

GNSS NLOS Signal Classifier with Successive Correlation Outputs using CNN

Sangjae Cho[†], Jeong-Hoon Kim

Graduate School of Mobility, Korea Advanced Institute of Science and Technology, Daejeon 34051, Korea

ABSTRACT

The problem of classifying a non-line-of-sight (NLOS) signal in a multipath channel is important to improve global navigation satellite system (GNSS) positioning accuracy in urban areas. Conventional deep learning-based NLOS signal classifiers use GNSS satellite measurements such as the carrier-to-noise-density ratio (CN₀), pseudorange, and elevation angle as inputs. However, there is a computational inefficiency with use of these measurements and the NLOS signal features expressed by the measurements are limited. In this paper, we propose a Convolutional Neural Network (CNN)-based NLOS signal classifier that receives successive Auto-correlation function (ACF) outputs according to a time-series, which is the most primitive output of GNSS signal processing. We compared the proposed classifier to other DL-based NLOS signal classifiers such as a multi-layer perceptron (MLP) and Gated Recurrent Unit (GRU) to show the superiority of the proposed classifier. The results show the proposed classifier does not require the navigation data extraction stage to classify the NLOS signals, and it has been verified that it has the best detection performance among all compared classifiers, with an accuracy of up to 97%.

Keywords: GNSS, multipath, NLOS, CNN

1. INTRODUCTION

오늘날 도심환경에서 생활하고 있는 현대인들은 스마트폰 단말기, 자가용 자동차, 응급구조와 같은 안전 서비스 등을 통해 직/간접적으로 위치 서비스를 매우 넓은 범위에서 활발히 사용하고 있다 (Lee & Park 2022). Global navigation satellite system (GNSS)은 이러한 위치 서비스에서 중요한 요소이며 가장 기본적으로 사용되고 있는 시스템이다 (Kaplan & Hegarty 2017). 최근 들어, GNSS를 자체적으로 서비스하는 여러 국가들은 GNSS 측위 성능 향상을 목적으로 GNSS 인공위성 개수를 늘리고 있다 (Yao & Lu 2017). 그러나, 인공위성 개수가 증가함에도 불구하고, 도시 지역에는 측위 성능이 급격하게 저하되는 경우가 발생한다 (Zhang et al. 2021). 그 측위 성능 저하의 가장 대표적인 원인은 도시 지역의 높은 건물 외벽이나 물체들의 표면에 의한 다중 경




Fig. 1. Comparison of LOS and NLOS multipath signals in urban area.

로 채널 환경이다 (Yu et al. 2009, Nunes et al. 2019).

다중경로 신호에는 무선 신호 전파 채널 환경에 따라 두 종류 (non-line-of-sight; NLOS, line-of-sight; LOS)로 구분된다. Fig. 1은 도심 영역에서 발생하는 NLOS, LOS 다중경로 신호를 보여 준다. LOS 다중경로 신호는 직접적으로 수신되는 신호 (이하 직접 신호)와 전파 반사되어 수신되는 신호가 동시에 들어오는 신호를 의미한다. LOS 다중경로 신호를 수신한 기존 GNSS 수신기

Received Sep 28, 2022 Revised Dec 06, 2022 Accepted Jan 11, 2023

[†]Corresponding Author

E-mail: sanje@kaist.ac.kr

Tel: +82-42-350-1285 Fax: +82-42-350-1250

Sangjae Cho <https://orcid.org/0000-0002-4836-9873>

Jeong-Hoon Kim <https://orcid.org/0000-0001-9996-9396>




Fig. 2. LOS-NLOS likelihood probabilistic model of satellite's signal CN_0 .




Fig. 3. CN_0 changes over the time in urban area.

는 auto-correlation function (ACF)을 통해 다중 경로 신호에서 직접 신호를 쉽게 분류할 수 있다. 또한, 수신기가 직접 신호를 분류하지 못하여도 LOS 다중경로 신호는 최대 수 m 의 측위 오차만을 야기하기 때문에, 도시 지역의 측위 성능 저하에 결정적이지 않다 (Van Dierendonck et al.1992).

그런데, NLOS 다중경로 신호 (이하 NLOS 신호)는 직접 신호를 포함하지 않고 전파 반사와 회절 된 신호로만 구성되어 있어 수십 m 이상의 측위 오차를 야기한다. NLOS 채널 환경은 주로 높은 건물들이 즐비한 고밀도 도심 환경 (e.g., 주변 건물 높이가 평균 100 m 이상)에서 발생한다. 또한, NLOS 신호로부터 측정된 의사거리의 오차는 전파 환경에 따라 변화무쌍하고 그 최대값을 정의할 수 없기 때문에 수신기에서 오차를 보정하기 매우 어렵다. 따라서, 수신기는 수집된 신호중 NLOS 신호를 분류하고, 위치 계산 과정에서 shadow matching (SM) (Groves 2011)과 같이 NLOS 인공위성 측정치에 대한 가중치를 낮추거나 제외시키는 것이 측위 성능 향상을 위한 단순하고 가장 확실한 방법이다.

NLOS 신호를 분류하기 위해, 기존 연구들에서는 인공위성 신호 측정치를 사용하는 것이 지배적이었다. 대표적인 인공위성 신호 측정치로는 신호의 상태를 나타내는 Carrier-to-noise-density ratio (CN_0) 또는 Signal-to-noise ratio (SNR)이 있다. 기존 기술들은 NLOS와 LOS 채널 환경을 구분하는 임의의 CN_0 또는 SNR 임계값을 설정하여 NLOS 인공위성을 구분하였다. 무선 신호가 전파 과정에서 왜곡되면 신호의 상태가 저하되기 때문에, 그 측정치는 NLOS 신호를 구분할 수 있는 매우 중요한 단서가 될 수 있다. 하지만, CN_0 또는 SNR만을 사용하면 NLOS 신호 검출 어려움이 높을 수 있다. Fig. 2는 라이시안/로그-정규 분포 (Irish

et al. 2014)에 따라 모델링 된 CN_0 에 따른 LOS-NLOS 신호 가능도를 보여준다. 두 가능도의 교차되는 CN_0 를 NLOS 검출을 위한 임계값으로 선정하게 되면, 오탐 (False-alarm) 발생 확률이 매우 높다. 또한, 고밀도 도심 영역을 제외하고 일반적인 도심 영역에서는 Fig. 3과 같이 신호의 CN_0 가 시간에 따라 끊임없이 변화한다. 따라서, CN_0 를 사용하여 정확하게 NLOS 신호를 검출하는 것은 한계가 있다 (Cho et al. 2019).

이러한 문제를 해결하기 위해, Hsu (2017)와 Cho et al. (2019)에서는 인공지능을 사용하는 NLOS 검출 기법을 제시하였다. Hsu (2017)는 순간의 인공위성 신호 측정치 (신호 세기, 의사거리 측정치 변화량)를 Support Vector Machine (SVM)의 입력으로 사용하여 NLOS 신호를 구분하는 기술을 제시하였다. SVM 기반의 NLOS 검출기법은 순간의 측정치만을 사용하여 최대 75%의 저조한 검출 성공율을 보였다.

Cho et al. (2019)에서는 Hsu (2017)를 기반으로 더 향상된 NLOS 검출기법을 제시하였다. Cho et al. (2019)의 NLOS 검출기법은 시계열 데이터 학습에 특화된 인공신경망을 사용하며, 그 인공신경망의 입력으로 일정 연속 시간 동안의 SNR 값과 의사거리 측정치 변화량, 인공위성의 고도각을 사용하였다. 일반적으로 고도각은 낮을 수록 무선 신호가 건물이나 장애물과 충돌할 가능성이 높기 때문에, 일반적인 도심 환경에서는 NLOS 신호를 검출하기 위한 좋은 파라미터이다. 그러나, 고밀도 도심 환경에서는 매우 가파른 고도각을 가지는 인공위성을 제외하면 고도각에 상관없이 건물의 배치에 따라 종속적으로 전파 환경이 결정되기 때문에, 고도각으로는 NLOS 인공위성을 검출하기 어렵다. 의사거리는 LOS 전파 환경에서 그 변화량이 선형적으로 증가 또는 감소하지만 NLOS 전파 환경에서는 불규칙하게 변하는 경향을 보인다 (Cho et al. 2019). LOS 전파 환경의 경우 SNR은 인공위성과 수신기간 거리에 반비례하는 특성을 가지지만, NLOS 전파 환경에서는 주로 낮은 경향을 가진다. 그러나, 의사거리 변화량도 NLOS 신호 검출을 위해 참조할 수 있지만 NLOS 채널 환경으로 추정할 수 있는 결정적인 요인이 될 수 없다. 또한, CN_0 또는 SNR을 제외한 인공위성 측정치들은 수신기의 네비게이션 정보 추출 단계까지 완료되어야 추출이 가능하기 때문에 계산 효율이 떨어진다.

본 논문에서 제안하는 기법은 신호의 상관 출력을 이미지 특징 학습에 특화된 Convolutional Neural Network (CNN)의 일종인 VGGNet (Simonyan & Zisserman 2015)에 입력하여 NLOS 검출 유무를 판단하는 기법이다. 제안하는 기법에서 사용하는 네트워크는 Hsu (2017), Cho et al. (2019)와 같이 수신기에서 추출하는 SNR, 인공위성 위치, 의사거리와 같은 측정치를 사용하지 않고, 여러 시간에 걸쳐 적층 된 자기 상관 함수 ACF 출력을 입력받아 NLOS 채널 환경만이 가지는 ACF 출력의 특징을 학습한다. 본 논문에서 우리가 제안하는 기법은 다음과 같은 몇 가지 의의가 있다.

GNSS 신호 처리에서 가장 원천적인 출력인 상관 출력을 인공지능에 직접 사용하는 혁신적인 방법을 채택하였다.

기존에는 고려되지 않았던 신호 수집 시간에 대한 검출 성능을 분석하여 NLOS 검출을 위한 신호 수집 시간 선정에 대한 중요성을 제시한다.

우리는 실제 일반 및 고밀도 도심 환경에서 수집한 신호를 사용하여 연구의 실질성을 높였다.

2. 이산 ACF 출력

이번 절에서는 제안하는 기법의 입력인 이산 ACF 출력에 대한 수식적인 표현을 도출해 낸다. 본 논문에서는 다양한 GNSS 신호 중 대표적으로 GPS L1 C/A 신호를 기준으로 한다. GPS L1 C/A의 네비게이션 데이터 $D(t)$ 는 비트 구간인 $(l-1)T_b \leq t < lT_b$ 동안 1 또는 -1 값으로 일정하다. 본 논문에서 다루는 NLOS 검출 기법은 비트 구간보다 훨씬 짧은 구간 동안 수행되기 때문에 $D(t)$ 는 상수 $D(=1 \text{ 또는 } -1)$ 로 대체한다. Kong et al. (2022)에서 소개한 것과 같이, PRN 시퀀스에 의해 생성된 기저대역의 Binary phase-shift keying (BPSK) 신호 $y(t)$ 는 식 (1)과 같이 정의된다.

$$y(t) = D \sum_{k=-\infty}^{\infty} \sum_{n=0}^{N_{code}-1} c[n - kN_{code}] [u(t - nT_c - kT_p) - u(t - (n+1)T_c - kT_p)], \quad (1)$$

여기서 T_c 는 C/A 코드의 칩 구간이며 $0.98 \mu\text{sec}$ 이다. $c[n]$ 은 $N_{code}(=1023)$ 의 코드 길이를 가지는 이진 PRN 시퀀스의 $(n+1)$ 번째 코드 값이며, $u(t)$ 는 단위 계단 함수이다. $y(t)$ 는 T_p 의 주기를 가진다 (i.e., $T_p = N_{code} T_c$). 인공위성에서 방사되어 도시 영역의 다중경로 채널을 통과하는 $y(t)$ 는 식 (2)와 같이 $s(t)$ 로 변환되어 수신기에 도달한다.

$$s(t) = y(t) * h(t) + n(t), \quad (2)$$

여기서 $h(t)$ 는 시간 도메인의 채널 임펄스 응답으로 표현된 다중경로 채널을 나타낸다. $n(t)$ 은 양측파대 power spectral density $N_0/2$ 를 가지는 복소 additive white Gaussian noise (AWGN) 프로세스이다. '*'는 컨볼루션 연산이다.

수신기에서 ACF는 coherent 상관 구간 T_{corr} 동안의 수신 신호 $s_k(t)$ 와 수신기에서 생성한 레플리카 코드 신호 $C_R(t)$ 간의 상관 연산을 수행한다. 동위상 (in-phase)에서 정규화된 ACF 출력은 식 (3)과 같다.

$$R_{k-I}(\tau) = \frac{1}{T_{corr}} \int_0^{T_{corr}} s_k(t) c_R^*(t - \tau) dt, \quad (3)$$

여기서 $R_{k-I}(\tau)$ 는 $[kT_p, kT_p + T_{corr}]$ 동안의 수집신호에 대한 동위상의 정규화된 ACF 출력이다. $(\cdot)^*$ 은 복소 쉼레 함수이다. 그리고, 직교 위상 ACF 출력 $R_{k-Q}(\tau)$ 와 $R_{k-I}(\tau)$ 는 non-coherent integration 과정을 통해 $R_k(\tau)$ (i.e., $R_k(\tau) = \{R_{k-I}(\tau)\}^2 + \{R_{k-Q}(\tau)\}^2$)로 변환된다. 우리는 연속하는 ACF 출력을 NLOS 신호 분류기에 입력하기 위해 식 (4)와 같이 $R_k(\tau)$ 를 적층한다.

$$R_{1:N_{corr}}(\tau) = \text{concat}(R_1(\tau), R_2(\tau) \dots R_{N_{corr}}(\tau)), \quad (4)$$

여기서 N_{corr} 는 연속 시간을 가리키며 1 ms를 단위로 정수배를 가진다. $R_{1:N_{corr}}(\tau)$ 는 $[N_{corr} \times T_{corr}]$ 의 크기를 가지는 적층된 ACF 출력이며, 제안하는 NLOS 신호 분류기의 입력이다.

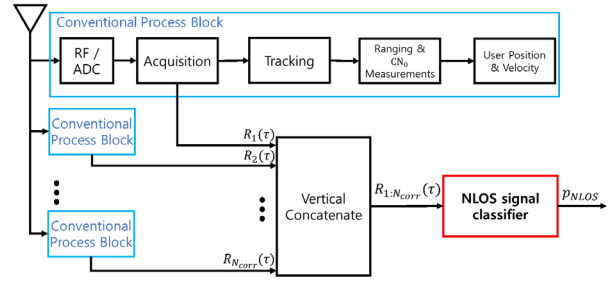


Fig. 4. An entire process using the proposed NLOS signal classifier.

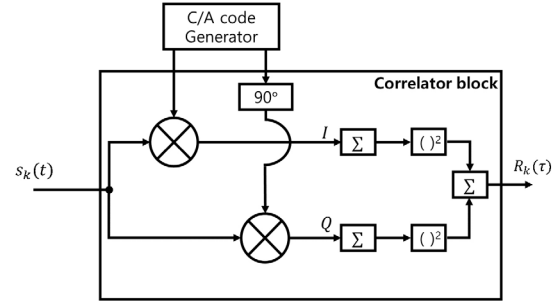


Fig. 5. Correlator block of acquisition block which outputs $R_k(t)$.

3. 제안하는 NLOS 신호 분류기

제안하는 검출 기법은 기존 GNSS 수신기의 Acquisition 단계에서 칩 지연에 따른 상관 출력만을 사용하여 구현 가능하기 때문에 수신기 구조를 크게 수정할 필요가 없다. Fig. 4는 우리가 제안하는 NLOS 신호 분류기가 반영된 GNSS 수신기의 블록 다이어그램이다. Fig. 4의 파란색 블록은 기존 GNSS 수신기 프로세스를 나타낸다. Fig. 4에 보여주는 것과 같이, Vertical concatenate 블록은 연속되는 시간에 따라 Fig. 5와 같이 기존 Acquisition 단계의 Correlator 블록에서 출력되는 N_{corr} 개의 $R_k(\tau)$ 를 입력 받아 식 (4)와 같은 과정으로 적층된 ACF 출력인 $R_{1:N_{corr}}(\tau)$ 을 출력한다. $R_{1:N_{corr}}(\tau)$ 는 $N_{corr} \times (\text{SPC} \cdot 1023)$ 사이즈의 행렬이며 제안하는 NLOS 신호 분류기의 입력으로 사용된다. 최종적으로 제안하는 NLOS 신호 분류기는 수신 신호가 NLOS 신호일 확률값 p_{NLOS} 을 출력한다.

제안하는 NLOS 신호 분류기는 Hsu (2017), Cho et al. (2019)와 다르게 신호처리의 가장 원초적인 ACF 출력을 인공지능의 입력으로 사용한다. 기존 GNSS 수신기는 측위 과정을 위해 ACF 출력에서 주엽 (main lobe)의 크기와 시간 지연 정보만으로 충분하다. 그런데, ACF 출력은 그 피크들로부터 다중 경로와 같은 전파 채널 환경을 유추할 수 있는 다양한 특징을 가지고 있다. Suzuki & Amano (2021)에서는 NLOS 신호를 분류하기 위해 연속되는 ACF 출력에서 주엽의 크기 및 시간 지연과 더불어 지역 피크들의 개수까지 고려하였다. 이러한 정보는 사실상 사람이 정의할 수 있는 ACF 출력의 특징이며, 원초적인 ACF 출력에서 많은 정보의 손실 가능성이 있다. 우리는 그 외에도 피크의 경사, 지역 피크 시간 지연, 노이즈 외 사람이 정의할 수 없는 특징까지 모두 포

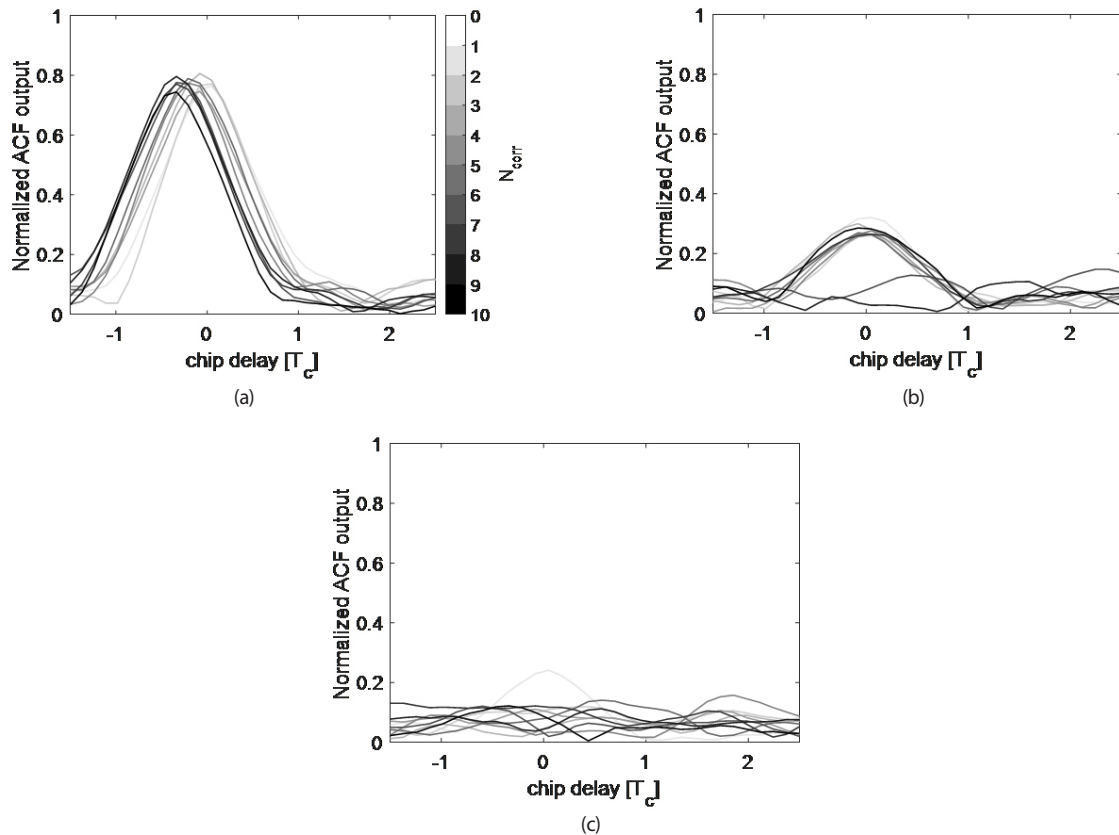


Fig. 6. Zoom of auto-correlation function output examples of (a) LOS, (b) weak NLOS and (c) strong NLOS channel environments.

함하는 ACF 출력을 인공지능의 입력으로 사용하여 전파 환경에 대한 정보를 최대한 특징 손실없이 인공지능이 학습할 수 있도록 설계하였다.

Fig. 6은 도시환경에서 10 ms 동안 (i.e., $N_{corr}=10$) 수집한 특정 하나의 GPS L1 인공위성의 신호를 기반으로 생성한 ACF 출력이다. Fig. 6은 최초 ACF 출력 $R_1(\tau)$ 의 피크가 가리키는 칩 지연을 기준으로 -1.5칩부터 2.5칩까지만을 보여준다. Fig. 6a는 건물에 가려지지 않은 LOS 인공위성에 대한 ACF 출력을 가리키고, Figs. 6b,c는 weak와 strong NLOS 인공위성에 대한 ACF 출력을 나타낸다. LOS 인공위성의 ACF 출력에서 삼각형 형태를 가지는 주엽의 크기는 일정하고 피크가 가리키는 칩의 지연은 0.3칩 내에서 균일하게 분포한다. Strong NLOS 인공위성에 대한 ACF 출력은 LOS 인공위성의 ACF 출력과 비교하여 삼각형의 주엽이 나타나지 않으며 대부분의 시간 지연에서 노이즈와 같은 크기를 가진다. 그런데, weak NLOS 인공위성의 ACF 출력은 Strong NLOS 채널 환경과 다르게 무선 신호가 반사되거나 굴절되어 신호가 수신되기 때문에 모든 연속시간에 삼각형의 주엽의 크기가 LOS 인공위성과 비교하여 그 크기가 매우 작으며, 경우에 따라 삼각형 주엽이 나타나지 않은 경우도 발생한다. 이러한 경우, NLOS 채널 환경임에도 불구하고 단일 측정치만을 사용하는 Hsu (2017)는 LOS 인공위성으로 검출할 가능성이 높다. 또한, ACF 출력에서 최대 피크의 정보 (크기 및 칩 지연)만을 사용하는 Suzuki & Amano (2021)는 주변 피크들을 전혀 고려하지 않기 때문에, 이러

한 weak NLOS 채널 환경에서 LOS 채널 환경으로 검출하는 오답이 발생할 수 있다.

Fig. 7은 제안하는 NLOS 신호 검출기의 입력인 $R_{1:N_{corr}}(\tau)$ 을 보여주며, Figs. 7a,c,e는 각각 LOS, weak/strong NLOS 인공위성에 대한 $R_{1:N_{corr}}(\tau)$ 이다. -Figs.7a,b의 $R_{1:N_{corr}}(\tau)$ 는 선명하게 특정 칩 지연에 높은 크기를 가진다는 것을 확인할 수 있다. 이것은 수신 신호가 LOS 신호일 경우 시간이 지나감에도 무선 신호가 거의 같은 시간 지연에서 도달한다는 것을 의미한다. 그러나, Figs. 7c,d의 weak NLOS 신호는 LOS 신호의 ACF 출력과 유사하지만, 간헐적으로 피크가 가리키는 칩 딜레이가 크게 변하는 것을 확인할 수 있다. Figs. 7e,f의 strong NLOS 신호는 Fig. 6c에서 확인한 것과 같이 모든 출력이 노이즈의 크기와 같다. 따라서, 제안하는 NLOS 신호 분류기는 전체 칩 지연에 대한 연속적인 피크 정보들을 한번에 입력 받기 때문에, 시간에 따른 피크의 특징과 전체 칩 지연에 대한 ACF 출력정보를 학습할 수 있다.

Fig. 8은 제안하는 NLOS 신호 분류기에서 사용하는 네트워크 구조를 보여준다. 제안 하는 NLOS 분류기에서 사용하는 네트워크는 CNN 중 일반적으로 다양한 task에서 뛰어난 성능을 보이는 VGGNet의 축소된 구조를 가진다. VGGNet은 커널 사이즈가 3×3으로 고정된 CNN의 일종이다. 일반적으로 layer의 깊이에 따라 VGG16 또는 VGG19로 불리지만, 저가형 수신기 적용을 고려하면 기존 VGGNet은 계산량이 불필요하게 매우 많기 때문에 Fig. 8과 같이 layer의 개수를 크게 줄였다. 제안하는 NLOS 신호 분류

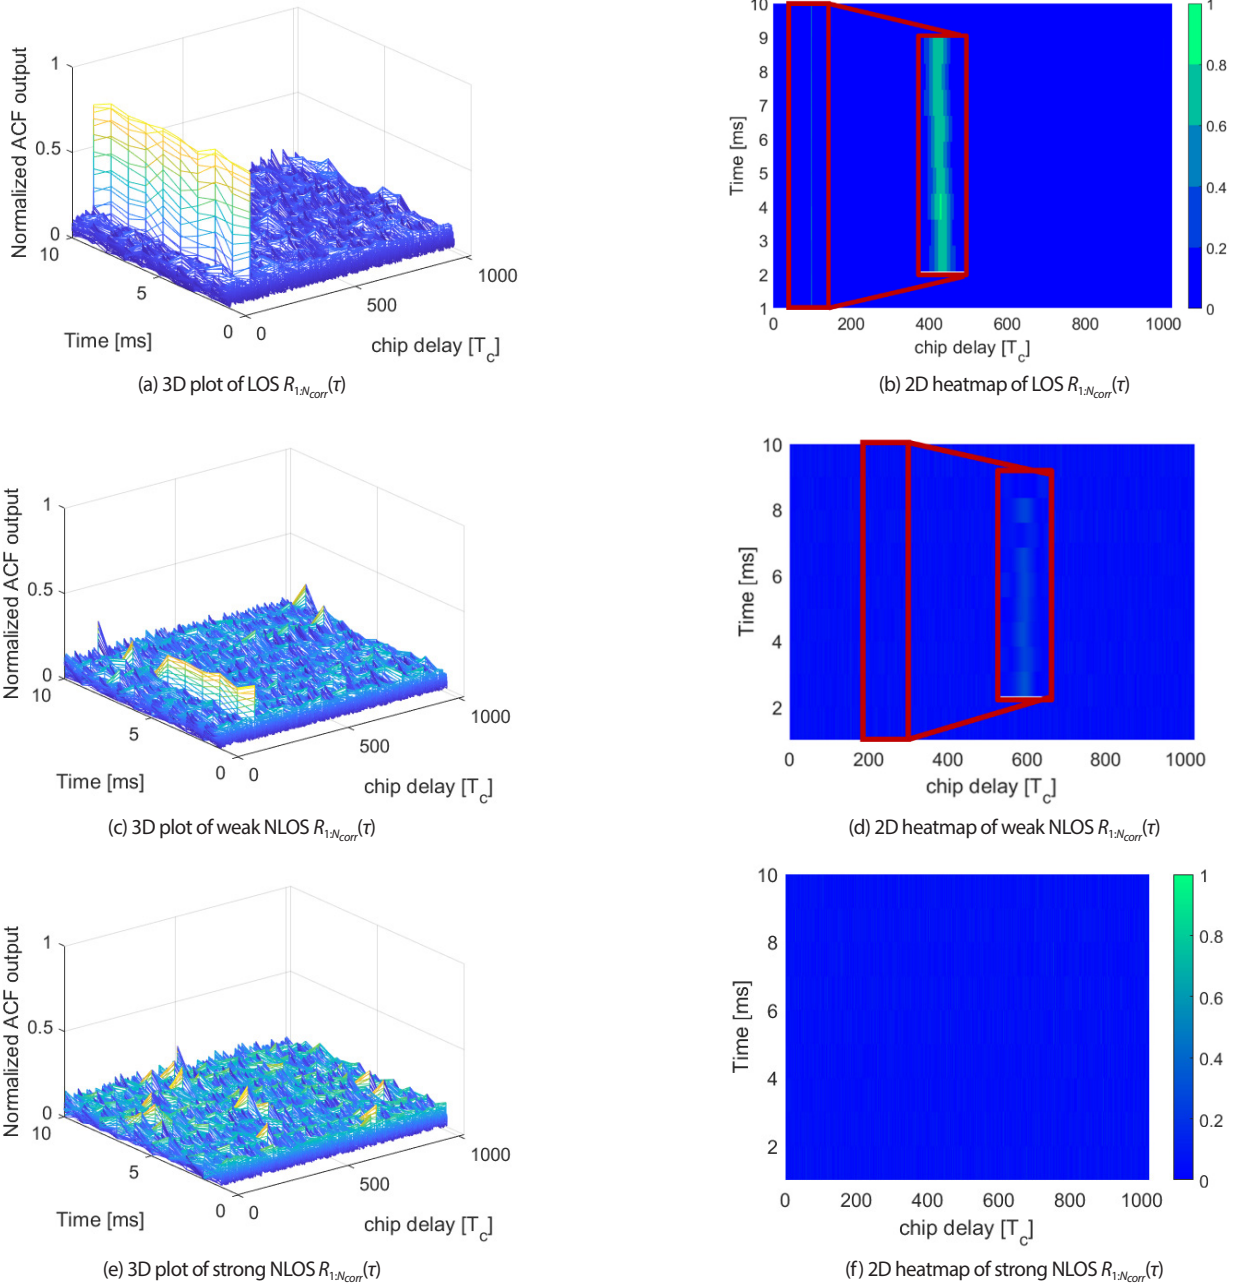


Fig. 7. auto-correlation function output examples with 3D plots and 2D heatmaps.




Fig. 8. Proposed NLOS detector structure.

기의 입력은 일반적인 CNN과 달리 정사각행렬이 아니지만, 컨볼루션 연산과정에서 zero-padding을 통해 feature 손실 없이 VGGNet의 커널을 온전히 사용할 수 있다.

성능 비교를 위해 Cho et al. (2019)에서 제시한 것과 동일하게 N_{corr} 개의 ACF 출력들을 입력으로 하는 두 종류의 multi-layer perceptron (MLP)를 사용한다. Fig. 9는 제안하는 NLOS 신호 검출기와 비교하는 네트워크들을 보여준다. 본 논문에서 비교하는 MLP는 직렬형과 병렬형으로 구분된다. Fig. 9a의 직렬형 MLP는 ACF 출력들을 벡터로 입력 받아 p_{NLOS} 를 출력한다. Fig. 9b의 병렬형 MLP는 T_{corr} 동안의 각 ACF 출력 $R_k(\tau)$ 을 병렬로 인코딩한 뒤

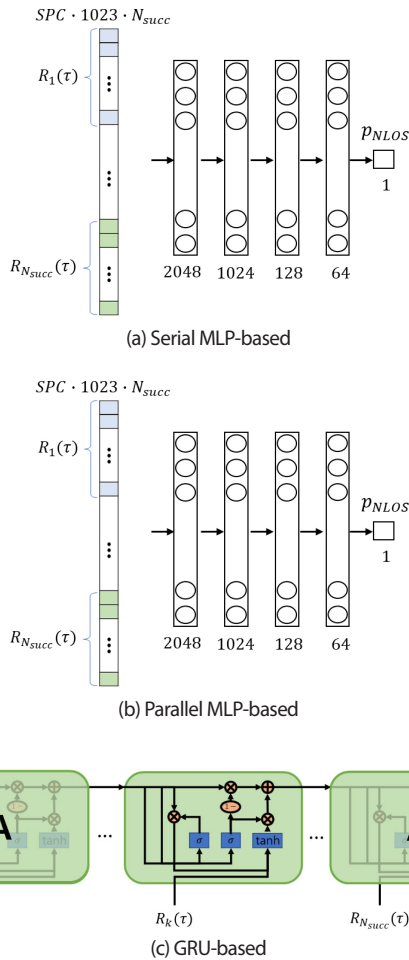


Fig. 9. MLP other NLOS signal classifier.

에 출력되는 feature를 모두 더하고 두 개의 layer를 통과한 뒤에 p_{NLOS} 를 출력한다.


추가적으로, Fig. 9c와 같이 연속되는 시간에 따른 NLOS/LOS 신호를 분류하는 문제를 위해 Cho et al. (2014)에서 제시한 신경망인 Gated Recurrent Unit (GRU)를 사용한다. GRU는 순환적 구조를 가진 신경망인 Recurrent Neural Network (RNN) 중 계산 부하가 적고 성능이 뛰어나며 충분히 입증된 순환 신경망으로서, 우리가 사용하는 GRU는 Fig. 9c에는 표현하지 않았지만 hidden layer의 차원을 4092로 고정하였다. 공정한 비교를 위해, 모든 네트워크들에 동일하게 활성화 함수로 ReLU를 사용하고 학습을 위한 최적화 알고리즘으로는 Adam optimizer를 채택하였다. 직렬형 MLP (약 1000만개)를 제외한 모든 네트워크는 사용 파라미터의 개수가 약 26만개이다. 따라서, 본 논문에서는 동일한 연속시간에 따른 ACF 출력들을 인공지능의 입력으로 사용하기 위해 적절한 입력의 형태와 네트워크의 구조를 비교한다.

4. 실험 결과


이번 장에서 제안하는 NLOS 신호 분류기의 우수성을 입증하



(a) Open sky



(b) Urban (Building height < 40m)



(c) Dense urban (Building height >= 40 m)

Fig. 10. GPS signal reception environments.

기 위해, 실험적인 결과를 다룬다. 4.1절에서 GNSS 무선 신호 수집 장소 및 실험 환경에 대해 소개한다. 그리고, 4.2절에서 인공지능 학습에 앞서 수집되는 신호에 대해 NLOS와 LOS를 구분할 수 있는 Ground Truth Annotation 과정에 대해 소개한다. 4.3절에서 수집되는 신호와 레이블을 기반으로 하는 제안하는 NLOS 신호 분류기를 측정치 기반의 MLP 및 GRU 기반 NLOS 신호 분류기와 학습 성능을 분석한다. 마지막으로 4.4절에서는 학습 데이터가 아닌 테스트 데이터로 다른 NLOS 신호 분류기의 분류 성능을 비교하여 제안하는 NLOS 신호 분류기의 우수성을 입증한다.

4.1 실험 환경

제안하는 NLOS 신호 분류기는 실제 환경에서 수집한 GNSS 무선신호를 기반으로 네트워크 학습 및 테스트가 수행된다. 우리는 일반적인 GNSS 측위 상황을 고려하여 Fig. 10과 같이 서로 다른 시간과 3개의 지역 (개활지 환경, 도심 환경, 고밀도 도심환




Fig. 11. NLOSAREA NLOS/LOS area generation process from cut off elevation and skyplot. (a) building boundary definition, (b) 3D map based on GIS, (c) the generated NLOS/LOS area in skyplot.

경)에서 신호 수집을 수행하였다. 신호 수집은 샘플링 주파수가 8 MHz인 SiGe GN3S Sampler v3를 사용하여 각 15분씩 GNSS 무선 신호 샘플을 수집하였다. 그리고, 모든 수식적인 실험은 64 GB의 물리적 메모리와 함께 3.5 GHz I9-11900K CPU의 PC에서 수행되었다. 또한, 제안하는 기법에 사용되는 인공지능의 학습은 Nvidia의 RTX 3070에서 수행되었다.

4.2 데이터 주석화

인공지능 학습을 위한 데이터 주석화 (data annotation)는 인공위성의 고도각과 방위각, 그리고 3D 공간정보시스템 (Geographic Information System, GIS)을 기반으로 자동적으로 수행된다. Fig. 11a와 같이, Hsu (2017)와 Cho et al. (2019)에서 수행한 방법과 동일하게 건물 옥상의 경계면과 수신기간 고도각을 컷오프각으로 정의하여, 컷오프각을 기준으로 LOS/NLOS 영역을 구분하였다. Fig. 11c는 Fig. 11b에서 보여지는 3D GIS를 활용하여 생성한 skyplot이다. 파란색 영역은 건물의 외벽에 가려지지 않는 LOS 영역이며 반대로 붉은색 영역은 NLOS 영역을 가리킨다. 우리는 수신기와 통신하는 인공위성들의 고도각 및 방위각을 추출한 뒤에, GIS 기반으로 생성된 컷오프각과 비교하여 신호 데이터들을 주석화했다. (i.e., NLOS는 1, LOS는 0으로 선정). 따라서, 본 논문에서 비교하는 모든 인공지능의 출력은 입력 신호가 NLOS 신호일 확률 p_{NLOS} 를 출력하도록 학습하였다.

4.3 네트워크 학습 성능 비교

이번 절에서는 N_{corr} 에 따른 제안하는 NLOS 신호 분류기 학습 성능과 직/병렬 MLP 및 GRU 기반 NLOS 신호 분류기의 학습 성능을 비교 분석한다. 우리는 총 20,000개의 샘플에 대하여 90% (18,000 샘플)는 Training 데이터 셋으로 구분하고 나머지 10% (2,000 샘플)는 Validation 데이터 셋으로 구분하여 학습을 수행하였다. 데이터 셋 내에서 LOS 신호는 약 35%를 차지하고 나머지는 NLOS 신호에 해당한다. 네트워크 학습은 총 30 에포크 동안 수행되었다. Fig. 12는 N_{corr} 가 4, 6, 8, 10에 따라 서로 다르게 설계된 제안하는 NLOS 신호 분류기와 직/병렬 MLP, 그리고 GRU

기반의 NLOS 신호 분류기의 학습 결과를 보여준다. 우리는 학습 결과를 Validation 데이터 셋에서의 LOS/NLOS 신호 구분의 정확도로 보여준다. Fig. 12d와 같이, 제안하는 NLOS 신호 분류기는 N_{corr} 가 4인 경우의 training과 validation에서 가장 저조한 검출 정확도를 보여주었다. 그리고 N_{corr} 가 길어질수록 training 성능과 validation 성능이 함께 증가하는 것을 보여준다. 이는 연속 시간이 길어질수록 NLOS 또는 LOS 채널 환경을 유추할 수 있는 기준이 더욱 명확해진다는 것을 의미한다. 하지만, 제안하는 NLOS 신호 분류기를 제외한 나머지 NLOS 신호 분류기는 전반적으로 N_{corr} 이 증가해도, 성능이 개선되지 않고, 오히려 성능이 저하되는 경우도 있다. 이는, 제안하는 NLOS 신호 분류기는 Figs. 7c,d의 weak-NLOS 신호의 특징과 같이 데이터 내의 지역 특징을 잘 학습할 수 있는 반면, 다른 NLOS 신호 분류기들은 ACF 출력의 지역 특징을 학습하지 못했다는 것을 의미한다. 추가적으로, MLP 네트워크 중 직렬형보다 병렬형 MLP가 학습 성능이 더 좋은 것은 병렬형 MLP가 각각의 $R_k(r)$ 를 나누어 인코딩하였기 때문에, 지역 특징을 조금 더 학습했다는 것을 의미한다.

4.4 테스트 데이터에 따른 분류 성능 비교

이번 절에서는 테스트 데이터로 제안하는 NLOS 신호 분류기를 MLP와 RNN 기반 NLOS 신호 분류기와 분류 성능을 비교한다. 우리는 학습 데이터 환경과 다른 새로운 장소에서 수집한 약 1,000개의 데이터로 테스트를 수행하였다. 또한, 3.3절과 동일하게 여러 N_{corr} 에 따른 분류 성능을 비교하였다. Table 1은 제안하는 NLOS 신호 분류기와 다른 네트워크들의 NLOS 신호 분류 성능 결과이다. Fig. 12의 경향과 같이 제안하는 NLOS 신호 분류기는 전반적으로 연속 시간이 증가하면서 분류 성능은 증가하는 것을 보여준다. 하지만, 다른 네트워크기반의 NLOS 신호 분류기들은 Figs. 12a-c와 같이 N_{corr} 과 무관한 경향을 보여주며, 매우 저조한 성능을 보여준다. 이러한 결과들로 보아, 원초적인 ACF 출력으로 NLOS 신호를 분류하기 위해서는 데이터의 지역적인 특징까지 잘 학습할 수 있는 CNN 계열의 네트워크가 일반적으로 적합한 네트워크라는 것을 의미한다.

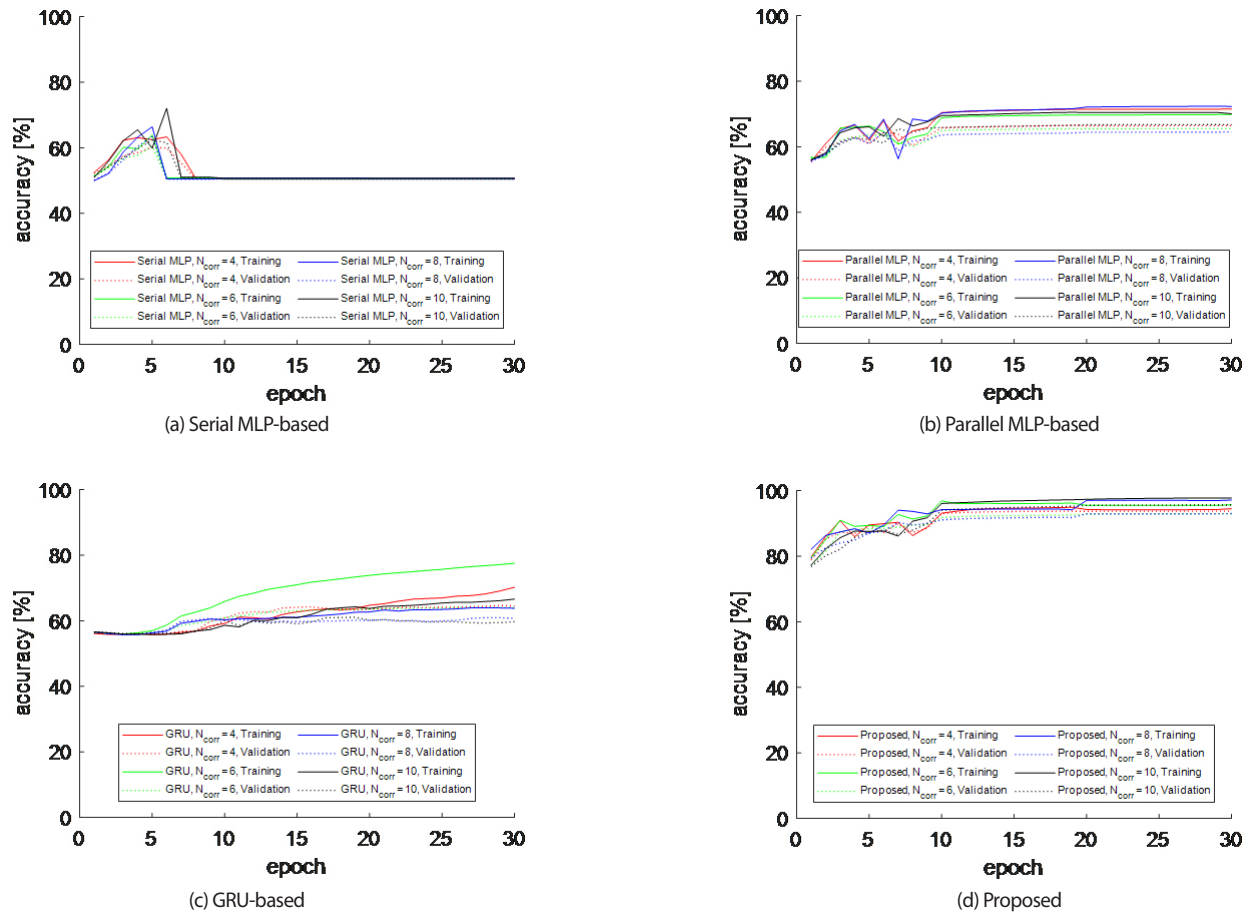


Fig. 12. Training performance comparison of NLOS signal classifiers according to N_{corr} .

Table 1. NLOS signal classifier performance comparison on test data.

	Serial MLP-based (%)	Parallel MLP-based (%)	GRU-based (%)	Proposed NLOS signal classifier (%)
4	50.0	66.2	61.2	90.4
6	50.0	64.7	59.2	92.5
8	50.0	56.3	63.4	94.6
10	50.0	62.0	66.1	97.2

5. CONCLUSIONS

본 논문에서 우리는 GNSS 신호 처리의 가장 원시적 출력인 ACF 출력을 사용하여 도시지역에서 발생하는 NLOS 신호를 분류하는 기술을 제안하였다. 제안하는 분류기는 연속하는 ACF 출력을 적응하여 LOS/NLOS 채널 환경이 가지는 ACF 출력의 시계열 특징을 학습한다. 제안하는 NLOS 신호 분류기는 모든 수신기에서 동일하게 추출할 수 있는 ACF 출력을 기반하기 때문에, 네비게이션 데이터 추출 이전에 NLOS 신호를 분류할 수 있다. 제안하는 NLOS 신호 분류기의 우수성을 입증하기 위하여, 다양한 네트워크기반의 NLOS 분류기와 성능을 비교하였다. 그 결과, 제안하는 NLOS 신호 분류기는 비교하는 다른 분류기들 중 가장 뛰어난 검출 성능을 보였다. 결과적으로 제안하는 NLOS 신호 분류기가 매우 정확하고 효율적임을 입증하였다.

AUTHOR CONTRIBUTIONS

Conceptualization, S.C.; methodology, S.C.; software, S.C.; validation, S.C.; formal analysis, S.C., J.K.; investigation, S.C.; resources, S.C.; data curation, S.C.; writing—original draft preparation, S.C. and J.K.; writing—review and editing, J.K.; visualization, S.J.; supervision, S.J.

CONFLICTS OF INTEREST

The authors declare no conflict of interest.

REFERENCES

Cho, K. H., van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., et al. 2014, Learning phrase representations using RNN encoder-decoder for statistical machine

translation, In Conference on Empirical Methods in Natural Language Processing, Doha, Qatar, 26-28 Oct 2014. <https://doi.org/10.48550/arXiv.1406.1078>

- Cho, S. J., Kim, B. S., Kim, T. S., & Kong, S. H. 2019, Enhancing GNSS performance and detection of road crossing in urban area using deep learning, IEEE Intelligent Transportation Systems Conference, Auckland, New Zealand, 27-30 Oct 2019, pp.2115-2120. <https://doi.org/10.1109/ITSC.2019.8917224>
- Groves, P. D. 2011, Shadow matching: A new GNSS positioning technique for urban canyons, The journal of Navigation, 64, 417-430. <https://doi.org/10.1017/S0373463311000087>
- Hsu, L. T. 2017, GNSS multipath detection using a machine learning approach, IEEE 20th International Conference on Intelligent Transportation Systems, Yokohama, Japan, 16-19 Oct 2017, pp.1-6. <https://doi.org/10.1109/ITSC.2017.8317700>
- Irish, A. T., Isaacs, J. T., Quitin, F., Hespanha, J. P., & Madhow, U. 2014, Belief propagation based localization and mapping using sparsely sampled GNSS SNR measurements, IEEE international conference on robotics and automation, Hong Kong, China, 31 May-7 June 2014, pp.1977-1982. <https://doi.org/10.1109/ICRA.2014.6907121>
- Kaplan, E. D. & Hegarty, C. J. 2017, Understanding GPS Principles and Applications (Norwood, MA: Artech House).
- Kong, S. H., Cho, S., & Kim, E. 2022, GPS First Path Detection Network based on MLP-Mixers, IEEE Transactions on Wireless Communications, 21, 7764-7777. <https://doi.org/10.1109/TWC.2022.3161457>
- Lee, Y. & Park, B. 2022, Nonlinear Regression-Based GNSS Multipath Modelling in Deep Urban Area, Mathematics, 10, 412. <https://doi.org/10.3390/math10030412>
- Nunes, F. D., Sousa, F. M., & Leitão, J. M. 2019, Characterization and performance analysis of generalized BOC modulations for GNSS, Navigation, 66, 185-197. <https://doi.org/10.1002/navi.279>
- Simonyan, K. & Zisserman, A. 2015, Very deep convolutional networks for large-scale image recognition, International Conference on Learning Representations, San Diego, CA, 7-9 May 2015. <https://doi.org/10.48550/arXiv.1409.1556>
- Suzuki, T. & Amano, Y. 2021, NLOS multipath classification of GNSS signal correlation output using machine learning, Sensors, 21, 2503. <https://doi.org/10.3390/s21072503>
- Van Dierendonck, A. J., Fenton, P., & Ford, T. 1992, Theory and Performance of Narrow Correlator Spacing in a GPS Receiver, Navigation, 39, 265-283. <https://doi.org/10.1002/j.2161-4296.1992.tb02276.x>
- Yao, Z. & Lu, M. 2017, Signal multiplexing techniques for GNSS: the principle, progress, and challenges within a uniform framework, IEEE Signal Processing Magazine, 34, 16-26. <https://doi.org/10.1109/MSP.2017.2713882>
- Yu, K., Sharp, I., & Guo, Y. J. 2009, Ground-based wireless positioning (New Jersey: John Wiley & Sons). <https://doi.org/10.1002/9780470747988>
- Zhang, G., Icking, L., Hsu, L. T., & Schön, S. 2021, A Study on Multipath Spatial Correlation for GNSS Collaborative Positioning, In Proceedings of the 34th International Technical Meeting of the Satellite Division of The Institute of Navigation (ION GNSS+ 2021), St. Louis, Missouri, 20-24 Sept 2021, pp.2430-2444. <https://doi.org/10.33012/2021.17942>



Sangjae Cho received the B.S. degree in Department of Energy and Electrical Engineering from Korea Polytechnic University, Korea, in 2018 and M.S. degree in Graduate School of Mobility from Korea Advanced Institute of Science and Technology (KAIST), where he is currently pursuing the Ph.D. degree. His research interests include GNSS, Signal processing, Deep learning, Autonomous vehicle, and Wireless communication.



Jeong-Hoon Kim received a B.S. degree in Computer Science and Engineering from Konkuk University, Korea in 2022. He is currently a Master's student in the CCS Graduate School of Mobility of Korea Advanced Institute of Science and Technology (KAIST). His research interests include Autonomous vehicle and GNSS.