

# BaroDetector: 스마트워치를 이용한 건물 단위 위치 추적

김진산\*, 노영태<sup>o</sup>

## BaroDetector: Building Level Location Track Using Smartwatch

Jin-san Kim\*, Young-tae Noh<sup>o</sup>

요약

스마트폰을 포함한 모바일 컴퓨팅 기술의 많은 발전으로 인해, 우리는 일상생활에서 많은 편리함을 누리고 있다. 특히, 위치 기반 서비스를 통해, 우리는 위치에 따라 적절한 광고를 받거나, 주변의 위험한 상황에 대한 경고 메시지를 받을 수 있다. 이러한 서비스는 대부분 GPS 센서에 의존하고 있다. GPS 센서는 다른 센서에 비해 배터리 소모량이 많으며, 실내 진입 시 사용자의 정확한 위치를 특정하기 힘들다. 본 논문에서는 스마트워치의 압력 센서와 스마트폰의 가시 위성 수를 이용한 건물 단위 위치 추적 방법을 제안한다. 스마트워치의 압력 센서 데이터를 수집해 이를 기계학습 모델에 학습시켜 출입문 통과 이벤트를 97.7%의 정확도로 탐지한다. 제안된 접근 방식은 사용자가 출입문을 통과했다고 판단한 경우, 스마트폰 GPS 센서 데이터 내 가시 위성 개수의 추이를 확인해 실내 진입 여부를 확정한다. 이후 마지막 GPS 좌표를 지도상에 고정해 사용자가 진입한 건물을 표시하고, GPS 센서를 비활성화하여 배터리 소모를 줄인다. 비활성화된 GPS 센서는 사용자가 실내를 벗어난 이후 재활성화된다. 제안된 방법은 평균 92.2%의 정확도로 사용자의 실내/외 상황을 탐지한다.

**Key Words** : LBS, Location tracking, Machine learning, Pressure sensor, Smartwatch

### ABSTRACT

Thanks to the many developments in mobile computing technology, including smartphones, we enjoy many conveniences in our daily lives. In particular, location-based services allow us to receive appropriate advertisements or receive alerts about dangerous situations. Most of these location-based services rely on GPS sensors. However, the GPS sensor consumes a lot of battery power of the smartphone. Moreover, when the user enters indoors, it is difficult to track the exact location of the user. In this paper, we propose a building-level location track using the pressure sensor on a smartwatch and the number of visible satellites from GPS data on smartphone. We detect door passing event with 97.7% accuracy by training machine learning model with pressure sensor data. The proposed method, when it determines that the user has passed through the door, it checks the trend of the number of visible satellites to determine whether user enters indoor. After that, the last GPS coordinates are fixed on the map to display the building where the user entered, and deactivate the GPS sensor to reduce battery consumption. The GPS sensor is reactivated when the user goes outdoor. The proposed method detects the user's indoor/outdoor state with an average accuracy of 92.2%.

\* 본 연구는 교육부의 재원으로 한국연구재단의 기초연구실 지원사업의 지원을 받아 수행된 것임 (NRF-2020R1A4A1018774)

• First Author : Inha University Computer Science Engineering, jskim@nsl.inha.ac.kr, 학생회원

◦ Corresponding Author : Inha University Computer Science Engineering, ytnoh@nsl.inha.ac.kr, 종신회원

논문번호 : 202109-244-C-RU, Received September 16, 2021; Revised November 3, 2021; Accepted November 23, 2021

## 1. 서 론

우리는 일상생활에서 현재 위치에 따라서 지역 날씨 및 뉴스를 전달받거나, 운동 구간 관련 정보를 얻거나, 가장 가까운 택시를 호출하는 등 여러 위치 기반 서비스를 이용하며 살고 있다<sup>1)</sup>. 이러한 서비스는 일반적으로 GPS (Global Positioning System)를 사용한다. GPS는 가시 위성 (Visible satellite)을 통해 정확한 위치 파악 서비스를 제공할 수 있다. 반면, 실내와 같이 인공위성의 영향을 받기 어려운 곳은 GPS의 신뢰도가 매우 낮다. 이 문제는 일반적으로 GPS multipath error와 NLOS (None-line-of-sight)로 인해 발생한다<sup>2)</sup>. 이러한 문제는 도시 환경에서 약 100m의 위치 오류를 일으킬 수 있다<sup>3)</sup>. GPS 센서는 다른 센서와 비교했을 때 소모 전력량이 매우 많은 센서이기도 하다. 스마트폰의 각 센서를 활성화한 상황에서 GPS 센서는 370mW의 전력을 소모한다. 이에 반해 조도 센서와 마이크 센서는 60mW 남짓 소모한다<sup>4-7)</sup>. GPS 센서는 사용자의 위치를 특정하기 어려운 환경에서 정확한 위치 정보를 얻고자 지속적으로 위성 스캔을 시도한다<sup>6)</sup>. 이로 인해 지도상의 위치가 계속해서 바뀌어 사용자의 정확한 위치를 특정하는 데 혼동을 주며, 배터리 소모도 그만큼 증가한다.

위치 기반 서비스의 또 다른 영역으로는 실내/외 감지 기능이 있다. 실내/외 감지는 사용자 상태를 실내 또는 실외로 구분하는 것이다. 대표적인 실내/외 감지 서비스의 예시는 사용자가 실내에 진입한 것을 탐지하여 공기청정기 등의 가전제품을 자동으로 작동시키는 스마트홈 서비스가 있다. 기존의 많은 연구는 앞서 언급한 GPS의 단점을 보완하기 위해 스마트폰에 내장된 여러 센서 조합을 사용하여 실내/외 감지 문제를 해결하려고 시도했다<sup>6-8)</sup>. 하지만 이러한 연구를 실제 (in-the-wild) 환경에 적용하기 위해서는 중요한 문제가 있다. 스마트폰은 보통 가방, 주머니 또는 다른 장소 등 위치가 수시로 바뀌어 일정한 환경을 유지하기 어렵다. 온-보드 (On-board) 센서를 이용한 상황 인식 연구에서 이는 큰 단점이다. 하지만 스마트워치의 경우, 대부분의 시간 동안 사용자의 손목 위에 위치한다. 이 점은 스마트워치가 사용자의 주변 환경을 대표하는 가장 적절한 기기임을 의미한다.

우리는 압력 센서가 실내/외 감지 기술을 구현하는 데 중요한 역할을 할 수 있을 것으로 생각한다. 건물 대부분은 쾌적한 실내 온도 및 압력을 유지하기 위해 HVAC (Heating, ventilating and air conditioning) 시스템을 갖추고 있다. 이로 인해 건물 내부와 외부 사

이에 환경적인 차이를 만든다. 이러한 차이로 인해 출입문을 통과할 때, 통상적으로 10Pa에서 30Pa의 기압 변화를 감지할 수 있다. 또한, 일정한 수준의 기압을 유지하다가 출입문을 통과할 때 우하향 혹은 우상향 후 다시 일정 수준의 기압을 유지하는 패턴을 관찰할 수 있다<sup>9)</sup>. 압력 센서는 상황 인지 (context-awareness) 연구에도 많이 쓰여왔다. Muchen Wu 등은 건물 2층에 위치한 스마트폰의 압력 센서로도 출입문 통과 이벤트를 감지할 수 있음을 보여준다<sup>9)</sup>. Sankaran 등은 스마트폰의 압력 센서를 이용해 걷기, 계단 오르기, 교통수단을 이용하는지 여부 등을 구분하였다. 또한, 압력 센서는 센서가 활성화된 상황에서 110mW의 전력을 소모해 GPS 센서에 비해 전력량 소모가 적어 스마트워치를 이용한 기술에 사용하기 적절하다<sup>5)</sup>.

실내/외 감지 기술을 구현하는 데 있어 GPS 원시 데이터 내 가시 위성의 숫자도 중요한 역할을 할 수 있다. Statista에 따르면, 2021년 1월 기준 지구의 위성군 (Satellite Constellation)에는 3372개의 활성 위성이 있다<sup>10)</sup>. Kongyang Chen 등은 실험을 통해 가시 위성의 수가 실내/외 상태와 강한 상관관계가 있음을 보였다<sup>11)</sup>.

본 논문에서는 스마트워치의 압력 센서와 GPS 가시 위성 수를 이용해 건물 단위 위치 추적 방법을 제안하고자 한다. 스마트워치의 압력 센서를 이용해 기압 데이터를 수집하고, 기압 데이터에서 보이는 패턴을 기계학습 모델에 학습시켜 사용자가 실외에서 실내 혹은 실내에서 실외로 이동하는지 탐지한다. 기압 패턴에 의해 사용자가 실내 혹은 실외로 이동했다고 판단되는 경우, 사용자의 스마트폰 내 GPS 센서 데이터에서 가시 위성 수의 추이를 파악하여 사용자의 현재 위치가 실외인지 실내인지 최종 판단을 내린다. 사용자가 실내로 진입한 경우, 스마트폰의 GPS 센서 데이터 내 좌표를 지도상에 고정해 사용자가 진입한 건물을 특정한다. 이후 GPS 센서를 비활성화한다. 사용자가 실외로 이동한 경우, GPS 센서를 재활성화한다.

BaroDetector는 기압 데이터를 수집하여 스마트폰으로 전송하는 스마트워치 애플리케이션과 전송된 기압 데이터를 전처리한 후 기계학습 classifier에 적용해 출입문 통과 이벤트를 탐지하고, GPS 가시 위성 수를 확인해 사용자의 실내/외 진입 여부를 판단하는 스마트폰 애플리케이션으로 구성된다. 스마트폰 애플리케이션에는 현재 사용자가 실내인지 실외인지 표기되며, 어느 건물에 위치하는지 지도상에 표시된다.

본 논문의 나머지 부분은 다음과 같이 구성된다. II 장에서는 실내/외 탐지에 관한 기존 연구들을 소개한

다. III장에서는 BaroDetector의 전체적인 시스템 설계 및 데이터 수집, 전처리 등을 설명한다. IV장에서는 개발된 BaroDetector의 성과와 전체 시나리오를 평가한다. V장은 고찰 및 향후 연구 방향, VI장은 결론을 다룬다.

## II. 관련연구

실내/외 탐지에 관한 기존 연구가 많이 존재한다. 이 연구는 두 가지 연구 방향으로 나눌 수 있다. 첫 번째는 GPS 신호와 그 특징에 기초한 연구, 두 번째는 스마트 기기에 다양한 센서 (e, g., 가속도계, 조도 센서 등) 조합을 사용하는 연구이다. 또한, 압력 센서를 이용한 상황 인지 연구도 진행되었다.

Lenin Ravindranath 등은 실내/외 탐지에 GPS 신호의 가용성을 사용한다. 이들은 실내에서 GPS를 사용할 경우 위치를 특정할 수 없다는 사실에 기초해 사용자가 실내 혹은 실외에 위치하는지 결정한다<sup>12)</sup>. 그러나 이 방법은 건물에 넓은 창문이 존재할 경우 실내에서 GPS 신호를 원활히 수신할 수 있어, 이 접근 방식은 신뢰하기 어렵다<sup>13)</sup>.

위성을 이용한 실내/외 연구도 존재한다. Weiping Wang 등은 GSM (Global System for Mobile) 통신 셀룰러 기지국의 신호 강도를 이용한다<sup>14)</sup>. 사용자의 위치를 Open outdoors, Semi-outdoors, Light indoors, Deep indoors로 나누어 GSM 통신 셀룰러 기지국의 신호 강도를 분류하고, 신호 패턴을 기계학습에 적용해 사용자의 위치를 식별한다. SatProbe는 원시 GPS 데이터에서 가시 위성 수를 사용해 사용자의 실내/외 상태를 판단한다<sup>11)</sup>. 이들은 클라우드 서비스를 통해 동료 사용자 (동일한 셀룰러 기지국 ID를 사용하는 사용자) 데이터를 이용한다. 이들의 데이터를 기반으로 가시 위성 수의 임계값 (threshold)을 정해 사용자의 위치 상태를 파악한다<sup>15)</sup>.

실내/외를 감지하는 또 다른 방법으로 스마트폰에 내장된 센서를 사용하는 것이다. IODetector<sup>6)</sup>는 빛, 셀 신호 및 자기 센서를 사용해 임계값 기반의 방법으로 실내/외를 감지한다. 하지만 이러한 임계값 기반 탐지 기법은 다양한 장치 및 환경을 대변할 수 없다는 한계가 있다. 이런 한계를 극복하기 위해 해당 연구팀은 마이크, 배터리 온도계 및 근접 센서 등을 추가하고, 다양한 환경에의 적용을 위해, 준 지도 학습을 적용하였다<sup>7)</sup>.

압력 센서는 여러 상황 인지 연구에 사용되었다. Muchen Wu 등은 스마트폰의 압력 센서가 건물의 출

입문이 열렸을 때 감지 가능하다는 사실을 기반으로 한 건물 보안 시스템을 제안하였다<sup>9)</sup>. 이 연구에서 그들은 건물의 2층에 스마트폰이 위치할지라도, 스마트폰 내의 압력 센서가 출입문이 열리는 것을 감지할 수 있다는 사실을 보여주었다. 또한, 출입문이 열렸을 때 특정한 기압 패턴이 생긴다는 것을 보였다. Kartik Sankaran 등은 스마트폰 압력 센서를 이용한 사용자 이동 상황 감지를 제안한다<sup>5)</sup>. 이들은 사용자의 고도 변화 속도를 통해 차량에 탑승한 경우, 걷고 있는 경우, 가만히 서 있는 경우 총 3가지의 사용자 상태를 구별한다.

## III. 건물 단위 위치 추적 시스템

건물 단위 위치 추적 시스템은 크게 기압 패턴 감지와 GPS 가시 위성 확인 두 부분으로 나뉜다. 기압 패턴 감지는 스마트워치의 압력 센서를 이용해서 출입문 통과 이벤트를 탐지한다. GPS 가시 위성 확인은 GPS 데이터 내 가시 위성 개수의 추이를 파악해 사용자의 위치 상황을 판단한다. 사용자가 건물 안에 있는 것으로 판단할 때, 사용자 스마트폰 내 GPS 센서를 비활성화하고 마지막 위치를 지도상에 표기함으로써 건물 단위 위치 추적을 이루어 낸다. 그림 1은 건물 단위 위치 추적 시스템의 순서도를 보여준다.

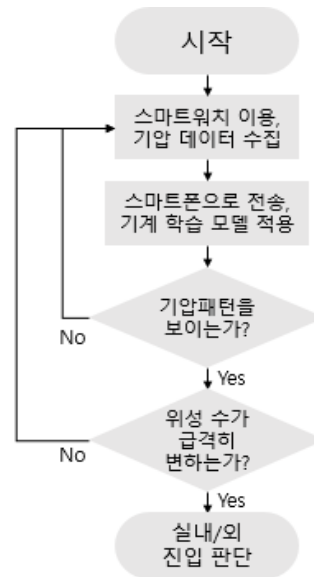


그림 1. 건물 단위 위치 추적 시스템 순서도  
Fig. 1. The Flowchart of building-level location tracking system

### 3.1 기압 패턴 감지

**데이터 수집.** 스마트워치를 통해 압력 센서 데이터를 수집하기 위해서 Samsung Galaxy Note 8<sup>[16]</sup> 스마트폰과 Samsung Gear S3 Frontier<sup>[17]</sup> 스마트워치를 사용한다. 스마트워치에는 0.0001 Pa 단위로 측정할 수 있는 압력 센서가 내장되어 있다. 우리는 그림 2에 나타난 데이터 수집 에이전트를 사용해 10 Hz의 Sampling rate으로 기압 데이터를 수집한다. 데이터 수집 에이전트는 Android 에이전트와 Tizen 에이전트로 구성되어 있다. (a) Android 에이전트를 이용해 현재 위치 (실내, 문 통과, 실외), 진행 방향 등을 수동으로 레이블링한다. 이때, 레이블링한 데이터는 GT (Ground Truth)로 사용한다. (b) Tizen 에이전트는 기압 데이터를 수집한 후 데이터를 기록한 파일을 전송한다. 한 개의 기압 데이터 세트는 약 3분, 1800여 개의 기압 데이터로 이루어져 있다.

다양한 환경에서도 신뢰성 있게 동작하기 위해 다중 환경을 고려한다. 사용자가 통과하는 문을 자동문, 회전문, 미는 문 및 당기는 문 총 4개의 출입 유형으로 나누어 데이터를 수집한다. 데이터 수집은 실내에서 실외, 실외에서 실내 총 2가지 시나리오에서 진행한다. 시립 도서관, 대형마트, 대학 건물 등 5층 이상의 높이를 가진 밀폐되지 않은 건물과 밀폐된 3m 이하의 가정 주택 등 다양한 장소에서 데이터를 수집한다. 학습을 위한 데이터 세트 개수는 총 80개이다. 4개의 출입 유형으로 나누어 각 문의 종류마다 20개의 데이터 세트가 있으며, 각 데이터 세트는 시나리오별로 나누어져 총 8종류의 데이터 세트로 구성되어 있다.

**데이터 전처리.** 우리는 기압 데이터의 시간에 따른 패턴을 포착하기 위해 슬라이딩 윈도우 (Sliding window)를 사용한다. 출입문을 열고, 통과하고, 닫는 시간을 기준으로 슬라이딩 윈도우의 길이는 3초로 설정하였고, overlap은 0.1초로 설정하였다. 각 기압 데이




그림 2. 데이터 수집 에이전트를 이용한 기압 데이터 수집 과정 (a) 사용자 위치 GT 전송, (b) 기압 데이터 전송  
Fig. 2. Pressure sensor data collection procedure using data collect agent. (a) sends GT of user's location state, (b) sends pressure sensor data stream file

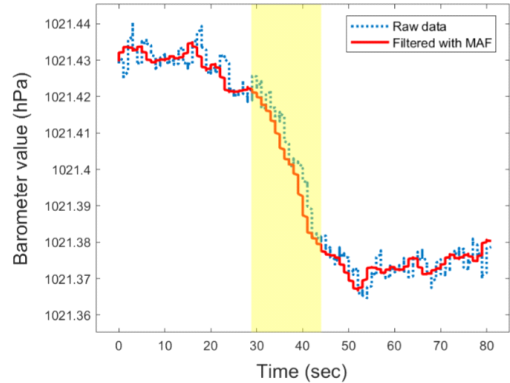


그림 3. 출입문 통과 이벤트 발생 시 기압 데이터 패턴  
Fig. 3. Pattern of the pressure sensor data stream during the door-passing event

터는 출입문 통과 이벤트의 여부에 따라 통과, 비통과 2가지로 나누어 라벨링 한다. 압력 센서는 민감하여 주변 환경의 영향을 쉽게 받아 이상 데이터가 많이 발생한다. 이를 제거하고, 명확한 기압 데이터 패턴을 얻기 위해 각 슬라이딩 윈도우에 MAF (Moving Average Filter)<sup>[18]</sup>를 적용하였다. 그림 3은 출입문 통과 이벤트가 있을 때의 기압 데이터 패턴을 보여준다. 통과로 분류되는 기압 데이터는 노란색으로 표시하였다. MAF를 적용한 데이터가 원시 데이터보다 안정된 모양을 갖추었음을 볼 수 있다.

기압 데이터를 기계학습 classifier에 학습시키기 위해 Data scaling을 진행하였다. Min-max normalization<sup>[19]</sup>을 이용해 모든 데이터를 [0, 1]의 범위 내에 정규화하였다. 이후 슬라이딩 윈도우 내에서 8개의 feature를 추출하였다. 각 feature에 절댓값을 적용해 실내에서 실외, 실외에서 실내 두 가지 경우를 모두 탐지할 수 있게 했다. feature들의 종류는 다음과 같다.

1. Rate of change: 기울기
2. Mean crossing rate: 평균을 지나는 횟수
3. Standard deviation: 표준편차
4. Inter quartile range: 사분위수 범위 (Q3 - Q1)
5. Kurtosis: 첨도
6. Root mean square: 제곱평균제곱근
7. Root sum square: 제곱합제곱근
8. Value difference: 최댓값과 최솟값의 차

**출입문 통과 이벤트 탐지.** 기압 패턴 감지에 사용할 기계학습 모델을 선택하고자 우리는 기계학습 도구인 Weka<sup>[20]</sup>를 이용해 6개의 기계학습 classifier를 비교한다. 사용 classifier는 RF (Random Forest), J48 Decision tree, SMO (Sequential Minimal Optimization), BN (Bayes Net), NB (Naive Bayes), LWL (Locally Weighted Learning)이다. 기계학습 모델은 10-folds 교차 검증을 이용한다. 이 검증법을 통해, 서로 다른 환경에서 수집된 기압 데이터들을 혼합해 학습하고, 테스트할 수 있다.

압력 센서는 바람과 같은 외부 환경에 민감하게 반응한다. 이로 인해 출입문 통과 이벤트에 대해 false positive가 발생할 가능성이 높다. 이를 방지하기 위해 슬라이딩 윈도우 내 모든 데이터가 통과로 판단된 경우, 출입문 통과 이벤트가 발생했다고 판단한다.

### 3.2 GPS 가시 위성 확인

**가시 위성 수 추이 파악.** GPS 데이터 내 가시 위성 개수는 사용자의 실내/외 상태와 강한 상관관계가 있다. 그림4는 사용자의 위치에 따른 GPS 가시 위성의 개수 추이를 보여준다. 실내에선 주로 10개 이하로 감지하며, 실외로 이동할 경우 급격히 증가하여 최대 32개 이상 감지할 수 있다.

우리는 가시 위성의 추이를 파악하기 위해 가시 위성 숫자를 길이 20의 큐 (Queue)에 저장하고, 큐에 저장된 가시 위성 수의 평균을  $Q_{mean}$  이라 한다. 이후 수집된 가시 위성의 개수가  $Q_{mean}$ 의  $\pm 50\%$  범위에 존재하면, 사용자의 위치는 실내/외로의 변화가 없다고 판단한다. 이후 수집된 가시 위성 개수가  $Q_{mean}$  값의 0.5 배 이하라면, 사용자가 실외에서 실내로 이동한 것으

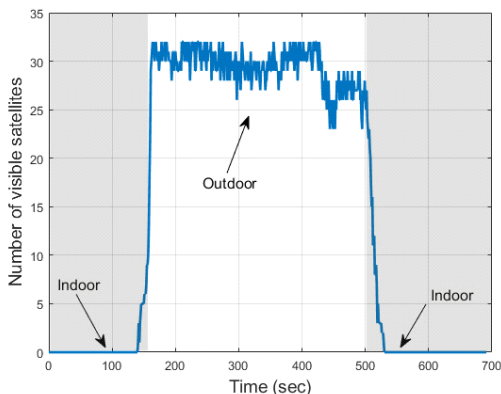


그림 4. 위치(실내, 실외)에 따른 가시 위성 개수  
Fig. 4. Number of visible satellites depends on location (Indoor, Outdoor)

로 판단한다. 반대로, 수집된 가시 위성 개수가  $Q_{mean}$  값의 1.5배 이상이라면, 이는 BaroDetector가 실내에서 작동이 시작되었음을 의미한다. 이 경우 Queue를 clear 한다. 50%의 임계값은 엄밀하게 사용자의 위치 상태를 파악하고자 설정하였다. 그림4에서 보듯 가시 위성 개수는 실내에서 극단적으로 줄어들기 때문에, 사용자가 실내 혹은 실외에 있는지 충분히 구분할 수 있다.

### 3.3 건물 단위 위치 추적

BaroDetector는 압력 데이터를 전송하는 스마트워치 애플리케이션과 데이터를 전처리하고, 내장된 Weka 라이브러리를 통해 기압 패턴을 탐지하고, 특정 기압 패턴 탐지 시 GPS 데이터 내 가시 위성 개수를 파악해 사용자의 위치 상태를 판단하는 스마트폰 애플리케이션으로 구성된다. 스마트폰 애플리케이션은 사용자가 실외에 있는 경우 가시 위성 개수를 저장한다. 또한, Google Maps Platform<sup>[21]</sup>을 통해 사용자의 위치를 나타내며, 사용자가 현재 실외인지, 실내인지 명시한다. 사용자가 실내에 있다고 판단한 경우, 마지막으로 받았던 GPS 센서 내 좌표를 지도에 고정해 사용자가 진입한 건물을 특정함으로써 건물 단위 위치 추적을 구현한다. 그림 5는 스마트폰에 구현된 BaroDetector의 스크린샷이다.




그림 5. BaroDetector 안드로이드 애플리케이션  
Fig. 5. BaroDetector Android application



### IV. 평 가

**기계학습 classifier 선택.** 6개의 기계학습 모델에 기압 데이터를 적용하여, 제일 높은 정확도를 보이는 모델을 선별하고자 하였다. 그림 6은 출입문의 종류에 따른 각 기계학습 classifier의 정확도를 보여준다: (a) 자동문, (b) 회전문, (c) 미는 문, (d) 당기는 문. 각 classifier에 대한 평균 정확도를 계산했을 때, RF가 가장 높은 88.53%의 정확도를 나타내, 이후 실험은 RF classifier를 이용해 진행하였다.

**기압 패턴 탐지 정확도 개선.** 그림 3에서 볼 수 있듯, 기압 데이터는 출입문을 통과한 후 약 10초의 시간이 지나며 실외 환경과 실내 환경을 구분할 수 있게 변한다. 이 점에 착안해 슬라이딩 윈도우의 길이를 기존 3초에서 7초까지 수정하며 기압 패턴 탐지 정확도 개선 실험을 진행하였다. 표 1은 해당 실험의 결과를 보여준다.

슬라이딩 윈도우 길이가 3초였을 때, 정확도는 88.5%에 거짓 양성률이 13.5%로 나왔지만, 6초로 슬라이딩 윈도우 길이가 늘어나면서 6.3%의 정확도와 4.6%의 False positive rate가 개선되었다. 슬라이딩 윈도우 길이가 7초일 때는 오히려 정확도가 감소하였다. 이 결과를 바탕으로 슬라이딩 윈도우의 길이는 6초로 적용한다.

**출입문 통과 이벤트 탐지.** BaroDetector가 실제 출입문 통과 이벤트를 탐지할 수 있는지 평가하기 위해 60개의 출입문 통과 이벤트가 있는 데이터 세트와 26개의 출입문 통과 이벤트가 없는 데이터 세트를 추가로 수집하였다. 출입문 통과 이벤트가 있는 데이터 세트는 3.1절에서 언급한 장소들에서 같은 방법을 통해 수집하였다. 출입문 통과 이벤트가 없는 데이터 세트는 실내 혹은 실외에서 다른 장소로 이동하지 않은 채 앉아있거나, 계속 걷는 등 출입문을 통과하지 않고 데이터를 수집하였다.

표 1. 슬라이딩 윈도우 길이에 따른 정확도 변화  
Table 1. Sensitivity of model performance for the given window size

| Window size | Accuracy (%) | TP Rate (%) | FP Rate (%) |
|-------------|--------------|-------------|-------------|
| 3 (sec)     | 88.5         | 91.5        | 13.5        |
| 4 (sec)     | 92.0         | 95.5        | 11.5        |
| 5 (sec)     | 93.6         | 97.2        | 10          |
| 6 (sec)     | 94.8         | 98.5        | 8.9         |
| 7 (sec)     | 91.4         | 94.1        | 12.1        |

실험결과 60개의 출입문 통과 이벤트가 있는 데이터 세트에 대해서 100%의 정확도를 보였다. 26개의 출입문 통과 이벤트가 없는 데이터 세트에 대해서는 24개의 데이터 세트에 대해 출입문 통과 이벤트가 없다고 판단하였다. 총 86개의 데이터 세트에 대해 97.7%의 정확도를 보였고, True positive rate 100%, False positive rate는 7.7%를 보였다.

**건물 단위 위치 추적 기술 평가.** 본 논문에서 제안하는 건물 단위 위치 추적 기술을 평가하기 위해, BaroDetector의 실내/외 탐지 정확도 및 배터리 사용량을 실험을 통해 검증하기로 한다. 실험은 Samsung Galaxy Note 8을 이용하며, 대형마트, 아파트, 지하철역에서 진행하였다. 대형마트는 지하 1층, 지상 4층 건물이며, 아파트는 지하 1층, 지상 5층 건물이다. 실험 방법은 다음과 같다. BaroDetector를 실행한 채로 건물에 들어갈 때 및 건물에서 나올 때 정확히 탐지하는지 여부를 확인한다. 실험은 건물 외부에서 시작하여 건물 진입 후 다시 외부로 나가는 방식으로 진행한다. 표2는 장소별 탐지 결과를 보여준다. 각 시나리오마다 30번 실험을 진행하였다.

기존 GPS센서를 이용한 방법과 배터리 사용량을 비교하기 위해, 실험 진행 중 백그라운드에서 GPS 센




그림 6. 출입문 종류(a) 자동문, (b) 회전문, (c) 미는 문, (d) 당기는 문)에 따른 6개 기계학습 classifiers (RF, J48, SMO, BN, NB, LWL)의 정확도 비교  
Fig. 6. Accuracy comparison of six machine learning classifiers (RF, J48, SMO, BN, NB, LWL) according to door type ((a) automatic door, (b) revolving door, (c) push door, (d) pull door)

서를 이용하여 1초마다 위치 정보를 받는 애플리케이션을 실행하였다. 다른 센서와의 비교를 위해, WiFi 센서도 추가적으로 측정하였다. WiFi 센서는 1초마다 주변 AP를 스캔하였다. 그림 7은 실험 동안 사용한 배터리 사용량의 평균을 보여준다. GPS 센서는 실험이 진행되는 동안 소모된 스마트폰 배터리의 45.12%를 소모했다. BaroDetector의 경우 16.24%를 소모했다.

표 2. 장소별 BaroDetector 실내/외 탐지 정확도  
Table 2. Detection accuracy of BaroDetector depends on locations

| Location              | Shopping mall | Apartment | Subway station |
|-----------------------|---------------|-----------|----------------|
| Accuracy Out → In (%) | 86.7          | 93.3      | 93.3           |
| Accuracy In → Out (%) | 90.0          | 96.6      | 93.3           |

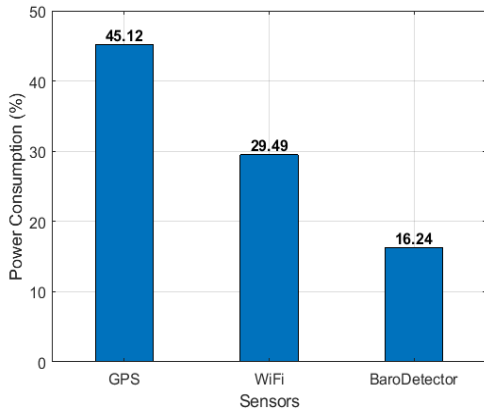


그림 7. 배터리 사용량 비교  
Fig. 7. Battery consumption comparison.

### V. 고찰 및 향후 연구 방향

본 논문에서 BaroDetector는 기존 GPS 기반 위치 추적의 스마트폰 배터리 소모 문제를 해결하였다. 하지만 스마트워치의 배터리 소모에 대한 고려가 부족하여 해당 부분에 관한 보충 연구가 필요하다. 따라서 우리의 향후 연구는 기존의 출입문 통과 이벤트 탐지 정확도는 유지하면서, 스마트워치의 충분한 사용 시간을 보장하는 압력 센서의 최적 Sampling rate를 찾는 연구 및 스마트워치의 센서별 배터리 사용 분석을 포함한다.

### VI. 결 론

본 논문에서는 스마트워치에 내장된 압력 센서와 스마트폰의 GPS 센서 데이터 내 가시 위성 개수를 이용하여 건물 단위 위치 추적 기술을 제안하였다. BaroDetector는 기계학습을 이용해 출입문 통과 이벤트를 97.7%의 정확도로 탐지하였으며, 가시 위성 수의 추이를 이용하여 사용자의 실내/외 위치를 평균 92.2%의 정확도로 탐지해냈다. 또한, 스마트폰의 배터리 소모량도 기존 GPS 기반 방법의 36% 수준으로 낮추었다. 이러한 결과를 통해 BaroDetector는 건물 단위의 위치 추적을 수행할 수 있음을 확인하였다.

### References

- [1] J. S. Han, "The influence of smartphone location based advertising on intention of continuous use and recommendation intension - Focused on the user location based advertising -," *J. Korea Design Forum*, vol. 49, pp. 65-74, Nov. 2015.
- [2] S. Miura, L. T. Hsu, F. Chen, and S. Kamijo, "GPS error correction with pseudorange evaluation using three-dimensional maps," *IEEE Trans. Intell. Transp. Syst.*, vol. 16, no. 6, pp. 3104-3115, Jun. 2015.
- [3] G. MacGougan, G. Lachapelle, R. Klukas, K. Siu, L. Garin, J. Shewfelt, and G. Cox, "Performance analysis of a stand-alone high-sensitivity receiver," *GPS Solutions*, vol. 6, no. 3, pp. 179-195, 2002.
- [4] N. Capurso, T. Song, W. Cheng, J. Yu, and X. Cheng, "An android-based mechanism for energy efficient localization depending on indoor/outdoor context," *IEEE Internet of Things J.*, vol. 4, no. 2, pp. 299-307, 2016.
- [5] K. Sankaran, M. Zhu, X. F. Guo, A. L. Ananda, M. C. Chan, and L.-S. Peh, "Using mobile phone barometer for low-power transportation context detection," in *Proc. 12th ACM Conf. Embedded Netw. Sensor Syst.*, pp. 191-205, 2014.
- [6] P. Zhou, Y. Zheng, Z. Li, M. Li, and G. Shen, "Iodetector: A generic service for indoor outdoor detection," in *Proc. 10th ACM Conf.*

- Embedded Netw. Sensor Syst.*, pp. 113-126, 2012.
- [7] V. Radu, P. Katsikouli, R. Sarkar, and M. K. Marina, "A semi-supervised learning approach for robust indoor-outdoor detection with smartphones," in *Proc. 12th ACM Conf. Embedded Netw. Sensor Syst.*, pp. 280-294, 2014.
- [8] M. Ali, T. ElBatt, and M. Youssef, "SenseIO: Realistic ubiquitous indoor outdoor detection system using smartphones," *IEEE Sensors J.*, vol. 18, no. 9, pp. 3684-3693, 2018.
- [9] M. Wu, P. H. Pathak, and P. Mohapatra, "Monitoring building door events using barometer sensor in smartphones," in *Proc. 2015 ACM Int. Joint Conf. Pervasive and Ubiquitous Computing*, pp. 319-323, 2015.
- [10] Statista, Number of satellites in orbit by country as of January 1, 2021, Retrieved Sep. 2021, from <https://www.statista.com/statistics/264472/number-of-satellites-in-orbit-by-operating-country/>.
- [11] K. Chen and G. Tan, "SatProbe: Low-energy and fast indoor/outdoor detection based on raw GPS processing," *IEEE INFOCOM 2017-IEEE Conf. Comput. Commun.*, pp. 1-9, 2017.
- [12] L. Ravindranath, C. Newport, H. Balakrishnan, and S. Madden, "Improving wireless network performance using sensor hints," in *Proc. 8th USENIX Conf. Networked Systems Design and Implementation*, pp. 21-21, 2011.
- [13] K. Chintalapudi, A. P. Iyer, and V. N. Padmanabhan, "Indoor localization without the pain," in *Proc. Sixteenth Annu. Int. Conf. Mob. Comput. and Netw.*, pp. 173-184, Sep. 2010.
- [14] W. Wang, Q. Chang, Q. Li, Z. Shi, and W. Chen, "Indoor-outdoor detection using a smart phone sensor," *Sensors*, vol. 16, no. 10, pp. 1563, 2016.
- [15] K. Chen and G. Tan, "SatProbe: Low-energy and fast indoor/outdoor detection via satellite existence sensing," *IEEE Trans. Mob. Comput.*, vol. 20, no. 3, pp. 1198-1211, Nov. 2019.
- [16] Samsung Electronics Co., Ltd, *Samsung Galaxy Note8 spec*, Retrieved Sep. 2021, from <https://www.samsung.com/global/galaxy/galaxy-note8/specs/>.
- [17] Samsung Electronics Co., Ltd, *Samsung Galaxy Gear S3 Frontier spec*, Retrieved Mar. 2020, from <https://www.samsung.com/us/mobile/wearables/smartwatches/samsung-gear-s3-frontier-sm-r760ndaaxar/>.
- [18] ScienceDirect, *Moving Average Filter*, Retrieved Sep. 2021, from <https://www.science-direct.com/topics/engineering/moving-average-filter>.
- [19] J. Han, J. Pei, and M. Kamber, *Data Mining: Concepts and Techniques*, Elsevier, 2011.
- [20] Waikato University, *Weka 3: Machine Learning Software in Java*, Retrieved Sep. 2021, from <https://www.cs.waikato.ac.nz/ml/weka/>.
- [21] Google, *Google Maps Platform*, Retrieved Sep. 2021, from <https://mapsplatform.google.com/>.

김진산 (Jin-san Kim)



2020년 2월 : 인하대학교 컴퓨터공학과 학사  
 2020년 3월~현재 : 인하대학교 전기컴퓨터공학 석사과정  
 <관심분야> 빅데이터 플랫폼, 데이터과학, 모바일 컴퓨팅

[ORCID:0000-0002-7820-7613]



노 영 태 (Young-tae Noh)



2004년 8월 : 조선대학교 전자  
계산학과 학사

2007년 2월 : 광주과학기술원  
정보기술공학부 석사

2007년 9월 : 광주과학기술정보  
기술원 정보통신공학과 연구  
원

2012년 6월 : University of California 컴퓨터 과학  
과 박사

2012년 7월~2014년 11월 : Cisco Systems Software  
Engineer

2015년 2월~2015년 8월 : Purdue University Post  
doc

2015년 9월~현재 : 인하대학교 컴퓨터 공학과 교수  
<관심분야> 데이터 센터 네트워킹, 무선 네트워킹,  
HCI(Human-computer interaction), 머신러닝

[ORCID:0000-0002-9173-1575]