 성능이 높은 모델의 예측 결과가 최종 위치 클래스 결정에 더 크게 반영되도록 하였다.

최종 앙상블 확률은 다음과 같이 계산된다.

$$P_{ens}(cvertx) = \frac{w_{RF}P_{RF}(cvertx) + w_{XGB}P_{XGB}(cvertx)}{w_{RF} + w_{XGB}} \quad (1)$$

식 (1)은 센서 데이터 입력 x 에 대해 Random Forest와 XGBoost의 예측 확률을 가중 결합하여 c 에 대한 최종 앙상블 예측 확률 $P_{ens}(cvertx)$ 를 계산하는 과정을 나타낸다. 여기서 $P_{RF}(cvertx)$ 와 $P_{XGB}(cvertx)$ 는 각각 Random Forest와 XGBoost가 클래스 c 에 대해 산출한 확률이며, w_{RF} , w_{XGB} 는 각각 Random Forest와 XGBoost에 부여된 가중치이다.

$$\hat{c} = \operatorname{argmax}_c P_{ensemble}(cvertx) \quad (2)$$

식 (2)는 최종 예측 클래스 $\hat{c}$ 가 결정되는 과정을 나타낸다. $P_{ensemble}$ 은 식 (1)에서 계산된 앙상블 모델의 최종 예측 확률을 의미하며, $P_{ensemble}(cvertx)$ 는 입력 x 가 주어졌을 때 클래스 c 에 대해 산출된 최종 앙상블 예측 확률을 나타낸다. 따라서 클래스별 앙상블 확률 중 가장 큰 값을 갖는 클래스를 최종 예측 클래스 $\hat{c}$ 로 선택한다.

그림 4는 Weighted Soft Voting에서 모델 조합 및 가중치 비율에 따른 분류 성능을 비교한 결과를 나타낸다. 각 가중치 조합에 대해 동일한 센서 데이터셋을 사용하여 검증 데이터에서 분류 정확도를 측정하였다. 또한 Random Forest와 XGBoost 모델을 결합한 앙상블 모델에서 Weighted Soft Voting(3:2)을 적용한 결과, 정확도는 88.03%로 추가적인 성능 향상이 확인되었다. 이는 모델 간 예측 확률을 가중 결합하는 방식이 단일 모델 대비 안정적이고 향상된 분류 성능을 제공함을 보여준다.

그림 5는 Weighted Soft Voting 앙상블 모델의 성능을 단일 실행 결과가 아닌 20회 이상의 반복 실험을 기반으로 검증하였으며, 각 반복마다 서로 다른 시드값을 적용하여 학습 및 평가 데이터를 재분할한 후 Random Forest와 XGBoost 모델을 재학습하였다. 결과 값은 평균 정확도를 중심 지표로 모델 성능의 안정성을 평가하였다. Weighted Soft Voting의 평균 정확도는 87.58%였으며, 신뢰구간은 86.70%~88.34%로 나타나 반복 분할에 따른 성능 변동을 고려하더라도 유사한 수준의 성능을 보였다.




그림 4. WSV 가중치 조합별 성능 비교
Fig. 4. WSV performance by weight combination




그림 5. 모델별 정확도 분포 비교
Fig. 5. Accuracy distribution by model

그림 6은 Wi-Fi 및 IMU 센서 융합 데이터에 대한 특징 중요도 분석 결과를 나타낸다. 분석 결과, Packet Loss, Rx Rate, Tx Rate는 본 실험 환경에서 위치 클래스 간 변동성이 충분히 나타나지 않아 특징 중요도 값이 매우 낮게 산출되었다. 이는 해당 특징들이 위치 분류에 기여하지 않았음을 의미하며, 본 실험에서는 RSSI와 IMU 자이로스코프 특징이 상대적으로 더 중요한 역할을 한 것으로 해석된다. Gyro_Z는 중요도가 약 0.24로 가장 높게 나타났으며, RSSI는 약 0.18로 두 번째로 높은 중요도를 보였다. 이는 IMU의 Z축 각속도 정보와 Wi-Fi 신호 세기가 실내 위치 클래스 구분에 중요한 영향을 미치는 핵심 특징임을 의미한다. Gyro_X와 Gyro_Y는 각각 약 0.13, 0.11 수준의 중요도를 보였으며, Acc_X, Acc_Y, Acc_Z와 같은 가속도 특징은 상대적으로 낮은 중요도를 나타냈다. Wi-Fi 신호 세기와 IMU 회전 정보를 함께 활용하는 센서 융합 방식이 실내 위치 추정 성능 향상에 효과적임을 확인할 수 있다.




그림 6. 특징 중요도 분석
Fig. 6. Feature importance analysis

4.5 Confusion matrix

그림 7은 4,103개의 테스트 데이터를 대상으로 제안한 앙상블 모델의 실내 위치 분류 결과를 Confusion Matrix로 나타낸 것이다. 대부분의 샘플이 대각선 방향에 집중되어 있어 모델이 전반적으로 위치 클래스를 안정적으로 분류하고 있음을 확인할 수 있으며, 전체 정확도는 88.03%, 오분류율은 11.97%로 나타났다. 일부 오분류는 클래스 3, 4, 6, 7, 9, 10에서 상대적으로 많이 발생하였으며, 이는 인접 Grid Cell 간 Wi-Fi 신호 세기와 IMU 센서 패턴이 유사하기 때문으로 판단된다.




그림 7. 실내 위치 분류 Confusion Matrix
Fig. 7. Indoor location classification confusion matrix

V. 결론 및 향후 과제

본 연구에서는 Wi-Fi와 IMU 센서를 융합한 실내 위치 추정 시스템을 설계하고, 단일 모델과 앙상블 모델의 성능을 정량적으로 비교하였다. 총 20,515개

샘플과 11개 입력 특징을 사용한 실험에서, Random Forest와 XGBoost는 각각 86.96%와 87.89%의 정확도를 보였으며, 가중 확률 결합을 적용한 Weighted Soft Voting(RF:XGB = 3:2)은 88.03%의 성능을 보였다. 또한 PCA 적용 방식에 따른 성능 비교를 하였으며, 5차원 이상부터는 성능이 일정하게 수렴되는 부분을 확인하였다. 특징 중요도 분석에서는 Gyro_Z와 RSSI가 핵심 변수로 나타났으며, Confusion Matrix에서는 주로 인접 위치 클래스 간 오분류가 발생함을 확인하였다.

실험 결과, Random Forest와 XGBoost 모델을 결합한 앙상블 모델에서 각 모델 간 예측 확률을 가중 결합하는 방식이 단일 모델보다 안정적이고 향상된 성능을 보임을 확인하였다.

향후 다양한 센서 데이터를 추가로 활용하고, 보다 정교한 앙상블 기법을 적용함으로써 실내 위치 추정 성능을 더욱 향상시킬 필요가 있으며, 실제 환경에서 발생하는 신호 변동, 센서 오차, 공간 구조의 차이 등을 고려한 추가 검증을 통해 시스템의 안정성과 신뢰성을 확보하는 실시간 위치 추정 시스템에 관한 연구가 필요할 것으로 판단된다.


References

- [1] S. G. Leitch, Q. Z. Ahmed, W. B. Abbas, M. Hafeez, P. I. Lazaridis, P. Sureephong, and T. Alade, "On Indoor Localization Using Wi-Fi, BLE, UWB, and IMU Technologies", *Sensors*, Vol. 23, No. 20, Art no. 8598, Oct. 2023. <https://doi.org/10.3390/s23208598>.
- [2] K. Mottakin, K. Davuluri, M. Allison, and Z. Song, "SWiLoc: Fusing Smartphone Sensors and Wi-Fi CSI for Accurate Indoor Localization", *Sensors*, Vol. 24, No. 19, Art no. 6327, Sep. 2024. <https://doi.org/10.3390/s24196327>.
- [3] R. S. Naser, M. C. Lam, F. Qamar, and B. B. Zaidan, "Smartphone-Based Indoor Localization Systems: A Systematic Literature Review", *Electronics*, Vol. 12, No. 8, Art no. 1814, Apr. 2023. <https://doi.org/10.3390/electronics12081814>.
- [4] A. Poulouse, J. Kim, and D. S. Han, "A Sensor Fusion Framework for Indoor Localization Using Smartphone Sensors and Wi-Fi RSSI Measurements", *Applied Sciences*, Vol. 9, No. 20, Art no. 4379, Oct. 2019. <https://doi.org/10.3390/app9204379>.
- [5] J. Chen, S. Song, and Z. Liu, "A PDR/Wi-Fi Indoor Navigation Algorithm Using the Federated Particle Filter", *Electronics*, Vol. 11, No. 20, Art no. 3387, Oct. 2022. <https://doi.org/10.3390/electronics11203387>.
- [6] Z. Li, C. Liu, J. Gao, and X. Li, "An Improved Wi-Fi/PDR Integrated System Using an Adaptive and Robust Filter for Indoor Localization", *ISPRS International Journal of Geo-Information*, Vol. 5, No. 12, Art no. 224, Nov. 2016. <https://doi.org/10.3390/ijgi5120224>.
- [7] H. E. Gorjan and V. P. G. Jiménez, "Improving Indoor Wi-Fi Localization by Using Machine Learning Techniques", *Sensors*, Vol. 24, No.19, Art no. 6293, Sep. 2024. <https://doi.org/10.3390/s24196293>.
- [8] N. Singh, S. Choe, R. Punmiya, and N. Kaur, "XGBLoc: XGBoost-Based Indoor Localization in Multi-Building Multi-Floor Environments", *Sensors*, Vol. 22, No. 17, Art no. 6629, Sep. 2022. <https://doi.org/10.3390/s22176629>.
- [9] T. Kosaka, S. Wandale, and K. Ichige, "RSSI-Based Indoor Localization Using Two-Step XGBoost", *IEICE Communications Express*, Vol. 12, No. 12, pp. 647-650, Dec. 2023. <https://doi.org/10.23919/comex.2023XBL0123>.
- [10] Z. Chen, H. Zou, H. Jiang, Q. Zhu, Y. C. Soh, and L. Xie, "Fusion of Wi-Fi, Smartphone Sensors and Landmarks Using the Kalman Filter for Indoor Localization", *Sensors*, Vol. 15, No. 1, pp. 715-732, Jan. 2015. <https://doi.org/10.3390/s150100715>.
- [11] H. Mehrabian and R. Ravanmehr, "Sensor Fusion for Indoor Positioning System through Improved RSSI and PDR Methods", *Future Generation Computer Systems*, Vol. 138, pp. 254-269, Jan.

2023. <https://doi.org/10.1016/j.future.2022.09.003>.
- [12] M. Martínez-del-Horno, L. Orozco-Barbosa, and I. García-Varea, "A Smartphone-Based Multimodal Indoor Tracking System", *Information Fusion*, Vol. 76, pp. 36-45, Dec. 2021. <https://doi.org/10.1016/j.inffus.2021.05.001>.
- [13] G. Guo, R. Chen, F. Ye, Z. Liu, S. Xu, L. Huang, Z. Li, and L. Qian, "A Robust Integration Platform of Wi-Fi RTT, RSS Signal, and MEMS-IMU for Locating Commercial Smartphone Indoors", *IEEE Internet of Things Journal*, Vol. 9, No. 17, pp. 16322-16331, Sep. 2022. <https://doi.org/10.1109/JIOT.2022.3150958>.
- [14] G. Guo, R. Chen, X. Niu, K. Yan, S. Xu, and L. Chen, "Factor Graph Framework for Smartphone Indoor Localization: Integrating Data-Driven PDR and Wi-Fi RTT/RSS Ranging", *IEEE Sensors Journal*, Vol. 23, No. 11, pp. 12346-12354, Jun. 2023. <https://doi.org/10.1109/JSEN.2023.3267121>.
- [15] Y. Wu, R. Chen, W. Fu, W. Li, H. Zhou, and G. Guo, "Indoor Positioning Based on Tightly Coupling of PDR and One Single Wi-Fi FTM AP", *Geo-spatial Information Science*, Vol. 26, No. 3, pp. 480-495, Jul. 2023. <https://doi.org/10.1080/10095020.2022.2072776>.
- [16] M. Nurpeiissov, A. Kuzdeuov, A. Assylkhanov, Y. Khassanov, and H. A. Varol, "End-to-End Sequential Indoor Localization Using Smartphone Inertial Sensors and Wi-Fi", *2022 IEEE/SICE International Symposium on System Integration (SII)*, Narvik, Norway, pp. 566-571, Jan. 2022. <https://doi.org/10.1109/SII52469.2022.9708854>.

저자소개

임 정 준(Jung-Jun Leem)



1999년 2월 : 광주대학교
컴퓨터공학과(공학학사)
2000년 2월 : 광주대학교
정보통신공학과(공학석사)
2026년 3월 ~ 현재 : 광주대학교
광·정보통신학과 박사과정
관심분야 : 지능형 로봇,

자율시스템 제어

조 정 호(Chung-Ho Cho)



1984년 2월 : 전남대학교
계산통계학과(이학사)
1987년 2월 : 전남대학교
전산학과(석사)
1996년 8월 : 전남대학교
전산학과(박사)
1988년 2월 ~ 1997년 2월

한국전자통신연구원(ETRI) 이동통신연구단 선임연구원
2005년 7월 ~ 2006년 7월 : University of Arizona(UofA)
Research Scholar
1997년 3월 ~ 현재 : 광주대학교 AI소프트웨어학과 교수
관심분야 : 인공지능/빅데이터, 통신망 설계 및 제어,
소프트웨어 설계 및 검증