

# Single Antenna Based GPS Signal Reception Condition Classification Using Machine Learning Approaches

Sanghyun Kim, Seunghyeon Park, Jiwon Seo<sup>†</sup>

School of Integrated Technology, Yonsei University, Incheon 21983, South Korea

## ABSTRACT

In urban areas it can be difficult to utilize global navigation satellite systems (GNSS) due to signal reflections and blockages. It is thus crucial to detect reflected or blocked signals because they lead to significant degradation of GNSS positioning accuracy. In a previous study, a classifier for global positioning system (GPS) signal reception conditions was developed using three features and the support vector machine (SVM) algorithm. However, this classifier had limitations in its classification performance. Therefore, in this study, we developed an improved machine learning based method of classifying GPS signal reception conditions by including an additional feature with the existing features. Furthermore, we applied various machine learning classification algorithms. As a result, when tested with datasets collected in different environments than the training environment, the classification accuracy improved by nine percentage points compared to the existing method, reaching up to 58%.

**Keywords:** global positioning system, signal reception condition classification, machine learning

## 1. 서론

최근 도심 항공 모빌리티 (Urban Air Mobility; UAM)와 같은 새로운 도시 교통 수단이 등장함에 따라, 도심 지역에서의 Positioning Navigation Timing (PNT) 정보를 제공받으려 하는 수요가 증가하고 있다 (Causa & Fasano 2021, Lee et al. 2022a). 이에 정밀한 PNT 정보를 제공할 수 있는 미국의 Global Positioning System (GPS)를 비롯한 위성항법시스템 (Global Navigation Satellite System; GNSS)의 중요성이 높아지고 있다 (Kim et al. 2020, Yoon et al. 2020). 그러나, 높은 건물들과 여러 장애물이 있는 도심 지역에서는 신호 차단이나 다중경로 현상으로 인해 위성항법시스템의 활용에 어려움이 있다 (Jia et al. 2021, Lee et al. 2022b, Kim et al. 2022a, Kim et al. 2022b). 이는 수백 미터 이상의 위치 오차를 야기할 수도 있기 때문에 도심에서 다중경로 문제를 해결하기 위한 노력은 필수적이다 (MacGougan et al. 2002,

Shen et al. 2020).

다중경로 환경에서의 위성항법 신호는 사용자 입장에서 다음의 세 가지 경우로 수신될 수 있다. 가시선 (Line-of-Sight; LOS) 신호만 수신되는 LOS-only 환경, 비가시선 (Non-Line-of-Sight; NLOS) 신호만 수신되는 NLOS-only 환경, 그리고 가시선과 비가시선이 동시에 수신되는 LOS+NLOS 환경이 이에 해당한다. 이 가운데 NLOS-only 및 LOS+NLOS 환경이 도심에서의 큰 위치 오차를 일으키는 원인이므로, 이를 탐지한 후 위치 계산에서 제외함으로써 위치 정확도를 높일 수 있다 (Misra & Enge 2001, Kubo et al. 2020). 이에 다중경로 신호 (NLOS-only 또는 LOS+NLOS)를 탐지하기 위한 다양한 방법들이 제안되었다 (Closas & Fernandez-Prades 2011, Xu & Rife 2019, Lee & Seo 2020).

여러 다중경로 신호 탐지 방법들 중 하나로, fish-eye 카메라를 사용하는 방법이 제안된 바 있다 (Bai et al. 2020). 이는 fish-eye 카메라를 통해 얻은 sky plot에서 건물에 해당하는 영역에 위치한 위성을 NLOS-only 위성으로 식별하는 방법이다. 또한, 3D 도시 모델을 이용하여 건물의 경계를 나타내는 sky plot을 생성하는 방법 (Wang et al. 2012)도 제안되었는데, 이는 fish-eye 카메라 없이도 NLOS-only 위성을 식별할 수 있다는 장점이 있다. 그러나, 이러한 방법들은 근본적으로 LOS+NLOS 신호는 탐지하지 못한다는 한계가 있다. 3D 도시 모델과 광선 추적 (ray tracing)을

Received May 08, 2023 Revised May 26, 2023 Accepted June 02, 2023

<sup>†</sup>Corresponding Author

E-mail: jiwon.seo@yonsei.ac.kr

Tel: +82-32-749-5833 Fax: +82-32-818-5801

Sanghyun Kim <https://orcid.org/0000-0003-4756-1596>

Seunghyeon Park <https://orcid.org/0009-0007-2344-3030>

Jiwon Seo <https://orcid.org/0000-0003-1781-533X>

이용하면 LOS+NLOS와 NLOS-only 신호를 모두 탐지할 수 있다 (Miura et al. 2013). 그러나 이는 높은 계산량이 요구되며 3D 도시 모델을 구축하고 불러오기 위해서는 상당한 작업량이 필요하다는 어려움이 여전히 존재한다 (Zhu et al. 2018).

또 다른 다중경로 신호 탐지 방법으로, 위성항법 신호에서 얻을 수 있는 여러 측정치 정보를 이용하는 통계적 분석 방법이 있다. 대표적으로, GPS L1, L2, L5 신호의 반송파 대 잡음비 (carrier-to-noise-density ratio;  $C/N_0$ )를 비교하여 다중경로 신호를 탐지하는 방법이 있다 (Strode & Groves 2016). 또한, 이중편파 안테나에서 수집한 우선회원편파 (Right Hand Circularly Polarized; RHCP) 신호와 좌선회원편파 (Left Hand Circularly Polarized; LHCP) 신호의 반송파 대 잡음비 차이를 다중경로 신호 탐지를 위한 척도로 사용할 수도 있다 (Groves et al. 2010, Kim et al. 2021). 최근에는 통계적 방법에서 더 나아가, 머신러닝을 통해 신호의 수신 환경을 분류하는 연구들이 활발히 진행되고 있다 (Sun et al. 2019).

머신러닝 모델의 성능은 사용되는 특징 (feature)의 종류에 큰 영향을 받기 때문에 위성항법 신호에서 적절한 특징을 추출하고 적용하는 것이 중요하다. Support Vector Machine (SVM) 알고리즘에 기반한 머신러닝 분류 방법 중 하나 (Suzuki et al. 2017)는 위성항법 신호의 상관기 출력을 특징 중 하나로 사용하였다. 그러나, 이 방법은 신호를 LOS-only와 다중경로 신호의 두 가지 환경으로만 분류할 수 있었다. SVM 알고리즘을 이용하는 또 다른 방법으로, Kim & Seo (2022)는 위성의 양각, 반송파 대 잡음비, 반송파 대 잡음비의 변화량을 머신러닝 모델의 특징으로 이용하여 LOS-only, NLOS-only, LOS+NLOS의 신호 수신 환경을 분류할 수 있었다. 그러나, Kim & Seo (2022)에서의 결과를 살펴보면, 학습 환경과 다른 환경에서 수집된 데이터셋을 통해 테스트하였을 때 약 49%의 낮은 분류 정확도를 보인다는 한계가 있었다. 일반적으로, 학습 환경과 다른 환경에서 수집된 데이터셋에 대한 단일 안테나 기반의 LOS-only, NLOS-only, LOS+NLOS 신호 수신 환경 머신러닝 분류 정확도는 55% 수준이다 (Sun et al. 2020).

이를 극복하기 위하여, 본 연구에서는 새로운 특징을 추가하여 기존 연구에서 적용된 바 없는 네 개의 특징 조합을 이용하는 머신러닝 기반 GPS 신호 수신 환경 분류 기법을 개발하였다. 또한, 다양한 종류의 머신러닝 알고리즘을 적용하여 알고리즘에 따른 분류 정확도를 비교하였다. 본 논문의 2장에서는 GPS 신호 수집 및 라벨링 방법에 대해 다루며, 3장에서는 머신러닝 특징 추출 방법 및 머신러닝 알고리즘에 대해 설명한다. 4장에서는 개발한 머신러닝 모델의 성능을 분석하고, 마지막으로 5장에서는 결론을 제시한다.

## 2. GPS 신호 수집 및 라벨링

본 논문에서는 GPS 신호 수집 및 라벨링 과정을 통해, 머신러닝 모델의 학습 및 테스트 데이터셋을 구성하였다. GPS 신호 수집은 Fig. 1의 하드웨어를 이용하여 진행하였으며, 이는 Antcom사의 안테나와 NovAtel PwrPak7 수신기, 그리고 노트북 컴퓨터로 구성되어 있다. Fig. 2와 같은 다중경로 환경을 가진 총 다섯 지




Fig. 1. GPS signal collection hardware (reproduction of Fig. 1 of Kim & Seo (2022)).




Fig. 2. Five static locations where GPS signals were collected.




Fig. 3. Formulation of training and test data sets.

점의 정적 환경에서 GPS L1 신호를 수집하였다.

수집된 GPS 신호를 학습 및 테스트 데이터 샘플로 사용하기 위해서는 해당 신호의 신호 수신 환경 참값 (ground truth) 정보를 기반으로 수집 데이터를 라벨링해야 한다. 이는 Kim & Seo (2022)에서의 방법과 동일하게 진행하였으며, 3차원 도시 모델을 이용하는 ray tracing 시뮬레이션을 통해 신호 수신 환경 참값을 획득하여 라벨링 할 수 있었다.

최종적으로 학습 및 테스트 데이터셋 구성은 Fig. 3과 같이 진행하였으며, 각 데이터셋에 포함된 데이터 샘플의 개수는 Table 1에 나타나 있다. 먼저, NLOS-only, LOS-only, LOS+NLOS 클래스의 데이터 샘플 개수가 균일한 학습 데이터셋을 구성하기 위하

**Table 1.** The number of NLOS-only/LOS-only/LOS+NLOS data samples for each dataset.

GPS dataset	Training dataset (T0)	Test dataset 1 (T1)	Test dataset 2 (T2)
Total samples	7500	7500	7500
NLOS-only samples	2500	2500	2500
LOS-only samples	2500	2500	2500
LOS+NLOS samples	2500	2500	2500

여, A, B, C 지점에서 수집한 데이터 샘플을 하나로 모으는 과정을 진행하였다. 이후 이를 절반씩 무작위로 나누어 학습 데이터셋(T0)과 테스트 데이터셋 1(T1)로 구성하였으며, 나머지 두 지점(D, E)에서 수집한 데이터 샘플은 테스트 데이터셋 2(T2)로 구성하였다. 이를 통해, 학습에 사용된 지점에서 얻은 데이터셋과 학습에 사용되지 않은 지점에서 얻은 데이터셋에 대한 테스트 결과를 모두 분석할 수 있었다.

### 3. 머신러닝 기반 GPS 신호 수신 환경 분류 기법

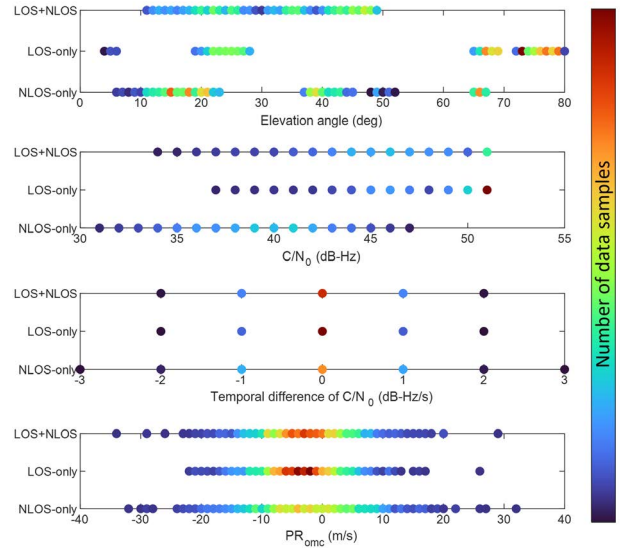
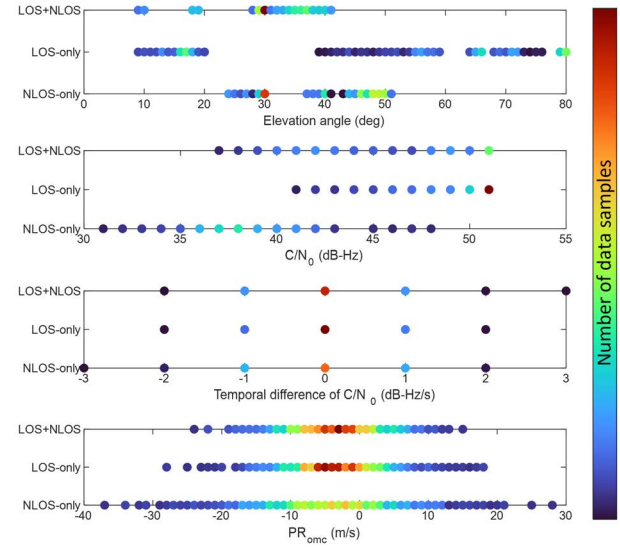
#### 3.1 머신러닝 특징 추출

머신러닝을 위해 본 논문에서 사용한 데이터의 특징 (feature)은 다음과 같다.

- 위성의 양각 (elevation angle): 일반적으로 위성의 양각이 높을수록 신호가 건물에 의해 반사되거나 차단될 가능성이 감소함.
- 반송파 대 잡음비: 반송파 대 잡음비는 수신 신호의 세기와 관련되는 측정치임. 일반적으로 신호가 장애물에 의해 반사되면 신호 전파 경로가 증가하며, 이로 인한 전파 손실의 증가로 반송파 대 잡음비 값이 감소함. 즉, NLOS-only 환경일 경우 LOS-only 환경보다 더 작은 값을 가짐.
- 반송파 대 잡음비의 변화량: 이는 두 연속된 측정 시점 (epoch) 사이의 반송파 대 잡음비 변화량을 의미하며, 수신기 추적 루프 (receiver tracking loop)의 특성에 의해 정적 환경의 다중경로 신호에서 큰 값이 나타남 (Hsu 2017).
- 의사거리 변화량 측정치 및 계산치의 차이: 앞서 설명한 세 가지의 특징은 기존 Kim & Seo (2022)에서 이용한 특징이며, 의사거리 변화량 측정치 및 계산치의 차이는 본 논문에서 새롭게 추가된 특징임. 이는 Hsu (2017)에서 다중경로 신호 탐지를 위한 특징으로 제안된 바 있으며, 의사거리 측정치와 도플러 측정치 사이의 일관성을 나타내는 파라미터로, Eq. (1)과 같이 계산됨.

$$PR_{omc} = \Delta\rho - \dot{\rho} \cdot \Delta t \quad (1)$$

여기서  $PR_{omc}$ 는 의사거리 변화량 측정치 및 계산치의 차이,  $\Delta\rho$ 는 두 측정 시점 사이에서 의사거리 측정치의 변화량,  $\dot{\rho}$ 은 도플러 측정치로부터 계산된 의사거리 변화율, 그리고  $\Delta t$ 는 두 측정 시점 사이의 시간을 나타냄. 즉, 의사거리 측정치와 도플러 측정치에 일관성이 있다면, 도플러 측정치에 기반한  $\dot{\rho}$ 에  $\Delta t$ 를 곱하면 의사거리 측정치의 변화량인  $\Delta\rho$ 와 매우 유

**Fig. 4.** The relationships between the features and signal reception types of T1 dataset.**Fig. 5.** The relationships between the features and signal reception types of T2 dataset.

사해야 하고 Eq. (1)의  $PR_{omc}$ 는 0에 가까운 값을 가져야 함.

각각의 테스트 데이터셋에 대해 특징을 추출하여 분석한 결과는 Figs. 4, 5와 같다. LOS-only 환경의 경우, 일반적으로 높은 위성의 양각과 큰 값의 반송파 대 잡음비를 가졌다. 또한, 반송파 대 잡음비의 변화량과 의사거리 변화량 측정치 및 계산치의 차이 값은 0에 밀집되어 있는 것을 확인할 수 있다. 반면 NLOS-only 환경의 경우, LOS-only 환경과 반대되는 경향을 보였다.

#### 3.2 머신러닝 알고리즘

본 논문에서 NLOS-only, LOS-only, LOS+NLOS 환경 분류를 위해 사용한 머신러닝 알고리즘은 decision tree (DT)




Fig. 6. Classification accuracy of each classification algorithm for T1 dataset, which was collected at the same location with the training dataset.

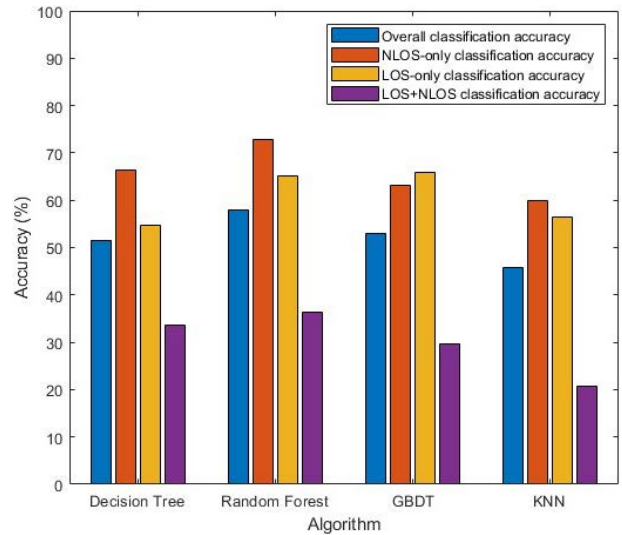


Fig. 7. Classification accuracy of each classification algorithm for T2 dataset, which was collected at different locations with the training dataset.

(Safavian & Landgrebe 1991), random forest (RF) (Liu et al. 2012), gradient boosted decision tree (GBDT) (Friedman 2001), k-nearest neighbor (KNN) (Bezdek et al. 1986) 알고리즘이다. 각 알고리즘에 대한 설명은 다음과 같다.

- DT: 각 데이터들이 가진 특징으로부터 패턴을 찾아내서 분류를 수행할 수 있도록 하는 알고리즘. 그러나 과적합 (overfitting)이 발생할 수 있다는 단점이 있으며 이를 해결하기 위한 알고리즘으로 RF나 GBDT가 제안되었음.
- RF: 의사결정 트리 (decision tree)를 bagging 방식으로 결합한 알고리즘. 학습 데이터셋의 부분집합을 무작위로 추출하여 다수의 의사결정 트리를 만들고, 이들의 분류 결과를 집계하여 최종적인 분류 결과를 출력함. 이를 통해 과적합이 발생한 트리의 영향력을 줄일 수 있음.
- GBDT: 의사결정 트리를 boosting 방식으로 결합한 알고리즘. 여러 약 분류기 (weak classifier)로부터 강 분류기 (strong classifier)를 얻기 위해 여러 의사결정 트리를 직렬로 결합함. 이때, 각 트리는 이전 트리에서의 잔차 (residuals)를 줄이기 위한 방향으로 학습됨.
- KNN: 입력 데이터 샘플로부터 가까운 k개의 주변 데이터 샘플의 라벨 (label)을 참조하여, 가장 높은 빈도의 라벨을 해당 입력 데이터 샘플의 라벨로 예측하는 알고리즘.

#### 4. 결과 및 논의

본 논문에서는 학습 데이터셋 T0을 이용하여 머신러닝 알고리즘에 따른 네 가지의 학습 모델을 생성하였으며, 테스트 데이터셋 T1과 T2를 통해 성능 검증을 진행하였다. T1과 T2 데이터셋에 대한 분류 정확도 결과는 각각 Figs. 6, 7과 같다.

Fig. 6의 T1 데이터셋 결과를 살펴보았을 때, DT, RF, GBDT, KNN 각각 73.7%, 74.6%, 82.7%, 66.0%의 정확도가 나타났다

며, GBDT와 RF에서 뛰어난 성능을 보였음을 확인하였다. 또한, 각 신호 수신 환경 별 분류 정확도를 분석한 결과, NLOS-only, LOS-only, LOS+NLOS 환경 모두 56.6-87.2% 수준의 정확도가 나타남을 확인할 수 있었다. T1 데이터셋은 학습 데이터셋과 동일한 장소에서 수집된 것이기 때문에 분류 정확도가 높게 나타나지만, 실제 사용자들의 이동 경로는 학습 데이터셋이 수집된 장소와 무관하므로 T1 데이터셋의 분류 정확도는 실제 사용자 관점에서는 큰 의미가 없다. 즉, 실제 사용자 관점에서 의미가 있는 분류 정확도는 학습 데이터셋과 다른 장소에서 수집된 T2 데이터셋의 분류 정확도이다.

T2 데이터셋의 분류 정확도 결과는 Fig. 7과 같다. 머신러닝 알고리즘에 따른 분류 정확도는 DT, RF, GBDT, KNN 각각 51.6%, 58.0%, 53.0%, 45.7%로 나타났다. 이는 T1 데이터셋과 달리 학습 데이터셋이 얻어진 지점과 다른 지점에서 수집된 데이터셋을 통해 테스트한 결과로, T1 데이터셋의 분류 정확도보다 낮은 결과가 나타나는 것이 타당하다. T1 데이터셋에서의 결과와 마찬가지로 RF와 GBDT에서 뛰어난 성능을 보였으며, KNN을 제외한 모든 알고리즘에서 Kim & Seo (2022) 보다 높은 분류 정확도를 가짐을 확인하였다. KNN의 경우 새로운 특징을 추가하였음에도 Kim & Seo (2022)에 비해 성능이 저하되었는데, 이는 데이터 샘플의 차원이 증가함에 따라 데이터 샘플의 밀도가 크게 감소하여, 가까운 데이터 샘플의 라벨을 바탕으로 현재의 데이터 샘플을 예측하는 KNN 알고리즘의 특성에 큰 영향을 미쳤기 때문으로 보인다 (Kouroukidis & Evangelidis 2011).

각 신호 수신 환경 별 분류 정확도를 비교해 보면, NLOS-only와 LOS-only는 54.6-72.8% 사이의 정확도 값을 가지는데 반해, LOS+NLOS 환경에서는 상대적으로 낮은 20.7-36.3%의 분류 정확도를 보였다. 이는, LOS+NLOS 환경이 NLOS-only나 LOS-only 환경에 비해 더 다양한 방식으로 발생할 수 있기 때문으로 생각된다. 따라서, 추후 LOS+NLOS 환경에 대한 추가적인 데이터 샘플을 수집하여 학습 및 테스트에 이용한다면, 분류 정확도




Fig. 8. The positioning result of the GPS receiver and the positioning result after eliminating NLOS-only signal (PRN 5) using RF in location D.

를 더욱 높일 수 있을 것으로 기대된다.

더 나아가, 가장 뛰어난 분류 성능을 보인 RF 알고리즘 기반 학습 모델을 이용하여 T2 데이터셋이 수집된 지점들 중 하나인, D 지점에 대해 NLOS-only 신호를 검출하고 이를 제거하였을 때의 측위 결과를 분석해 보았다. 분석을 진행한 D 지점은 시간당 평균 4.3개의 LOS-only 신호가 수신되는 환경으로, 많은 NLOS-only 신호를 제거하게 되면 측위를 위한 신호의 개수가 충분하지 않아 오히려 측위 정확도가 감소할 수 있다. 따라서, 모든 측정 지점 (epoch)에서 NLOS-only로 검출된 위성 신호만을 제거한 후 측위 결과를 분석하였으며, 그 결과는 Fig. 8과 같다. NLOS-only 신호 제거 전 95% 수평 측위 정확도는 37.8 m를 보였으며, 제거 이후에는 26.7 m로 약 29% 향상되었음을 확인하였다.

## 5. 결론

높은 건물들이 밀집된 도심 지역에서는 위성항법 신호가 반사되어 수신되는 NLOS-only와 LOS+NLOS 환경에 의해 측위 성능이 저하될 수 있다. 이에 NLOS-only, LOS-only, LOS+NLOS 환경을 분류할 수 있는 SVM 알고리즘 기반의 머신러닝 모델이 개발된 바 있으나, 이는 분류 성능에 한계가 있었다. 따라서 본 논문에서는 기존 기법에 특징을 추가하여 총 네 개의 특징 조합을 이용하는 머신러닝 모델을 개발하였다. 또한, 다양한 머신러닝 분류 알고리즘을 적용하여 분류 성능을 비교하였다. 그 결과, 학습 환경과 다른 환경에서 수집된 데이터셋을 통해 테스트하였을 때 최대 58%의 분류 정확도를 얻을 수 있었으며, 기존 기법에 비해 9%p 가량 분류 정확도가 향상됨을 보였다.

## ACKNOWLEDGMENTS

본 연구는 과학기술정보통신부의 재원으로 한국연구재단, 무인이동체원천기술개발 사업단의 지원을 받아 수행되었음

(2020M3C1C1A01086407).

본 논문은 2022년 항법시스템학회 정기학술대회에서 발표한 논문을 확장한 내용임.

## AUTHOR CONTRIBUTIONS

Conceptualization, S. Kim, S. Park, and J. Seo; methodology, S. Kim and J. Seo; software, S. Kim and S. Park; validation, S. Park; formal analysis, S. Kim and S. Park; writing—original draft preparation, S. Kim and S. Park; writing—review and editing, J. Seo; visualization, S. Kim and S. Park.

## CONFLICTS OF INTEREST

The authors declare no conflict of interest.

## REFERENCES

- Bai, X., Wen, W., & Hsu, L.-T. 2020, Using sky-pointing fish-eye camera and LiDAR to aid GNSS single-point positioning in urban canyons, *IET Intelligent Transport Systems*, 14, 908-914. <https://doi.org/10.1049/iet-its.2019.0587>
- Bezdek, J. C., Chuah, S. K., & Leep, D. 1986, Generalized k-nearest neighbor rules, *Fuzzy Sets and Systems*, 18, 237-256. [https://doi.org/10.1016/0165-0114\(86\)90004-7](https://doi.org/10.1016/0165-0114(86)90004-7)
- Causa, F. & Fasano, G. 2021, Improving navigation in GNSS-challenging environments: Multi-UAS cooperation and generalized dilution of precision, *IEEE Transactions on Aerospace and Electronic Systems*, 57, 1462-1479. <https://doi.org/10.1109/TAES.2020.3043543>
- Closas, P. & Fernandez-Prades, C. 2011, A statistical multipath detector for antenna array based GNSS receivers, *IEEE Transactions on Wireless Communications*, 10, 916-929. <https://doi.org/10.1109/TWC.2011.011111.100412>
- Friedman, J. H. 2001, Greedy function approximation: A gradient boosting machine, *The Annals of statistics*, 29, 1189-1232. <https://www.jstor.org/stable/2699986>
- Groves, P. D., Jiang, Z., Skelton, B., Cross, P. A., Lau, L., et al. 2010, Novel multipath mitigation methods using a dual-polarization antenna, in *Proc. ION GNSS*, 21-24 Sept 2010, Portland, Oregon, pp.140-151.
- Hsu, L.-T. 2017, GNSS multipath detection using a machine learning approach, in *Proc. IEEE ITSC*, 16-19 Oct 2017, Yokohama, Japan, pp.1-6. <https://doi.org/10.1109/ITSC.2017.8317700>
- Jia, M., Lee, H., Khalife, J., Kassas, Z. M., & Seo, J. 2021,

- Ground vehicle navigation integrity monitoring for multi-constellation GNSS fused with cellular signals of opportunity, in Proc. ITSC, 19-22 Sept 2021, Indianapolis, IN, USA, pp.3978-3983. <https://doi.org/10.1109/ITSC48978.2021.9564686>
- Kim, S., Byun, J., & Park, K. 2022a, Machine learning-based GPS multipath detection method using dual antennas, in Proc. ASCC, 04-07 May 2022, Jeju, Korea, pp.691-695. <https://doi.org/10.23919/ASCC56756.2022.9828175>
- Kim, S., Lee, H., & Park, K. 2021, GPS multipath detection based on carrier-to-noise-density ratio measurements from a dual-polarized antenna, in Proc. ICCAS, 12-15 Oct 2021, Jeju, Korea, pp.1099-1103. <https://doi.org/10.23919/ICCAS52745.2021.9648845>
- Kim, S., Park, J., Yun, J.-K., & Seo, J. 2020, Motion planning by reinforcement learning for an unmanned aerial vehicle in virtual open space with static obstacles, in Proc. ICCAS, 13-16 Oct 2020, Busan, Korea, pp.784-787. <https://doi.org/10.23919/ICCAS50221.2020.9268253>
- Kim, S. & Seo, J. 2022, Support vector machine-based GPS multipath detection method, in Proc. IPNT Conference, 2-4 Nov 2022, Gangneung, Korea, pp.365-368. <http://ipnt.or.kr/2022proc/45>
- Kim, W., Son, P.-W., Park, S. G., Park, S. H., & Seo, J. 2022b, First demonstration of the Korean eLoran accuracy in a narrow waterway using improved ASF maps, IEEE Transactions on Aerospace and Electronic Systems, 58, 1492-1496. <https://doi.org/10.1109/TAES.2021.3114272>
- Kouiroukidis, N. & Evangelidis, G. 2011, The effects of dimensionality curse in high dimensional kNN search, in Proc. Panhellenic Conference on Informatics, 30 Sept-02 Oct 2011, Kastoria, Greece, pp.41-45. <https://doi.org/10.1109/PCI.2011.45>
- Kubo, N., Kobayashi, K., & Furukawa, R. 2020, GNSS multipath detection using continuous time-series C/N0, Sensors, 20, 1-25. <https://doi.org/10.3390/s20144059>
- Lee, H., Pullen, S., Lee, J., Park, B., Yoon, M., et al. 2022a, Optimal parameter inflation to enhance the availability of single-frequency GBAS for intelligent air transportation, IEEE Transactions on Intelligent Transportation Systems, 23, 17801-17807. <https://doi.org/10.1109/TITS.2022.3157138>
- Lee, H. & Seo, J. 2020, A preliminary study of machine-learning-based ranging with LTE channel impulse response in multipath environment, in Proc. ICCE-Asia, 01-03 Nov 2020, Seoul, Korea, pp.1-4. <https://doi.org/10.1109/ICCE-Asia49877.2020.9277218>
- Lee, H., Seo, J., & Kassas, Z. 2022b, Urban road safety prediction: A satellite navigation perspective, IEEE Intelligent Transportation Systems Magazine, 14, 94-106. <https://doi.org/10.1109/ITS.2022.3181557>
- Liu, Y., Wang, Y., & Zhang, J. 2012, New machine learning algorithm: Random forest, in Proc. ICICA, 14-16 Sept 14-16 2012, Chengde, China, pp.246-252. [https://doi.org/10.1007/978-3-642-34062-8\\_32](https://doi.org/10.1007/978-3-642-34062-8_32)
- MacGougan, G., Lachapelle, G., Klukas, R., Siu, K., Garin, L., et al. 2002, Performance analysis of a stand-alone high-sensitivity receiver, GPS Solutions, 6, 179-195. <https://doi.org/10.1007/s10291-002-0029-z>
- Misra, P. & Enge, P. 2001, The Global Positioning System: Signals, Measurements, and Performance (Lincoln, MA: Ganga-Jamuna Press)
- Miura, S., Hisaka, S., & Kamijo, S. 2013, GPS multipath detection and rectification using 3D maps, in Proc. IEEE ITSC, 06-09 Oct 2013, The Hague, Netherlands, pp.1-7. <https://doi.org/10.1109/ITSC.2013.6728447>
- Safavian, S. R. & Landgrebe, D. 1991, A survey of decision tree classifier methodology, IEEE Transactions on Systems, Man, and Cybernetics, 21, 660-674. <https://doi.org/10.1109/21.97458>
- Shen, N., Chen, L., Wang, L., Lu, X., Tao, T., et al. 2020, Site-specific real-time GPS multipath mitigation based on coordinate time series window matching, GPS Solutions, 24, 1-14. <https://doi.org/10.1007/s10291-020-00994-z>
- Strode, P. R. R. & Groves, P. D. 2016, GNSS multipath detection using three-frequency signal-to-noise measurements, GPS Solutions, 20, 399-412. <https://doi.org/10.1007/s10291-015-0449-1>
- Sun, R., Hsu, L. T., Xue, D., Zhang, G., & Ochieng, W. Y. 2019, GPS signal reception classification using adaptive neuro-fuzzy inference system, The Journal of Navigation, 72, 685-701. <https://doi.org/10.1017/S0373463318000899>
- Sun, R., Wang, G., Zhang, W., Hsu, L. T., & Ochieng, W. 2020, A gradient boosting decision tree based GPS signal reception classification algorithm, Applied Soft Computing, 86, 105942. <https://doi.org/10.1016/j.asoc.2019.105942>
- Suzuki, T., Nakano, Y., & Amano, Y. 2017, NLOS multipath detection by using machine learning in urban environments, in Proc. ION GNSS+2017, 25-29 Sept 2017, Portland, Oregon, pp.3958-3967. <https://doi.org/10.33012/2017.15291>
- Wang, L., Groves, P. D., & Ziebart, M. K. 2012, Multi-constellation GNSS performance evaluation for urban canyons using large virtual reality city models, The Journal of Navigation, 65, 459-476. <https://doi.org/10.1017/S0373463312000082>
- Xu, L. & Rife, J. 2019, NLOS and multipath detection using

doppler shift measurements, in Proc. ION GNSS+2019, 16-20 Sept 2019, Miami, Florida, pp.4064-4075. <https://doi.org/10.33012/2019.17115>

Yoon, H., Seok, H., Lim, C., & Park, B. 2020, An online SBAS service to improve drone navigation performance in high-elevation masked areas, *Sensors*, 20, 1-20. <https://doi.org/10.3390/s20113047>

Zhu, N., Marais, J., Betaille, D., & Berbineau, M. 2018, GNSS position integrity in urban environments: A review of literature, *IEEE Transactions on Intelligent Transportation Systems*, 19, 2762-2778. <https://doi.org/10.1109/TITS.2017.2766768>



**Sanghyun Kim** is an M.S./Ph.D. student in the School of Integrated Technology, Yonsei University, Incheon, Korea. He received the B.S. degree in Integrated Technology from Yonsei University. His research interests

include seamless positioning in urban environments and intelligent transportation systems.



**Seunghyeon Park** is an M.S./Ph.D. student in the School of Integrated Technology, Yonsei University, Incheon, Korea. She received the B.S. degree in Integrated Technology from Yonsei University. Her research interests

include seamless positioning in urban environments and intelligent transportation systems.



**Jiwon Seo** received the B.S. degree in mechanical engineering (division of aerospace engineering) from Korea Advanced Institute of Science and Technology, Daejeon, Korea, and the M.S. degrees in aeronautics/astronautics and electrical engineering and the Ph.D. degree in aeronautics/astronautics

from Stanford University, Stanford, CA, USA. He is currently an Associate Professor with the School of Integrated Technology, Yonsei University, Incheon, Korea. His research interests include GPS anti-jamming technologies; alternative positioning, navigation, and timing technologies including eLoran; and intelligent unmanned systems.