

기압 데이터를 활용한 층수 예측 알고리즘별 성능 비교 연구

김규석*, 정태양**

A Comparative Study on Indoor Floor Prediction Performance by Algorithm using Barometric Pressure Data

Kyuseok Kim*, Taeyang Jeong**

요 약

본 연구는 스마트폰에 내장된 기압 센서와 셀룰러 신호를 활용하여 실내 지하주차장의 층수를 예측하는 인공지능 모델을 비교 분석하였다. 서울시 22개 건물의 지하주차장에서 수집한 데이터를 기반으로 24종의 머신러닝 및 딥러닝 알고리즘을 동일한 조건에서 평가하였다. 실험 결과, Decision Tree, ExtraTrees, Random Forest 등 트리 기반 모델이 가장 우수한 예측 성능을 보였다. 특히 Decision Tree와 ExtraTrees는 높은 정확도와 안정적인 결과를 나타냈다. 또한 학습 시간과 예측 시간이 매우 짧아 실시간 서비스 환경에 적합한 것으로 확인되었다. 반면 딥러닝 모델은 상대적으로 긴 학습 시간이 요구되었으며 정확도 측면에서도 우위를 보이지 못하였다. 연구 결과는 별도의 측위 인프라 없이 스마트폰 센서만으로 효율적인 실내 층수 예측이 가능함을 시사한다. 향후에는 다양한 건물 환경과 계절적 요인을 반영한 추가 연구가 필요하다.

Abstract

This study compares artificial intelligence models for predicting underground parking floor levels using smartphone barometric pressure sensors and cellular signal strength. Data were collected from underground parking lots in 22 buildings located in Seoul, South Korea. A total of 24 machine learning and deep learning algorithms were evaluated under identical experimental conditions. The results showed that tree-based models, including Decision Tree, ExtraTrees, and Random Forest, achieved the best predictive performance. In particular, Decision Tree and ExtraTrees demonstrated both high accuracy and stable results across repeated experiments. These models also required extremely short training and inference times, making them suitable for real-time mobile applications. In contrast, deep learning models required significantly longer training times without providing superior prediction accuracy. The findings suggest that accurate indoor floor prediction can be achieved using only smartphone sensors without additional positioning infrastructure, while future research should consider broader building environments and seasonal variations.

Keywords

barometric pressure sensor, cellular signal strength, floor level prediction, tree-based ensemble model, real-time location-based service, LBS

* 한국폴리텍대학 인공지능소프트웨어과 부교수(교신저자)
- ORCID: <https://orcid.org/0000-0001-6613-5125>
** 만들다컴퍼니 대표이사
- ORCID: <https://orcid.org/0009-0004-6442-7836>

• Received: Apr. 13, 2026, Revised: Jun. 10, 2026, Accepted: Jun. 13, 2026
• Corresponding Author: Kyuseok Kim
Dept. of Artificial Intelligence Software, Korea Polytechnics,
Gyeonggi-do, Korea
Tel.: +82-31-696-8832, Email: kyuseokkim@kopo.ac.kr

1. 서 론

최근 스마트 시티 및 디지털 전환 환경의 확산과 함께 실내 위치 기반 서비스(Indoor LBS, Indoor Location-Based Service)의 중요성이 지속적으로 증가하고 있다[1][2]. 대형 쇼핑몰, 복합 환승센터, 스마트 빌딩, 지하 주차장과 같은 복층 구조의 실내 공간이 확대됨에 따라, 사용자의 정확한 위치를 파악하는 기술은 서비스 품질을 결정하는 핵심 요소로 자리 잡고 있다[3][4]. 특히 실내 환경에서는 사용자가 위치한 층수와 같은 수직 위치 정보가 중요한 의미를 가지며, 이는 주차 위치 탐색, 실내 내비게이션, 긴급 구조 등 다양한 응용 서비스에서 필수적으로 요구된다[5][6].

그러나 기존의 GPS(Global Positioning System) 기반 위치 측위 기술은 실내 환경에서 신호 감쇠 및 다중 경로 간섭 등의 문제로 인해 정확도가 크게 저하되는 한계를 가진다[7]. 이를 보완하기 위해 Wi-Fi, BLE(Bluetooth Low Energy), UWB(Ultra-Wideband) 등 다양한 인프라 기반 측위 기술이 제안되었으나, 별도의 장비 설치와 유지 관리 비용이 필요하여 확장성과 경제성 측면에서 제약이 존재함을 알 수 있다[2][3].

또한 실제 상용 서비스에서는 코엑스와 같은 대형 복합시설 및 유통시설을 중심으로 주차 위치를 파악하기 위한 다양한 센서 기반 시스템이 도입되고 있다[7]. 이러한 시스템은 주차장 내에 설치된 카메라, 차량 감지 센서, 비콘(BLE beacon) 등을 활용하여 차량의 위치를 자동으로 인식한다. 그리고 사용자가 모바일 애플리케이션을 통해 자신의 주차 위치를 확인할 수 있도록 지원한다. 특히 대규모 지하 주차장의 경우 차량 위치를 시각적으로 안내하거나, 빈 주차 공간을 탐색하는 기능까지 결합되어 사용자 편의성을 크게 향상시키고 있다.

그러나 이러한 센서 기반 주차 위치 인식 시스템은 시설 전반에 걸친 센서 및 네트워크 장비의 설치가 필수적이다. 그리고 초기 구축 비용뿐만 아니라 유지, 보수 비용이 지속적으로 발생한다는 단점이 있다. 따라서 모든 실내 공간에 보편적으로 적용하기에는 경제적 부담이 크다. 이러한 이유로 인프라 의존형 방식은 확장성과 범용성 측면에서 제약

이 존재한다고 할 수 있다.

본 저자들의 선행 연구에서는 딥러닝 기반의 층수 예측 모델을 개발하였다[8]. 그리고 스마트폰만 가지고 주차 층수를 예측하는 모바일 애플리케이션을 개발하였다[9]. 이 연구들에서는 Android 및 iOS 환경에서 동작하는 모바일 애플리케이션을 구현함으로써 실제 서비스 환경에서의 활용 가능성을 제시하였다. 또한 별도의 인프라 없이 기압 데이터만으로 층수 예측이 가능함을 확인하였다.

또한 실제 주차 환경에서는 건물마다 층고(층 높이)가 상이하고, 기압 변화 패턴 역시 환경 조건에 따라 달라지는 등 다양한 복합적인 변수가 존재한다. 특히 모바일 애플리케이션에 탑재되어 실제 사용자 환경에서 동작하는 경우, 센서 오차와 사용자 이동 패턴 등의 영향이 추가적으로 반영되면서 층수 예측 정확도는 약 90% 내외 수준에 이르는 것으로 나타난다. 따라서 보다 다양한 환경에서 안정적이고 일관된 예측 성능을 확보하기 위해서는 이러한 복합 변수를 고려한 모델링 접근과 함께 다양한 알고리즘 간 비교 분석이 필요하다.

본 연구의 목적은 저자들의 기존 연구에서 개발된 모바일 애플리케이션을 통해 수집된 기압 데이터를 활용하여, 실내 층수 예측의 정확도를 향상시키기 위한 모델 고도화 방안을 제시하는 데 있다. 특히 단일 딥러닝 모델의 한계를 보완하기 위해 다양한 머신러닝 및 앙상블 학습 기반 방법론을 적용하고, 각 모델의 예측 성능을 비교, 분석하는 데 목적이 있다.

이를 위해 본 연구에서는 동일한 데이터셋을 기반으로 여러 알고리즘을 적용하여 성능을 검증하고, 반복적인 학습 및 평가 과정을 통해 모델의 안정성과 일반화 성능을 동시에 확보하는 것을 목표로 한다. 또한 모델별 학습 시간과 예측 시간까지 함께 고려하여 실제 모바일 환경에서의 적용 가능성을 종합적으로 분석하고자 한다.

본 논문의 구성은 다음과 같다. 제2장에서는 실내 측위 기술과 기압 센서를 활용한 층수 예측 연구, 그리고 기압 센서를 활용한 층수 예측 연구 등의 이론적 배경을 고찰한다. 제3장에서는 본 연구에서 활용한 데이터의 수집 과정과 전처리 방법을 설명하고, 다양한 모델링 기법의 설계 및 실험 환경을

제시한다. 제4장에서는 각 모델의 예측 성능을 비교, 분석하고, 반복 실험을 통해 도출된 결과를 바탕으로 최적 모델을 선정한다. 마지막으로 제5장에서는 연구 결과를 종합하고 향후 연구 방향을 제시한다.

II. 문헌 고찰

2.1 실내 측위 기술 동향

Zafari et al.[3]은 실내 위치 기반 서비스의 중요성이 증가함에 따라 다양한 실내 측위 기술이 발전해 왔음을 제시하였다. 특히 스마트 시티 환경에서 실내 위치 정확도가 서비스 품질을 결정하는 핵심 요소로 작용한다고 설명하였다[3]. 이 연구는 실내 위치 추정 기술이 단순한 위치 확인을 넘어 다양한 응용 서비스의 기반 기술로 확장되고 있음을 강조하였다.

Basiri et al.[2]은 Wi-Fi, BLE, UWB 등 무선 신호 기반 실내 측위 기술이 널리 활용되고 있으나, 인프라 구축과 유지 비용이 발생하며 환경 변화에 따른 신호 왜곡 문제를 포함한다고 지적하였다. 특히 실내 환경의 복잡성으로 인해 신호 기반 위치 추정의 안정성과 확장성이 제한될 수 있음을 강조하였다.

Mostafa et al.[10]은 다층 구조를 포함한 실내 환경에서의 위치 추정 기술을 분석하며, 영상 기반 및 딥러닝 기반 접근이 높은 정확도를 제공할 수 있다고 하였다. 그러나 실제 적용에서는 조명 조건, 장애물, 개인정보 보호 문제 등으로 인해 한계가 존재한다고 보고하였다[10]. 이는 기술적 성능뿐 아니라 실제 적용 가능성을 고려한 접근의 필요성을 시사하는 것이다.

Liu et al.[4]은 가속도계, 자이로스코프 등 센서 기반 측위 기술이 인프라 의존도를 낮출 수 있는 대안으로 제시된다고 하였다. 다양한 센서 융합을 통해 위치 추정 성능을 향상시킬 수 있음을 설명하였다[4]. 이러한 흐름 속에서 기압 센서는 수직 위치(층수) 추정에 효과적인 센서로 주목받고 있다고 하였다.

2.2 기압 센서를 활용한 층수 예측 연구

기압 센서는 고도 변화에 따라 압력이 감소하는 물리적 특성을 기반으로 수직 위치를 추정할 수 있는 대표적인 센서이다. 그래서 실내 환경에서의 층수 탐지에 효과적으로 활용될 수 있다. 특히 기압과 고도 간의 관계를 이용하면 별도의 인프라 없이도 층 변화 여부를 판단할 수 있어, 실내 위치 추정 분야에서 중요한 대안 기술로 주목받고 있다.

Torres-Sospedra et al.[11]은 다층 구조 환경에서의 실내 위치 추정 문제를 분석하며, 수직 위치 정보의 중요성과 이를 위한 다양한 접근 방법의 필요성을 강조하였다. 스마트폰에 내장된 기압 센서를 활용한 연구에서는 사용자의 이동 과정에서 발생하는 기압 변화를 분석하여 층 이동을 감지하는 방법이 제안되었다. 이러한 접근은 별도의 장비 설치 없이 구현 가능하며, 사용자 행동 데이터와 결합할 경우 보다 정교한 위치 추정이 가능하다는 것을 의미한다.

Rai et al.[12]은 실내 위치 추정에서 센서 기반 접근이 추가적인 인프라 없이도 위치 정보를 효과적으로 추정할 수 있음을 보이며, 모바일 환경에서의 적용 가능성을 제시하였다. 한편, 기압 기반 층수 예측에서는 외부 기상 변화나 시간에 따른 기압 변동으로 인해 데이터의 불안정성이 발생할 수 있으며, 이를 보정하기 위한 다양한 방법이 연구되고 있다. 예를 들어 기준 기압과의 차이를 활용하거나 필터링 기법을 적용하여 노이즈를 제거함으로써 예측 정확도를 향상시키는 방식이 제안되고 있다.

Xu et al.[13]은 관성센서와 기압센서를 융합하여 실내 층수 추정의 정확성과 강건성을 향상시킬 수 있음을 제시하였다. 이는 단일 센서보다 다양한 센서 정보를 결합한 접근이 실내 위치 추정 성능 향상에 효과적임을 시사한다.

최근에는 기압 데이터를 단순 물리 모델이 아닌 머신러닝 및 딥러닝 기법을 통해 분석하는 연구가 확대되고 있다. 다양한 환경 변수와 사용자 이동 패턴을 함께 고려함으로써 보다 높은 정확도와 안정성을 확보할 수 있으며, 특히 여러 알고리즘 간 비교를 통해 최적 모델을 도출하는 접근이 중요하게 다뤄지고 있다.

He 와 Chan[14]은 실내 위치 추정에서 다양한 알고리즘 비교 및 성능 분석이 정확도 향상에 핵심적인 요소임을 강조하였다.

2.3 본 연구의 차별점

기존의 실내 층수 예측 연구는 주로 기압 센서를 활용한 딥러닝 기반 단일 모델을 중심으로 수행되어 왔다. 이러한 접근은 기압 변화 패턴을 효과적으로 학습하여 일정 수준 이상의 예측 성능을 확보할 수 있다는 장점이 있으나, 실제 환경에서 발생하는 다양한 변수들을 충분히 반영하지 못하는 한계를 가진다.

특히 건물별 층고 차이, 기압 변화의 불규칙성, 사용자 이동 특성뿐만 아니라 통신사 기지국 기반의 셀룰러 신호 세기와 같은 외부 신호 환경도 함께 영향을 미치는 등 복합적인 요인이 동시에 작용하는 실내 환경에서는 단일 모델만으로 안정적인 예측 성능을 유지하기 어렵다.

본 연구에서 제안하는 접근의 특징으로, 비콘·카메라와 같은 별도의 측위 인프라를 필요로 하지 않고 스마트폰에 내장된 기압 센서와 셀룰러 신호만을 이용하므로 시설 구축 및 유지·보수 비용이 발생하지 않는다. 또한 트리 기반 모델은 학습 시간이 1초 미만, 추론 시간이 0.04초 이내로 연산 부담이 작아 모바일 단말과 같은 경량 환경에서도 실시간 동작이 가능하며, 학습 비용이 낮아 건물별 환경 차이에 맞추어 모델을 수시로 재학습·갱신할 수 있다. 반면 단점으로, 절대 기압값은 건물의 층고·기준 기압·측정 환경에 따라 달라지므로 건물 간 편차에 민감하며, 셀룰러 신호 역시 기지국과의 거리 및 차폐의 영향을 받아 층수 자체보다 건물·위치 특성을 반영할 수 있다. 본 연구는 이러한 장단점을 고려하여 정확도와 함께 연산 효율 및 안정성을 종합적으로 평가한다.

이에 본 연구에서는 기존의 DNN(Deep Neural Network) 기반 접근을 확장하여 기압 데이터와 함께 셀룰러 신호 세기와 같은 추가적인 환경 정보를 결합하고, 다양한 머신러닝 및 딥러닝 모델을 동일한 데이터셋에 적용하여 반복적인 학습 및 검증을 수행함으로써 각 모델의 성능을 비교, 분석하는 것을 주요 차별성으로 제시한다. 또한 단순한 정확도 비교를 넘어 모델의 안정성과 일반화 성능, 그리고 학습 및 예측 시간까지 함께 고려함으로써 실제 모바일 환경에서 적용 가능한 최적의 층수 예측 모델을 도출하고자 한다.

III. 연구 방법

3.1 데이터 정의

본 연구에서는 실내 주차 환경에서의 층수 예측 모델을 구축하기 위해 스마트폰 기반의 기압 센서와 통신 신호인 셀룰러 신호 강도를 활용한다. 데이터는 실제 모바일 애플리케이션 환경에서 수집되었다. 전체 표본 수와 지하 층(BF)별 표본 분포를 표로 제시하였다. 셀룰러 신호 세기는 기지국과의 거리·차폐 등 건물·위치 특성의 영향을 받으므로, 층수에 대한 직접적 지표라기보다 보조적 환경 정보로 활용된다.

데이터는 저자들이 개발한 모바일 애플리케이션을 이용하여 차량으로 각 건물 지하주차장을 진입·하강하는 과정에서 수집되었으며, 수집 시기는 2025년 1~2월(동절기)에 집중되었다. 동절기 단기간 수집은 기상·기온에 따른 기압 변동이 상대적으로 제한적인 조건을 제공한다. 각 측정은 이동 상태와 정지 상태를 함께 기록하되, 본 연구의 층 판정에는 정지 상태의 측정값을 사용하였다.

기압 센서는 고도 변화에 따른 압력 변화를 반영하며, 셀룰러 신호는 건물 내부 및 지하 공간에서의 전파 감쇠 특성을 반영하는 중요한 변수로 활용된다. 단, 온도에 따른 지상과 지하의 기압 차는 매우 제한적으로 무시할 수 있다는 연구에 기반한다. 즉, 이를 전제조건으로 한다[15].

본 연구의 데이터는 서울시 금천구와 구로구의 가산디지털단지 일대 및 구로디지털단지 일대에 위치한 22개 건물의 지하주차장에서 수집되었다. 수집된 데이터는 지상 기준 정보와 지하 환경 정보로 구분되며, 각 샘플은 특정 위치에서 측정된 기압 및 통신 신호 정보를 포함한다.

본 연구에서 사용된 변수는 표 1과 같이 정의된다. 지상 기압(GP, Ground Pressure)과 지하 기압(BP, Basement Pressure)은 각각 기준 위치와 측정 위치에서의 기압 값을 의미하며, 두 값의 차이는 층수 변화에 따른 압력 변화를 나타낸다. 또한 지상 신호(GS, Ground Signal)와 지하 신호(BS, Basement Signal)는 셀룰러 신호 세기를 나타내며, 실내 및 지하 환경에서의 전파 감쇠 특성을 반영한다. 마지막

으로 지하 층수(BF, Basement Floor)는 예측 대상 변수로, 지상은 0, 지하 층은 음수 값으로 정의된다.

표 1. 변수의 정의

Table 1. Definition of variables

Variable name[Unit]	Description
GP[hPa] (Ground Pressure)	Atmospheric pressure measured at ground level
GS[dBm] (Ground Signal)	Signal strength measured at ground level
BP[hPa] (Basement Pressure)	Atmospheric pressure measured in basement
BS[dBm] (Basement Signal)	Signal strength measured in basement
BF[Integer] (Basement Floor)	Floor level of the basement

제안하는 모델의 실질적인 활용 가능성을 검토하기 위해, 본 연구에서는 Google Colab 환경을 기반으로 각 모델의 학습 시간(Training time)과 검증 시간(Inference/Validation time)을 측정하여 비교 분석하였다. 이는 단순히 예측 정확도(Accuracy)뿐만 아니라, 실제 서비스 적용 시 요구되는 연산 효율성을 고려하여 최적의 정확도와 최소의 학습 및 검증 시간을 보장하는 최적의 모델을 선정하기 위함이다.

본 연구는 전체 데이터를 무작위로 분할하였으므로 동일 건물의 데이터가 학습과 평가에 함께 포함될 수 있는 구조입니다. 따라서 현재 결과는 수집된 건물 집합 내에서의 성능으로 해석하는 것이 타당하며, 학습에 사용되지 않은 새로운 건물에 대한 일반화는 검증되지 않았습니다. 또한 본 방법은 건물별 환경 차이에 따라 모델을 갱신하는 것을 전제로 하므로, 범용 모델이라기보다 건물 환경에 적응하는 모델에 가깝습니다. 이 점을 본문에 명확히 하고 한계 및 향후 과제로 기술하였습니다.

3.2 학습 모델의 설계 및 다양화

본 연구에서는 아래의 식 (1)에 제시된 바와 같이 지상층과 지하층에서 측정된 기압 및 신호 세기의 조합을 최대한 다양하게 구성하고자 하였다. 이를 위해 지상층 데이터와 지하층 데이터를 상호 결합하는 방식으로 다양한 입력 패턴을 생성하였으며,

예를 들어 지상층의 신호가 세 가지이고 지하층의 신호가 다섯 가지일 경우, 두 집합의 조합을 통해 총 열다섯 가지의 데이터 패턴을 생성하도록 설계하였다. 이러한 조합 확장은 학습 데이터의 다양성을 확보하고 모델의 일반화 성능을 향상시키기 위한 목적을 가진다. 식 (1)의 조합은 한 건물에서 측정된 지상 기준값과 지하 측정값을 결합하여 입력 패턴을 구성하는 과정으로, 다양한 (지상, 지하) 쌍을 생성한다. 본 연구에서는 이 조합이 학습/평가 분할 이전에 수행되었으며, 그 결과 동일한 지하 측정값에서 파생된 유사 표본이 학습과 평가에 함께 포함될 수 있다. 이는 데이터셋 내 정확도를 다소 높게 평가할 수 있는 요인이므로, 본 결과는 수집된 데이터 범위 내의 성능으로 해석해야 한다.

본 실험의 반복은 전체 데이터셋을 층(BF) 기준으로 층화하여 8:2로 무작위 분할하는 과정을 10회 반복한 것이며, 각 반복에서 학습/평가 집합을 재구성하여 평균 성능과 표준편차를 산출하였다.

$$\chi = [(GP_i, GS_i, BP_j + BS_j, BF)|t_i = 0, t_j < 0] \quad (1)$$

$t_i = 0$: Ground floor

$t_j < 0$: Basement floor

BF: Corresponding basement floor

또한, 본 연구에서의 모형은 아래의 식 (2)와 같다. 종속변수는 지하 층수인 BF를 활용하며, 독립변수로는 지상층의 기압인 GP, 지상층의 신호 세기인 GS, 지하층의 기압인 BP, 지하층의 신호 세기인 BS를 활용한다.

$$BF = f(GP, GS, BP, BS) \quad (2)$$

표 2는 총 24개의 인공지능 모형과 그에 대한 설정값을 보여준다. 실내 층수 예측의 종합적인 비교 분석을 수행하기 위해 총 24종의 머신러닝 및 딥러닝 알고리즘을 구현하였다. 선정된 모델은 로지스틱 회귀(Logistic regression)와 릿지(Ridge) 등 선형 모델부터, KNN(k-Nearest Neighbors) 및 Nearest Centroid와 같은 거리 기반 모델, 그리고 가우시안 및 베르누이 나이브 베이즈(NB) 등의 확률 모델까지 폭넓은 범위를 포괄한다. 이처럼 다양한 알고리즘 스펙

트럼을 구축함으로써, 건물 환경에 따른 기압 데이터 특유의 미세한 변동성과 비선형적 패턴을 가장 강건하게 해석할 수 있는 최적의 예측 구조를 규명하고자 하였다.

높은 예측력을 지닌 것으로 알려진 트리 기반 및 앙상블 모델의 경우, 배깅(Bagging)과 부스팅(Boosting) 기법을 모두 활용하였다. 랜덤 포레스트(Random forest)와 엑스트라 트리(Extra trees) 같은 앙상블 구조는 분산 감소와 안정적인 성능 확보를 위해 200개의 결정 트리(Estimators)로 구성하였다. 또한, XGBoost, LightGBM, CatBoost와 같은 고성능 부스팅 프레임워크는 수직 변위 데이터 학습 시 발생할 수 있는 과적합을 방지하기 위해 최대 깊이(Depth)와 서브샘플링(Subsampling) 비율을 정밀하게 조정하여 학습 속도와 일반화 성능 간의 최적의 균형을 도출하였다.

커널 기반 및 통계적 모델의 구현에서는 수렴

안정성 확보에 중점을 두었다. 선형 및 RBF 커널을 사용하는 서포트 벡터 머신(SVM)을 도입하였으며, 특히 선형 변환 모델의 경우 완전한 최적화를 보장하기 위해 최대 반복 횟수(max_iter)를 5,000회로 설정하였다. 아울러 선형 판별 분석(LDA, Linear Discriminant Analysis)과 이차 판별 분석(QDA, Quadratic Discriminant Analysis)을 포함하여, 고도화된 연산 방법론 대비 고전적 통계 접근법의 효용성을 함께 평가하였다. 규제 매개변수인 λ 값과 분산 평활화(Variance smoothing) 계수 등 각 모델의 하이퍼파라미터는 실험의 일관성 유지를 위해 엄격히 제어되었다.

마지막으로, 데이터셋 내의 복잡하고 계층적인 특징을 추출하기 위해 신경망 기반 구조를 설계하였다. (128, 64)의 은닉층 구조를 가진 다층 퍼셉트론(MLP, Multilayer Perceptron)과 (128-64-32)의 병목 구조를 가진 심층 신경망(DNN)을 구현하였다.

표 2. 모형별 설정값

Table 2. Hyperparameter configurations by model type

Model	Algorithm type	Configuration
Logistic regression	Linear model	solver=lbfgs max_iter=3000
Ridge classifier		alpha=1.0
SGD classifier		loss=hinge max_iter=2000 tol=1e-3
Linear model		max_iter=2000 tol=1e-3
Passive aggressive		max_iter=2000 tol=1e-3
KNN	Instance-based learning	n_neighbors=5 metric=minkowski
Nearest centroid	Distance-based model	metric=euclidean
SVM(RBF)	Kernel-based model	kernel=rbf C=1.0 gamma=scale
SVM(Linear)	Perceptron	max_iter=5000 C=1.0
Decision tree	Tree-based model	criterion=gini
Random forest	Ensemble(Bagging)	n_estimators=200 n_jobs=-1
Extra trees		n_estimators=200 n_jobs=-1
Gradient boosting	Ensemble(Boosting)	n_estimators=100 learning_rate=0.1
AdaBoost		n_estimators=50 learning_rate=1.0
HistGradientBoosting		max_iter=100 learning_rate=0.1
Gaussian NB	Probabilistic model	var_smoothing=1e-9
Bernoulli NB		alpha=1.0 binarize=0.0
LDA	Statistical model	solver=svd
QDA		reg_param=0.0
MLP	Neural network	activation=relu max_iter=500 hidden_layer=(128,64)
XGBoost	Ensemble(Boosting)	n_estimators=200 max_depth=5 subsample=0.9 colsample_bytree=0.9
LightGBM		n_estimators=200 num_leaves=31
CatBoost		iterations=200 depth=6
DNN	Deep neural network	Dense(128-64-32) activation=ReLU optimizer=Adam epochs=100 batch_size=16

특히 DNN 모델은 ReLU 활성화 함수와 Adam 옵티마이저를 결합하였으며, 배치 사이즈 16으로 100회 (Epochs) 반복 학습을 수행하였다. 이러한 다각적인 접근은 기압 기반의 고도 추정 환경에서 딥러닝의 표현력과 전통적 머신러닝의 해석력 간의 성능 차이를 정밀하게 비교 분석할 수 있는 기반을 제공한다.

본 실험은 결과의 신뢰성과 통계적 유의성을 확보하기 위해 선정된 24종의 예측 모델을 Google Colab 환경에서 각각 10회씩 반복 수행한다. 이러한 반복 실험을 통해 환경적 요인에 따른 성능 변동성을 최소화하고 각 알고리즘의 평균적인 학습 및 예측 시간을 도출한다. 또한, 이를 기반으로 실제 서비스 환경에 최적화된 안정적이고 효율적인 층수 예측 모델을 최종 선정한다.

IV. 연구 결과

4.1 모델별 예측 정확도 비교 분석

표 3은 각 모델별 정확도의 기술통계를 보여준다. 24종의 알고리즘을 대상으로 실내 층수 예측 정확도를 분석한 결과, Decision Tree, ExtraTrees, RandomForest, HistGradientBoosting, LightGBM이 평균 정확도 0.88을 기록하며 성능상 상위 5개 모델 (Top 5)로 도출되었다. 이들 모델은 최솟값과 최댓값의 차이가 거의 없고 표준편차 또한 0.00으로 나타나, 반복 수행 시에도 극히 안정적인 예측 성능을 유지함을 확인하였다. 이는 기압 변화와 통신 신호 감쇠라는 비선형적 변수 특성을 학습하는 데 있어 트리 기반의 분할 방식이 상대적으로 효과적임을 입증한다.

상위권 모델들과 달리 딥러닝 계열인 MLP(0.67)와 DNN(0.65)은 중위권의 성능을 기록하였으며, SVM과 로지스틱 회귀 등 선형 및 확률 기반 모델들은 0.54 이하의 낮은 정확도를 보였다. 특히 앙상블 기법 중에서도 AdaBoost(0.73)는 상위 5개 모델에 비해 현저히 낮은 수치를 기록하여, 같은 트리 기반 모델이라 하더라도 알고리즘의 구성 방식에 따라 실내 환경 데이터에 대한 적합도가 크게 다를 수 있음을 확인하였다. 이는 정형 데이터 중심의 실내 층수 예측 환경에서는 단순 선형 결합이나 복잡한 신경

망보다 트리 기반 앙상블 기법의 효율성이 더 높다는 것을 시사한다.

모델의 강건성 측면에서는 상위 5개 모델이 일관된 성능을 보인 것과 대조적으로, PassiveAggressive (0.44)와 Perceptron(0.42)은 가장 낮은 성능과 함께 높은 표준편차를 기록하였다. 이들 모델은 실험 회차에 따라 최솟값과 최댓값의 편차가 커 실제 서비스에 적용하기에는 부적합한 것으로 판단된다. 결과적으로 높은 정확도와 낮은 편차를 동시에 달성한 상위 5개 모델이 실내 주차장 환경의 층수 예측을 위한 최적의 모형군임을 확인하였으며, 향후 실시간 시스템 구축 시 이들을 우선적으로 고려할 필요가 있다.

표 3. 정확도의 기술통계량

Table 3. Descriptive statistics for accuracy

Model	Min.	Max.	Mean	Std.DEV
Decision tree	0.87	0.89	0.88	0.00
ExtraTrees	0.87	0.89	0.88	0.00
RandomForest	0.87	0.89	0.88	0.00
HistGradientBoosting	0.87	0.88	0.88	0.00
LightGBM	0.87	0.88	0.88	0.00
XGBoost	0.84	0.86	0.85	0.00
KNN	0.83	0.85	0.84	0.00
CatBoost	0.83	0.84	0.83	0.00
GradientBoosting	0.83	0.84	0.83	0.00
AdaBoost	0.72	0.74	0.73	0.01
QDA	0.68	0.69	0.69	0.00
LDA	0.68	0.69	0.68	0.00
MLP	0.64	0.68	0.67	0.01
DNN	0.64	0.68	0.65	0.01
SVM(RBF)	0.56	0.56	0.56	0.00
LogisticRegression	0.54	0.54	0.54	0.00
RidgeClassifier	0.54	0.54	0.54	0.00
SVM(Linear)	0.54	0.54	0.54	0.00
BernoulliNB	0.54	0.54	0.54	0.00
SGDClassifier	0.50	0.54	0.53	0.01
GaussianNB	0.52	0.54	0.53	0.00
PassiveAggressive	0.37	0.52	0.44	0.05
Perceptron	0.27	0.52	0.42	0.07
NearestCentroid	0.33	0.36	0.35	0.01

표 3은 24종 알고리즘의 정확도에 대한 기술통계로, 평균뿐 아니라 최솟값·최댓값·표준편차를 함께 제시하여 모델군 간 성능 격차와 반복 실험에서의 안정성을 동시에 비교하기 위한 근거가 된다. 이를

통해 평균만 높은 모델과, 평균이 높으면서 편차가 작아 실제 서비스에 안정적으로 적용 가능한 모델을 구분할 수 있다.

선행 연구[8][9]에서 보고된 정확도는 상이한 데이터 및 평가 조건에서 산출된 것으로 본 연구의 수치와 직접 비교하기 어렵다. 동일 평가 체계 하에서의 선행 모델과의 정량 비교는 향후 과제로 남긴다.

4.2 학습 및 예측 시간 효율성 평가

표 4는 모델별 학습시간의 기술통계를 보여준다. 모델별 학습 시간을 분석한 결과 알고리즘의 복잡도와 연산 방식에 따라 처리 속도에서 극명한 차이가 나타난다. 가장 우수한 정확도를 보였던 상위권 모델 중 Decision Tree는 평균 0.02초의 매우 빠른 학습 시간을 기록하였으며, ExtraTrees(0.46초)와 LightGBM(0.83초) 역시 1초 미만의 준수한 속도를 보였다. 반면 신경망 기반의 DNN과 MLP는 각각 평균 180.14초와 77.42초라는 압도적으로 긴 학습 시간을 소요하였으며, 특히 MLP의 경우 표준편차가 17.16으로 나타나 시스템 자원 상황에 따라 학습 속도의 불확실성이 큰 것으로 확인된다. 이는 고차원의 신경망 연산이 정형 데이터인 기압 정보를 처리하는 데 있어 트리 기반 모델 대비 시간 효율성이 현저히 낮음을 입증한다.

정확도와 학습 속도를 종합적으로 고려한 자원 효율성 측면에서는 트리 기반의 앙상블 모델들이 실내 층수 예측에 가장 적합한 것으로 판단된다. 정확도 상위 5개 모델 중 하나인 GradientBoosting은 평균 6.09초로 다른 앙상블 모델들에 비해 상대적으로 긴 시간이 소요되었으나, Decision Tree와 ExtraTrees는 최상위권의 정확도를 유지하면서도 연산 비용을 획기적으로 낮출 수 있음을 보여준다. 결론적으로 실시간 층수 보정이 필요한 모바일 애플리케이션 환경에서는 높은 정확도와 함께 즉각적인 재학습 및 모델 업데이트가 가능한 트리 기반 모델을 채택하는 것이 기술적 측면에서 가장 타당하다.

표 4는 모델별 학습 시간의 기술통계로, 건물별 환경 변화에 따라 모델을 수시로 재학습·갱신해야 하는 모바일 서비스 환경에서 모델 선정의 핵심 근거가 된다.

표 4. 학습 시간의 기술통계량

Table 4. Descriptive statistics for training time

Model	Min.	Max.	Mean	Std.DEV
Decision tree	0.02	0.02	0.02	0.00
ExtraTrees	0.43	0.50	0.46	0.02
RandomForest	0.59	0.69	0.64	0.03
HistGradientBoosting	0.98	1.05	1.02	0.02
LightGBM	0.77	0.89	0.83	0.04
XGBoost	0.69	0.79	0.74	0.03
KNN	0.02	0.02	0.02	0.00
CatBoost	0.90	0.97	0.93	0.02
GradientBoosting	5.91	6.22	6.09	0.10
AdaBoost	0.37	0.44	0.40	0.02
QDA	0.01	0.01	0.01	0.00
LDA	0.01	0.01	0.01	0.00
MLP	46.86	106.25	77.42	17.16
DNN	177.73	181.90	180.14	1.16
SVM (RBF)	24.92	25.71	25.30	0.26
LogisticRegression	0.06	0.23	0.17	0.07
RidgeClassifier	0.01	0.07	0.01	0.02
SVM(Linear)	0.06	0.08	0.06	0.00
BernoulliNB	0.01	0.01	0.01	0.00
SGDClassifier	0.19	0.22	0.20	0.01
GaussianNB	0.00	0.01	0.00	0.00
PassiveAggressive	0.05	0.08	0.06	0.01
Perceptron	0.04	0.07	0.06	0.01
NearestCentroid	0.01	0.01	0.01	0.00

표 5는 각 모델별 예측시간의 기술통계를 보여준다. 모델별 검증 시간을 분석한 결과, 대부분의 알고리즘이 0.1초 미만의 매우 신속한 처리 속도를 보이며 실시간 서비스 대응이 가능함을 확인하였다. 정확도 상위권을 차지했던 Decision Tree, ExtraTrees, RandomForest 등 트리 기반 모델들은 평균 0.00초에서 0.04초 사이의 검증 시간을 기록하여 실제 모바일 환경에서의 즉각적인 층수 보정에 적합한 특성을 보였다. 특히 연산 복잡도가 높은 것으로 알려진 XGBoost와 AdaBoost 역시 0.02초대의 빠른 추론 속도를 유지하였으며, 딥러닝 모델인 DNN 또한 0.28초 내외의 수치로 검증이 완료되어 대규모 연산이 필요한 신경망 구조임에도 불구하고 실시간 추론 단계에서의 병목 현상은 크지 않은 것으로 나타났다.

반면 커널 기반 모델인 SVM(RBF)은 평균 5.85초의 검증 시간을 소요하며 타 알고리즘 대비 현저히

낮은 연산 효율성을 보였다. 이는 정확도 측면에서의 열세뿐만 아니라 추론 속도 면에서도 실내 주차장과 같이 빠른 응답성이 요구되는 환경에 부적합함을 시사한다. 결과적으로 정확도와 학습 시간, 검증 시간이라는 세 가지 지표를 종합적으로 검토했을 때, Decision Tree와 ExtraTrees를 포함한 상위권 트리 기반 모델들이 연산 자원의 최적화와 예측 정밀도를 동시에 달성할 수 있는 가장 균형 잡힌 알고리즘군임이 명확해졌다. 이러한 결과는 향후 실내 위치 기반 서비스의 경량화 및 고도화를 위한 모델 선정의 중요한 근거가 된다.

표 5는 모델별 검증(추론) 시간의 기술통계로, 사용자 이동 시 즉각적인 층 판정이 요구되는 실시간 응답성을 평가하기 위한 지표이다.

표 5. 예측 시간의 기술통계량

Table 5. Descriptive statistics for predicting time

Model	Min.	Max.	Mean	Std.DEV
Decision tree	0.00	0.00	0.00	0.00
ExtraTrees	0.04	0.04	0.04	0.00
RandomForest	0.03	0.04	0.04	0.00
HistGradientBoosting	0.07	0.08	0.08	0.00
LightGBM	0.08	0.09	0.09	0.00
XGBoost	0.02	0.02	0.02	0.00
KNN	0.04	0.04	0.04	0.00
CatBoost	0.00	0.00	0.00	0.00
GradientBoosting	0.04	0.05	0.04	0.00
AdaBoost	0.02	0.02	0.02	0.00
QDA	0.00	0.00	0.00	0.00
LDA	0.00	0.00	0.00	0.00
MLP	0.01	0.07	0.04	0.02
DNN	0.27	0.29	0.28	0.01
SVM(RBF)	5.68	6.00	5.85	0.10
LogisticRegression	0.00	0.00	0.00	0.00
RidgeClassifier	0.00	0.00	0.00	0.00
SVM (Linear)	0.00	0.00	0.00	0.00
BernoulliNB	0.00	0.00	0.00	0.00
SGDClassifier	0.00	0.00	0.00	0.00
GaussianNB	0.00	0.00	0.00	0.00
PassiveAggressive	0.00	0.00	0.00	0.00
Perceptron	0.00	0.00	0.00	0.00
NearestCentroid	0.00	0.00	0.00	0.00

기존 연구와의 비교 측면에서, 저자들의 선행 연구[8][9]는 단일 딥러닝 모델로 약 90% 수준의 정확

도를 보고한 바 있으며, Wi-Fi 지문 기반 실내 측위 연구는 더 높은 정확도를 제시하기도 한다. 다만 이들 연구는 사용 데이터, 입력 변수, 평가 절차가 본 연구와 상이하여 정확도 수치를 직접 비교하기는 어렵다. 본 연구의 의의는 최고 정확도의 경신보다는, 동일한 데이터셋과 평가 조건에서 24종 알고리즘을 공정하게 비교하고 정확도와 연산 효율을 함께 제시하여 경량·실시간 환경에 적합한 모형군을 규명한 데 있다.

4.3 최적의 모형 선정

본 연구에서는 정밀도와 실시간성이라는 두 가지 서비스 요구사항을 완벽하게 충족하는 Decision Tree와 ExtraTrees를 최적의 모델로 최종 선정한다. 선정 근거는 다음과 같은 세 가지 관점에서 도출되었다. 본 연구에서는 정밀도와 실시간성이라는 두 가지 서비스 요구사항을 완벽하게 충족하는 Decision Tree와 ExtraTrees를 최적의 모델로 최종 선정한다. 선정 근거는 다음과 같은 세 가지 관점에서 도출되었다.

본 연구에서는 정밀도와 실시간성이라는 두 가지 서비스 요구사항을 완벽하게 충족하는 Decision Tree와 ExtraTrees를 최적의 모델로 최종 선정한다. 선정 근거는 다음과 같은 세 가지 관점에서 도출되었다.

첫째, 예측 성능의 상대적 안정성이다. Decision Tree와 ExtraTrees는 24종의 모델 중 가장 높은 평균 정확도(0.88)를 기록하였으며, 10회 반복 실험 동안 표준편차가 0.00에 수렴하는 안정성을 보여주었다. 이는 기압 변화와 셀룰러 신호 감쇠가 복합적으로 작용하는 지하 주차장 환경의 비선형적 특성을 트리 구조의 분할 방식이 가장 정밀하게 학습했음을 의미한다.

둘째, 즉각적인 재학습이 가능한 최저 수준의 학습 시간이다. 실제 서비스 환경에서는 장치별 센서 오차나 건물별 환경 차이에 따라 모델을 수시로 업데이트해야 할 필요가 있다. Decision Tree는 평균 0.02초, ExtraTrees는 0.46초라는 매우 낮은 학습 소요 시간을 기록하였다. 이는 수백 초(180.14초)가 소요되는 DNN이나 수십 초가 걸리는 MLP와 대조되는 수치이다. 즉, 클라우드 자원을 최소화하면서도

대규모 사용자의 데이터를 실시간으로 반영하여 모델을 최신화하기에 가장 적합한 구조임을 시사한다.

셋째, 실시간 보정을 보장하는 빠른 검증 속도이다. 스마트폰 기반의 층수 예측은 사용자가 이동하는 즉시 결과가 도출되어야 하므로 예측 시간이 매우 중요하다. 선정된 모델들은 평균 0.00~0.04초 내에 추론을 완료하여 실시간 응답성에 지장을 주지 않는 것으로 나타났다.

결론적으로, 정확도 상위 5개 모델 중에서도 연산 비용이 가장 낮으면서 높은 성능을 일관되게 유지한 Decision Tree와 ExtraTrees가 실내 위치 기반 서비스(LBS)를 위한 최적의 알고리즘으로 판단된다.

V. 결 론

본 연구의 목적은 스마트폰에 내장된 기압 센서와 셀룰러 신호 세기만을 이용하여 별도의 인프라 없이 실내 지하주차장의 층수를 예측하고, 이에 적합한 인공지능 모델을 규명하는 데 있다. 이를 위해 서울시 G밸리 일대 22개 건물 지하주차장에서 수집한 데이터에 대하여, 지상·지하의 기압(GP, BP)과 신호 세기(GS, BS)를 입력으로 하고 지하 층수(BF)를 출력으로 하는 24종의 머신러닝·딥러닝 알고리즘을 동일 조건에서 적용하였다. 각 모델은 층화 무작위 분할을 10회 반복하여 평가하였으며, 예측 정확도뿐 아니라 학습 시간과 검증 시간을 함께 측정하여 실제 모바일 환경에서의 적용 가능성을 종합적으로 분석하였다.

실험 결과, 층수 예측에 가장 탁월한 성능을 보인 모델은 Decision Tree와 ExtraTrees를 포함한 트리 기반 앙상블 알고리즘군으로 나타났다. 이들 모델은 평균 0.88의 높은 정확도를 기록하며 본 데이터셋과 실험 조건에서 상대적으로 우수한 성능을 보였다. 특히 트리 구조의 분할 학습 방식이 가장 정교하게 포착함을 확인하였다. 이는 복잡한 신경망 구조 없이도 스마트폰 센서만으로 충분히 고정밀 층수 보정이 가능함을 시사한다. 데이터 규모와 입력 차원이 제한적인 정형 데이터 환경에서는 트리 기반 모델이 딥러닝 대비 유리할 수 있다.

또한 본 연구는 Google Colab 환경에서의 반복

실험을 통해 모델의 실용성을 객관적으로 검증하였다. 최종 선정된 Decision Tree와 ExtraTrees는 학습 시간이 1초 미만으로 매우 짧고, 예측 시간 역시 0.04초 이내의 초고속 연산 성능을 보였다. 결과적으로 제안된 모델들은 사용자 이동에 따른 즉각적인 층수 변화를 지연 없이 반영할 수 있어, 실시간 응답성이 필수적인 상용 애플리케이션에 즉시 도입 가능한 최적의 대안임을 확인하였다. 또한 본 연구는 다음의 한계를 가진다. 절대 기압이 건물별 환경에 의존하여 건물 간 편차에 민감하고, 데이터가 동절기 단기간에 수집되어 계절·기상 변화에 대한 검증이 이루어지지 않았으며, 셀룰러 신호가 건물·위치 특성의 영향을 받을 수 있다.

결론적으로 본 연구는 기압 데이터 기반의 고도 추정 분야에서 모델의 예측 정밀도와 연산 효율성 간의 균형이 우수한 모델군을 제시하였다. 이는 별도의 인프라 구축 비용 없이 기존 스마트폰 단말기의 센서 데이터만으로 지하 주차 공간에서의 수직 위치 인지 정확도를 극대화할 수 있음을 의미한다. 본 연구의 결과는 향후 실내 내비게이션, 주차 관리 시스템, 긴급 구조 서비스 등 다양한 실내 위치 기반 서비스의 고도화를 위한 핵심적인 기술 가이드라인으로 활용될 것으로 기대된다.

본 연구는 지하 주차장이라는 특정 환경에 집중하였으나, 향후에는 보다 다양한 변수를 고려한 모델 고도화 연구를 진행할 계획이다. 먼저 기온, 습도와 같은 미세한 변화로 인한 정확도의 차이를 검증할 것이다. 그리고 상위의 모델들 중 다양한 파라미터를 활용하여 여러 가지 방향 및 반복 수행으로 검증을 수행할 것이다. 또한 실험 대상 건물을 전국 단위의 다양한 건축 구조로 확대하여 모델의 일반화 성능을 검증할 것이다. 즉, 예측의 연속성과 정교함을 더욱 높이는 연구를 지속할 예정이다.

References

- [1] H. Huang, G. Gartner, and M. Raubal, "Location-based services: ongoing evolution and research agenda", *Journal of Location Based Services*, Vol. 12, No. 2, pp. 63-93, Aug. 2018.

- <https://doi.org/10.1080/17489725.2018.1508763>.
- [2] A. Basiri, P. Lohan, P. Moore, P. Winstanley, S. Peltola, J. Hill, and R. Amirian, "Indoor location based services challenges, requirements and usability of current solutions", *Computer Science Review*, Vol. 24, pp. 1-12, May 2017. <https://doi.org/10.1016/j.cosrev.2017.03.002>.
 - [3] F. Zafari, A. Gkelias, and K. K. Leung, "A survey of indoor localization systems and technologies", *IEEE Communications Surveys & Tutorials*, Vol. 21, No. 3, pp. 2568-2599, Sep. 2017. <https://doi.org/10.1109/COMST.2019.2911558>.
 - [4] H. Liu, H. Darabi, P. Banerjee, and J. Liu, "Survey of wireless indoor positioning techniques and systems", *IEEE Transactions on Systems, Man, and Cybernetics, Part C*, Vol. 37, No. 6, pp. 1067-1080, Nov. 2007. <https://doi.org/10.1109/TSMCC.2007.905750>.
 - [5] R. Harle, "A survey of indoor inertial positioning systems for pedestrians", *IEEE Communications Surveys & Tutorials*, Vol. 15, No. 3, pp. 1281-1293, Jan. 2013. <https://doi.org/10.1109/SURV.2012.121912.00075>.
 - [6] M. Youssef and A. Agrawala, "The Horus WLAN location determination system", *Proc. of the 3rd International Conference on Mobile Systems, Applications, and Services (MobiSys)*, Seattle, Washington, pp. 205-218, Jun. 2005. <https://doi.org/10.1145/1067170.1067193>.
 - [7] <https://www.yna.co.kr/view/AKR20230707068800017>. [accessed: Apr. 01, 2026]
 - [8] T. Jeong, K. Kim, and J. Kim, "A proposal of an indoor floor prediction model using deep learning-based atmospheric pressure", *Journal of Korean Institute of Information Technology (JKIIT)*, Vol. 22, No. 5, pp. 43-50, May 2024. <https://doi.org/10.14801/jkiit.2024.22.5.43>.
 - [9] T. Jeong, K. Kim, A. Kang, and J. Kim, "Development of deep learning-based parking floor detection application", *Journal of Industrial Technology Research (JITR)*, Vol. 29, No. 3, pp. 163-172, Sep. 2024. <https://doi.org/10.29279/jitr.k.2024.29.3.163>.
 - [10] S. Mostafa, K. Harras, and M. Youssef, "A survey of indoor localization systems in multi-floor environments", *TechRxiv*, pp. 1-25, Aug. 2022. <https://doi.org/10.36227/techrxiv.20439648.v1>.
 - [11] J. Torres-Sospedra, R. Montoliu, A. Martínez-Usó, J. Avariento, T. J. Arnau, and J. Huerta, "UJIIndoorLoc: A new multi-building and multi-floor database for WLAN fingerprint-based indoor localization problems", *Proc. of the International Conference on Indoor Positioning and Indoor Navigation (IPIN)*, Busan, Korea, pp. 1-8, Oct. 2014. <https://doi.org/10.1109/IPIN.2014.7275492>.
 - [12] A. Rai, K. Chintalapudi, V. N. Padmanabhan, and R. Sen, "Zee: Zero-effort crowdsourcing for indoor localization", *Proc. of the 18th Annual International Conference on Mobile Computing and Networking (MobiCom)*, Istanbul Turkey, pp. 293-304, Aug. 2012. <https://doi.org/10.1145/2348543.2348580>.
 - [13] Z. Xu, J. Wei, J. Zhu, and W. Yang, "A robust floor localization method using inertial and barometer measurements", *Proc. of the International Conference on Indoor Positioning and Indoor Navigation (IPIN)*, Sapporo, Japan, pp. 1-8, Sep. 2017. <https://doi.org/10.1109/IPIN.2017.8115952>.
 - [14] S. He and S.-H. G. Chan, "Wi-Fi fingerprint-based indoor positioning: Recent advances and comparisons", *IEEE Communications Surveys & Tutorials*, Vol. 18, No. 1, pp. 466-490, Aug. 2016. <https://doi.org/10.1109/COMST.2015.2464084>.
 - [15] Pierre Auger Collaboration, "Impact of atmospheric effects on the energy reconstruction of air showers", *Astroparticle Physics*, pp. 1-29, Feb. 2017. <https://doi.org/10.48550/arXiv.1702.02835>.

저자소개

김 규 석 (Kyuseok Kim)



2011년 2월 : 한국항공대학교

정보통신공학(학사)

2019년 8월 : 아주대학교

정보통신공학(석사)

2025년 2월 : 서울대학교

도시계획학(박사)

2011년 1월 ~ 2019년 6월 :

LG전자(주) 선임연구원

2019년 7월 ~ 2020년 2월 : (주)LG유플러스 연구소 책임

2020년 2월 ~ 현재 : 한국폴리텍대학

인공지능소프트웨어과 부교수

관심분야 : 도시계획, 부동산, 인공지능, 빅데이터, 근거리

무선통신

정 태 양 (Taeyang Jeong)



2016년 6월 ~ 2019년 5월 :

(주)에이텍 S/W 연구원

2022년 4월 ~ 2022년 12월 : ICT

이노베이션 AI융합교육 강사

2025년 2월 : 한국공학대학교

스마트팩토리융합학과(석사)

2023년 3월 ~ 현재 :

한국폴리텍대학 인공지능소프트웨어과 외래교원

2023년 12월 ~ 현재 : (주)만들다소프트 대표이사

2025년 3월 ~ 현재 : 한국공학대학교 컴퓨터공학과

박사과정

2025년 8월 ~ 현재 : 한국공학대학교 AI소프트웨어학과

겸임교수

관심분야 : 인공지능, 증권 및 암호화폐 데이터 활용