

<https://doi.org/10.7236/JIIBC.2024.24.6.63>  
JIIBC 2024-6-10

# GPS 음영 지역에서 측위 성능 개선을 위한 CNN-GRU 기반 GPS/INS 융합 측위 시스템

## A GPS/INS Integrated Positioning System Based on CNN-GRU Model to Improve Positioning Performance in GPS Shaded Areas

이민규\*, 황병선\*, 김수현\*, 선준호\*, 김정호\*, 김진욱\*, 김진영\*\*

Min-Gyu Lee\*, Byungsun Hwang\*, Soo Hyun Kim\*, Joonho Seon\*,  
Jeongho Kim\*, Jinwook Kim\*, Jin-Young Kim\*\*

**요약** 측위 기술은 자율주행과 UAV 등 실시간으로 이동하는 이동체의 안전한 운영을 위해 필수적으로 적용되는 기술이다. GPS와 INS를 결합한 기존 융합 측위 시스템은 높은 정확도를 제공하지만, GPS 음영지역에서는 INS 센서의 오차 누적 문제로 인해 측위 성능이 저하되는 문제가 있다. 이를 해결하기 위해 본 논문에서는 CNN-GRU 기반 GPS/INS 융합 측위 시스템을 제안한다. 본 논문에서 제안한 시스템은 음영지역에서 CNN-GRU 모델을 통해 이동체 위치를 예측하고 예측값을 Kalman filter에 입력하여 GPS 음영지역에서도 높은 정확도로 위치를 추정한다. 제안된 모델 성능 검증을 위해 NCLT (North Campus Long-Term) 데이터셋으로 학습 및 시뮬레이션을 진행하였으며, 실험 결과 제안된 측위 시스템은 기존 Kalman filter만을 이용한 측위 결과의 오차보다 음영 지역에서 최대 83.3% 감소한 측위 오차를 얻었다.

**Abstract** Positioning technology is essential for the safe operation of moving objects in real-time, such as autonomous vehicles and UAVs. While traditional GPS/INS fusion positioning systems offer high accuracy, their performance degrades in GPS shadow zone due to the error accumulation problem of the INS. To address this issue, a GPS/INS fusion positioning system based on CNN-GRU is proposed in this paper. The proposed system predicts the position of the moving object in GPS shadow zone using a CNN-GRU model and inputs the predicted values into a Kalman filter to estimate the position with high accuracy even in GPS shadow zone. In order to validate the performance of the proposed model, training and simulations were performed on the North Campus Long-Term (NCLT) dataset. Experimental results show that the proposed positioning system reduced the positioning error in GPS shadow zones by up to 83.3% compared to the positioning results using only the traditional Kalman filter.

**Key Words** : CNN-GRU, Kalman filter, Positioning, Localization, GPS shadow zone

\*준회원, 광운대학교 전자융합공학과

\*\*정회원, 광운대학교 전자융합공학과, 교신저자

접수일자 2024년 8월 28일, 수정완료 2024년 11월 8일

계재확정일자 2024년 12월 6일

Received: 28 August, 2024 / Revised: 8 November, 2024 /

Accepted: 6 December, 2024

\*\*Corresponding Author: jinyoung@kw.ac.kr

Dept. of Electronic Convergence Engineering, Kwangwoon University, Korea

## I. 서 론

측위 기술은 위치 기반 서비스를 바탕으로 하는 자율 주행, 내비게이션 등 다양한 분야에서 활용되고 있다<sup>[1]</sup>. 이동체의 위치를 추정하기 위해서는 다양한 접근법이 있으며, 일반적으로 위성항법시스템 (Global Positioning System, GPS), 관성항법시스템 (Inertial Navigation System, INS), 카메라, LIDAR (Light Detection And Ranging), RADAR (Radio Detection And Ranging) 등의 센서를 통해 수집한 정보를 기반으로 위치 추정이 이루어진다. 위치 정보를 수집하기 위해 대표적으로 사용되는 GPS 센서는 최소 3개의 위성과 LOS (Line of Sight) 상태가 보장되는 환경에서 높은 정확도를 보장하기 때문에 널리 이용되고 있다<sup>[2]</sup>. 그러나 GPS 신호는 터널과 도심지 환경과 같이 위성과의 통신이 제한되는 음영 지역에서 GPS 수집 신호의 불안정성으로 인하여 측위 오차가 크게 발생한다<sup>[3]</sup>. 음영 지역에서 이동체의 위치 정보를 수집하는 과정에서 GPS 신호가 갖는 한계를 극복하기 위한 보조 방안으로 이동체에 직접 부착된 INS 센서가 활용된다<sup>[4]</sup>.

INS는 관성측정장치 (Inertial Measurement Unit, IMU)가 측정한 이동체의 관성 정보를 통해 이동체의 이동 거리를 추정하는 항법 시스템이다. INS는 x, y, z축 방향의 가속도계와 자이로스코프로 데이터를 특징하는 IMU로 구성되어 이동체의 운동 및 자세 데이터를 산출하며, 산출된 데이터를 바탕으로 위치를 추정한다. 그러나 INS 센서에서 수집한 데이터는 잡음이 존재하며, INS 센서로 수집되는 데이터의 잡음은 시간이 지날수록 누적되어 이동체의 이동 거리 추정 결과값에 큰 오차를 초래하는 문제점이 있다<sup>[5]</sup>. 이동체의 위치 추정 결과값의 오차를 보정하기 위해 일반적으로 Kalman filter 알고리즘이 사용된다. Kalman filter 알고리즘은 GPS 신호를 이용하여 INS의 오차 누적을 보정하고, INS 신호는 GPS 신호가 약해지거나 차단되었을 때 단기적으로 위치 추정을 수행한다<sup>[6]</sup>. GPS 음영지역에서 Kalman filter 기반 GPS/INS 융합 측위 시스템은 GPS 신호 사용이 제한되므로, INS 신호만을 이용하기 때문에 음영 구간에 장기간 지속된다면 이동체의 위치 추정 정확도는 음영 구간에 비례하여 낮아지게 된다<sup>[7]</sup>.

음영 구간에서 GPS/INS 융합 측위 시스템을 장시간 운용하면서 발생하는 INS의 오차 누적 문제를 해결하기 위한 방안으로 2가지 접근법이 제시되고 있다<sup>[3]</sup>. 첫째는 카메라, LIDAR, RADAR 등 추가적인 센서를 사용하는

것이다. 이는 측위 정보를 수집하기 위한 부가적인 센서들의 요구로 인한 비용이 발생하는 한계가 있다. 둘째는 인공지능 모델 기반 Kalman filter의 추정 오류를 보정하는 방법이다. 인공지능을 이용한 접근법은 주로 역전파 신경망 (Back Propagation Neural Network, BPNN)을 사용하여 추정 데이터와 실제 데이터 간의 오류 보정이 이루어진다. Kalman filter의 성능은 비선형 시스템을 불안정하게 모델링하는 등의 이유로 저하될 수 있는데<sup>[8]</sup> BPNN은 비선형적 시스템에서 입력과 출력의 관계성을 모델링하는데 장점이 있다. 그러나 BPNN은 현재 시점의 데이터만을 이용하여 예측을 수행하기 때문에 시계열 데이터의 특성을 고려하지 않는다<sup>[9]</sup>. 따라서 시간적 패턴을 학습할 수 있는 순환 신경망을 이용해 센서 데이터의 시간적 특징을 추출할 필요성이 있다.

본 논문에서는 음영지역 환경에서 측위 성능을 개선하기 위해 CNN-GRU 기반 GPS/INS 융합 측위 시스템을 제안한다. 제안된 시스템은 이동체의 GPS, IMU, wheel encoder 데이터를 CNN-GRU 모델과 Kalman filter를 통해 이동체의 위치 추정이 이루어진다. Wheel encoder는 이동체의 바퀴에 장착되어 각 바퀴의 속도를 측정하며, 측정된 데이터를 통해 이동체의 속도를 추정한다. CNN-GRU 모델은 시계열 데이터의 시간적 특성을 추출하여 다음 스텝을 예측하는 데 최적화된 모델로<sup>[10]</sup> IMU, INS 데이터와 wheel encoder 데이터를 입력으로 하여 이동체의 변위량을 예측하도록 훈련한다. GPS 음영 지역에서는 모델이 예측한 변위량을 Kalman filter의 입력으로 사용하여 GPS 음영지역에서 개선된 성능의 측위 시스템을 구현하였다.

본 논문의 구성은 다음과 같다. II장에서는 제안한 모델을 구성하는 Kalman filter와 CNN, GRU를 소개한다. III장에서는 본 논문에서 제안한 시스템을 설명하며, IV장에서는 NCLT (North Campus Long-Term) 데이터셋을 활용하여 제안 시스템의 성능 검증을 수행하였다. 마지막으로 V장에서 결론을 짓는다.

## II. 관련 이론

### 1. Kalman filter

Kalman filter는 시간에 따라 선형적으로 변하는 시스템의 상태를 추정하는 알고리즘이며, 관측값에 존재하는 잡음을 재귀적 기법으로 보정하여 선형 시스템의 상태를 추정하는데 주로 사용된다.

Kalman filter는 예측 단계와 갱신 단계로 구성되며, 예측 단계에서는 이전 단계에서의 상태와 물리 법칙에 기반한 상태 전이 행렬을 사용하여, 현재의 상태를 예측한다. 각 시점의 상태를 이루는 상태 변수들끼리의 관계는 공분산 행렬로 나타낼 수 있으며 현재 시점의 공분산 행렬은 상태 전이 행렬과 이전 시점의 공분산 행렬, 상태 전이 행렬을 전치한 행렬과의 행렬 곱으로 나타낸다.

그림 1은 Kalman filter의 동작을 블록 다이어그램으로 나타낸 것이다. 식(1), (2)는 예측 단계에서 시스템 상태와 오차 공분산 행렬을 예측하는 수식이다.

$$\hat{x}_k^- = A\hat{x}_{k-1}, \quad (1)$$

$$P_k^- = AP_{k-1}A^T + Q \quad (2)$$

위 식에서  $A$ 는 상태 전이 행렬,  $\hat{x}_k^-$ 는 시점  $k$ 에서의 예측된 상태,  $\hat{x}_{k-1}$ 은 시점  $k-1$ 에서의 시스템 상태를 의미한다. 일반적으로 시스템은 외부 물리력에 의해 불확실성이 존재한다. 따라서 공분산 행렬을 예측할 때, 외력에 의한 불확실성을 고려하여 예측한다.  $P_k^-$ 는 현재 시점  $k$ 의 예측된 오차 공분산 행렬,  $Q$ 는 외부로부터의 불확실성을 반영하는 공분산 행렬을 의미한다.

갱신 단계에서는 보정 계수인 칼만 이득을 구하여 최적의 추정값을 얻는다. 칼만 이득은 추정값과 측정값의 불확실성을 기반으로 결정되며, 칼만 이득을 통해 최적화된 상태와 오차 공분산 행렬을 얻을 수 있다. 식 (3), (4), (5)는 갱신 단계에서 칼만 이득을 구하고 칼만 이득을 기반으로 최적의 시스템 상태를 추정하는 식이다.

$$K_k = P_k^- H^T (HP_k^- H^T + R)^{-1}, \quad (3)$$

$$\hat{x}_k = \hat{x}_k^- + K_k(z_k - H\hat{x}_k^-), \quad (4)$$

$$P_k = P_k^- - K_k HP_k^-. \quad (5)$$

위 식에서  $K_k$ 는 시점  $k$ 에서의 칼만 이득을 의미하며,  $H$ 는 관측 모델 행렬로 센서로부터 얻은 관측값과 상태 변수들의 관계를 나타낸다.

## 2. CNN

CNN은 영상 데이터를 분석하는데 주로 사용되는 딥러닝 모델이다. CNN은 컨볼루션 레이어, 풀링 레이어, FC (Fully Connected) 레이어로 구성되며, 영상 데이터의 공간적, 시간적 상관관계 특징을 추출한다.

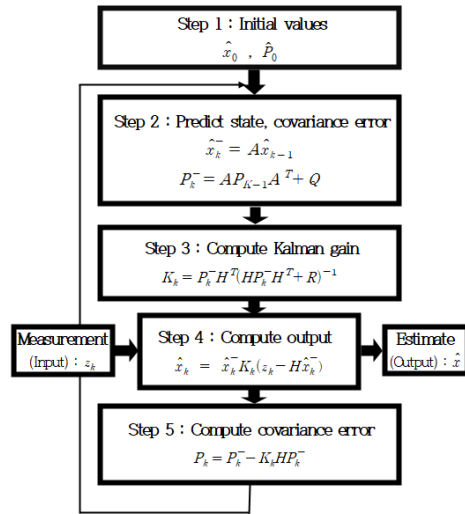


그림 1. Kalman filter의 block diagram.  
 Fig. 1. Block diagram of Kalman filter.

컨볼루션 레이어는 FC 레이어와 달리 일정 영역에 대하여 가중치를 공유하는 2차원 필터를 사용하여 학습 시 이미지 데이터의 공간적 특징을 고려하면서 상대적으로 적은 수의 파라미터를 사용하기 때문에 학습 속도가 빠르다.

CNN 모델은 시계열 데이터를 분석하기 위한 방법으로 1D-CNN 모델과 2D-CNN 모델이 주로 사용된다. 2D-CNN 모델을 통한 시계열 분석 방법은 1차원 데이터로 구성된 시계열 데이터를 2차원 데이터로 변환시키는 전처리 과정이 필요하며, 모델 학습 과정에서 계산 복잡도가 높아진다. 반면, 1D-CNN 모델은 1차원 컨볼루션 필터를 사용하기 때문에 2D-CNN 모델을 사용하는 것보다 별도의 전처리 과정이 없어 계산 복잡도가 낮은 장점이 있다<sup>[11,12]}</sup>.




그림 2. 1D-CNN의 모델 구조.  
 Fig. 2. Model structure of 1D-CNN.

이동체의 위치 정보 수집과 연관된 센서 데이터는 대부분 1차원 시계열 데이터로 구성되며, 본 연구에서는 IMU 센서와 wheel encoder의 데이터의 특징을 추출하기 위해 1D-CNN 모델을 사용하였다. 그림 2는 1차원 시계열 데이터를 입력받는 1D-CNN의 모델 구조를 나타낸다.

### 3. GRU

RNN 모델은 이전 상태의 은닉층 출력을 현재 상태의 입력값으로 하는 피드백 구조의 딥러닝 모델이다. RNN을 비롯한 피드백 형태의 모델들은 시계열 데이터를 효과적으로 처리할 수 있다. 그러나, RNN은 시계열 데이터가 길어질수록 초반에 입력된 정보가 잊혀지는 gradient vanishing 현상이 존재한다<sup>[8]</sup>. RNN 모델이 갖는 문제를 해결하기 위해 LSTM 모델이 제안되었다.

LSTM 모델은 RNN과 동일한 피드백 구조에 망각 게이트를 추가하여 RNN 모델이 갖는 gradient vanishing 문제를 개선하였으나, 추가되는 망각 게이트로 인하여 모델의 연산 복잡도가 높다는 한계가 있다.

GRU 모델은 RNN 계열의 모델 중 하나로 LSTM 모델과 구조가 유사하지만, LSTM 모델 대비 간결한 구조로 설계되어 모델의 학습 속도가 개선되었다<sup>[13]</sup>. GRU는 갱신 게이트와 리셋 게이트로 구성되며, 갱신 게이트에서는 이전 은닉층의 정보를 반영할 비율을 결정하여 중요한 정보를 장기적으로 유지할 수 있도록 한다. 리셋 게이트는 이전의 은닉층의 정보를 무시할 비율을 결정하여 불필요한 정보를 제거한다.

## III. 시스템 모델

본 논문에서는 음영 지역에서 GPS 신호가 갖는 한계를 극복하기 위한 GPS/INS 융합 센싱 시스템을 제안한다.

제안된 시스템 모델은 INS와 CNN-GRU 모델, linear Kalman filter로 구성되며, GPS가 정상적으로 동작하는 경우와 GPS 신호가 제한되는 경우로 나누어 동작한다. 그림 3은 GPS 신호가 정상적으로 동작할 때 제안하는 측위 시스템의 동작을 보여준다. GPS 신호가 정상적으로 동작할 경우, wheel encoder와 IMU 센서로부터 취득한 데이터를 INS의 입력값으로 하여 속도, 자세, 위치정보를 출력한다. GPS 신호로 수집한 측위 정보와 INS가 출력한 속도, 자세, 위치정보는 Kalman filter에 입력되어 이동체의 현재위치를 추정한다.

CNN-GRU 모델은 음영 지역에서 이동체의 위치를 추정하기 위해 비음영 지역에서 수집된 wheel encoder와 IMU 데이터를 통해 사전 학습이 이루어진다.




그림 3. 비 음영지역에서의 CNN-GRU 기반 GPS/INS 융합 센싱 시스템 구조도.

Fig. 3. Structure of the CNN-GRU based GPS/INS fusion sensing system in GPS unshadow zone.

그림 4는 음영 지역에서 GPS 신호 수집에 한계가 있는 조건에서의 시스템 동작을 보여준다. Wheel encoder와 IMU 센서는 GPS 신호와 달리 음영 지역에서 센서 정보 수집이 가능하므로, 그림 3에서 사전 학습된 CNN-GRU 모델에서 도출한 위치 추정값을 Kalman filter에 입력한다.




그림 4. GPS 음영 지역에서의 CNN-GRU 기반 GPS/INS 융합 센싱 시스템 구조도.

Fig. 4. Structure of the CNN-GRU based GPS/INS fusion sensing system in GPS shadow zone.

본 논문에서 제안한 CNN-GRU 모델은 비음영 지역에서 wheel encoder로부터 취득한 이동체의 중심 속도  $V_{center}$ , IMU로부터 취득한 Heading 데이터  $\psi_{IMU}$ , INS가 추정한 위치 데이터  $P_{INS}$ 를 통해 이동체의 위치  $\Delta P_{GPS}$ 를 추정하며, 추정된  $\Delta P_{GPS}$ 은 GPS 신호로부터 수집된  $P_{GPS}$ 와의 오차값이 최소화되도록 학습이 이루어진다.

그림 5는 본 논문에서 제안한 CNN-GRU 모델의 구조이다. CNN-GRU 모델의 입력 데이터는 직렬로 연결된 3개의 1D-CNN과 풀링 레이어로 구성된 컨볼루션 레이어를 통과하여 512 X 1 크기의 특징맵으로 추출된다. 추출된 특징맵은 wheel encoder, IMU 센서로부터 취득한 데이터 간의 관계를 포함한다.

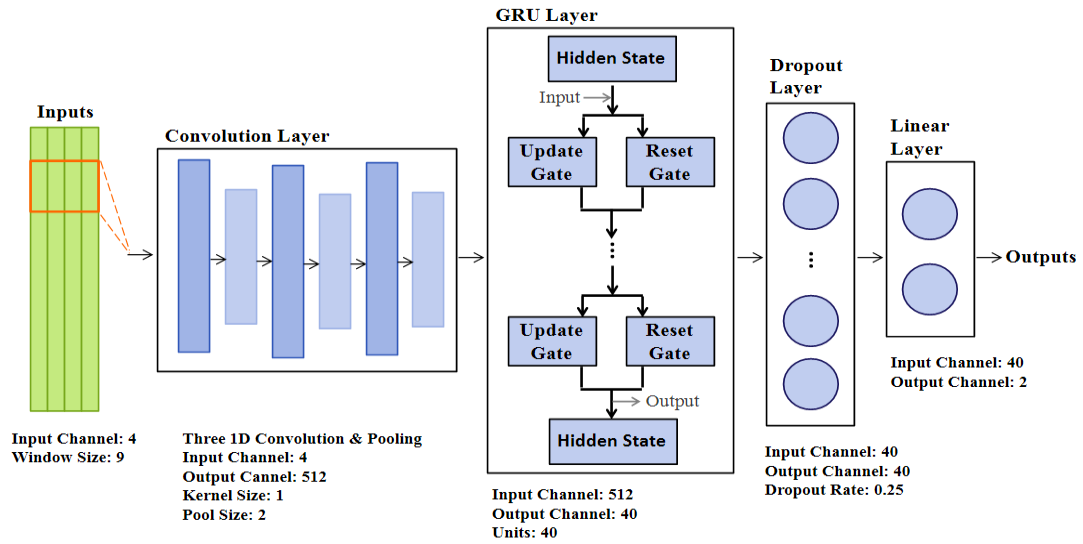


그림 5. CNN-GRU 모델 구조.  
 Fig. 5. Architecture of CNN-GRU model.

GRU layer에서는 특징맵의 시간적 의존성을 학습하여 40 채널을 출력한다. GPU layer에서 출력된 특징값들은 이후 dropout layer와 linear layer를 통해 x축 및 y축 방향으로의 위치변화량을 출력한다.

#### IV. 모의실험 및 결과분석

##### 1. 실험 개요

본 연구에서는 제안된 CNN-GRU 모델을 학습시키기 위해 NCLT 데이터셋을 사용했다. 데이터셋은 GPS, IMU, wheels 등 세그웨이 (Segway) 로봇에 장착된 센서들로 15개월 간 미시간 대학교 북부 캠퍼스에서 수집되었다. 그림 6은 2012년 3월 25일 수집된 데이터를 지도에 가시화한 것이다. 그림 6의 Outage #1과 Outage #2는 시뮬레이션 환경에서의 GPS 음영 지역을 의미한다. 본 논문에서 제안한 모델의 성능을 검증하기 위해 Outage #1과 Outage #2에서 IMU만을 이용한 위치 추정, Kalman filter를 사용한 위치 추정 기법과 본 논문에서 제안한 CNN-GRU 모델의 성능을 비교하였다.

성능 평가를 위한 정량적 지표로 시스템의 추정값과 실제 위치값 사이 평균 제곱근 오차 (Root Mean Squared Error, RMSE)와 음영 구간 중 최대 위치 오차 거리를 사용하였다.

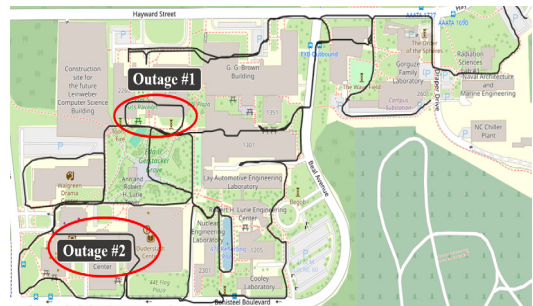


그림 6. 시뮬레이션 환경.  
 Fig. 6. Simulation environment.

##### 2. 데이터 전처리

GPS 데이터에는 수신되는 GPS 신호의 품질을 판단하는 기준인 fix 값이 존재한다. Fix 값이 3 이상이면 GPS 수신기가 최소 4개의 위성으로부터 신호를 수신하여 정확한 위치정보를 얻은 것으로 판단한다. Fix 값이 2 이하 구간에서는 신뢰도가 낮은 것으로 판단하여 GPS 신호, IMU 데이터, wheel encoder 데이터를 GPS 데이터와 같은 구간의 데이터만 남겨 학습 데이터로 사용하였다.

##### 3. 실험 결과 분석

그림 7과 표 1에서 INS만을 이용해 Outage #1에서의 이동체 경로를 추정한 결과, 북쪽으로 최대 319.14m,

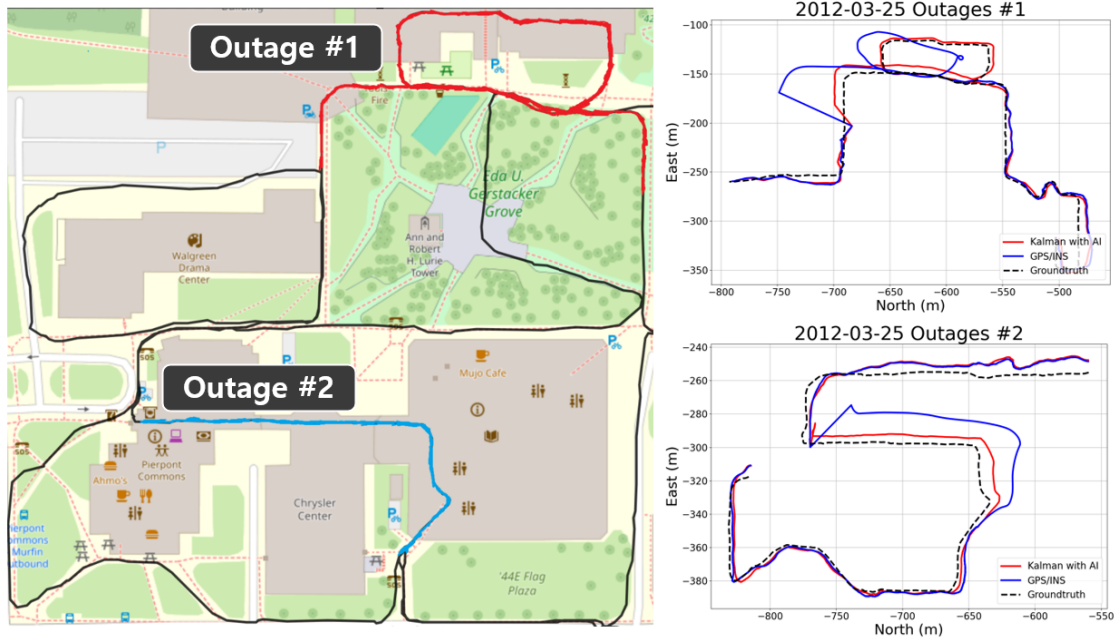


그림 7. 구간 1, 구간 2에서의 실험 결과.  
Fig. 7. Experimental results from section 1 and section 2.

동쪽으로 최대 544.93m의 큰 오차를 보였다. Kalman filter로 보정한 경우 북쪽으로 최대 57.62m, 동쪽으로 최대 21.19m의 오차를 보였으며 본 논문에서 제안한 CNN-GRU 모델은 북쪽으로 최대 9.63m, 동쪽으로 최대 13.83m의 오차값을 얻어 INS와 Kalman filter 방식 대비 오차가 낮은 것을 확인하였다. 측위 오차값은 제안한 측위 시스템이 Kalman filter만을 이용한 측위 방식 대비 북쪽 방향에서 최대 83.3%, 동쪽 방향에서 최대 34.7% 감소하였음을 확인하였다. Outage #2 경로에서의 실험 결과 제안한 측위 시스템이 Kalman filter만을 이용한 측위 방식보다 북쪽 방향에서 최대 64.1%, 동쪽 방향에서 최대 74.0% 감소한 측위 오차값을 얻었다.

표 1. Outage #1, #2에서의 RMSE, Max Position Error.  
Table 1. RMSE, Max Position Error in Outage #1, #2.

		RMSE (m)		Max Position Error (m)	
		North	East	North	East
#1	Pure INS	282.79	524.97	319.14	544.93
	Kalman Filter	26.64	7.39	57.62	21.19
	KF + CNN-GRU	3.93	4.86	9.63	13.83
#2	Pure INS	327.97	679.89	363.40	693.76
	Kalman Filter	36.99	10.82	54.00	18.75
	KF + CNN-GRU	11.80	3.62	19.39	4.87

## V. 결론

본 논문에서는 GPS 음영 지역에서 개선된 측위 성능을 위한 CNN-GRU 기반의 GPS/INS 융합 측위 시스템을 제안했다. 제안한 시스템은 CNN-GRU 모델을 사용하여 이동체의 속도, 자세와 위치 사이의 비선형적 관계를 학습하여 GPS 음영지역에서 이동체의 변위를 예측한다. 최종적으로 예측한 위치와 INS의 추정값을 보정하여 음영 지역에서 정밀한 위치추정을 수행한다. NCLT 데이터셋으로 시뮬레이션한 결과 제안한 측위 시스템은 GPS 음영 지역에서 기존의 Kalman filter만을 이용한 방식보다 측위 오차가 최대 83.3% 감소한 정확도로 이동체의 위치를 추정했음을 확인했다. 제안한 측위 시스템은 GPS 음영 지역에서 운용되는 이동체에 적용되어 정밀한 위치 기반 서비스를 제공할 수 있을 것으로 기대한다.

## References

- [1] J. Bressler, P. Reisdorf, M. Obst, and G. Wanielik, "GNSS Positioning in Non-Line-of-Sight Context—A Survey," in 2016 IEEE 19th International Conference on Intelligent Transportation Systems (ITSC), Rio de Janeiro, Brazil: IEEE, pp. 1147–1154, Nov. 2016.



DOI: <https://doi.org/10.1109/ITSC.2016.7795701>.

- [2] J. Liu and G. Guo, "Vehicle Localization During GPS Outages with Extended Kalman Filter and Deep Learning," IEEE Trans. Instrum. Meas., Vol. 70, pp. 1-10, Jul. 2021.  
 DOI: <https://doi.org/10.1109/TIM.2021.3097401>.
- [3] E. Zhang and N. Masoud, "Increasing GPS Localization Accuracy with Reinforcement Learning," IEEE Trans. Intell. Transport. Syst., Vol. 22, No. 5, pp. 2615-2626, May 2021.  
 DOI: <https://doi.org/10.1109/TITS.2020.2972409>.
- [4] P. Srinivas and A. Kumar, "Overview of Architecture for GPS-INS Integration," 2017 Recent Developments in Control, Automation & Power Engineering (RDCAPE), Noida, India, pp. 433-438, Oct 2017.  
 DOI: <https://doi.org/10.1109/RDCAPE.2017.8358310>.
- [5] M. Narasimhappa, A. D. Mahindrakar, V. C. Guizilini, M. H. Terra, and S. L. Sabat, "MEMS-Based IMU Drift Minimization: Sage Husa Adaptive Robust Kalman Filtering," IEEE Sens. J., Vol. 20, No. 1, pp. 250-260, Jan. 2020.  
 DOI: <https://doi.org/10.1109/JSEN.2019.2941273>.
- [6] Y. Kwon, "GPS/INS Fusion Using Multiple Compensation Method Based on Kalman Filter," IEIE, Vol. 52, No. 5, pp. 190-196, May 2015.  
 DOI: <https://doi.org/10.5573/ieie.2015.52.5.190>.
- [7] Y. Liu, Q. Luo, and Y. Zhou, "Deep Learning-Enabled Fusion to Bridge GPS Outages for INS/GPS Integrated Navigation," IEEE Sens. J., Vol. 22, No. 9, pp. 8974-8985, May 2022.  
 DOI: <https://doi.org/10.1109/JSEN.2022.3155166>.
- [8] J. Gonzalez and W. Yu, "Non-Linear System Modeling Using LSTM Neural Networks," IFAC-PapersOnLine, Vol. 51, No. 13, pp. 485-489, 2018.  
 DOI: <https://doi.org/10.1016/j.ifacol.2018.07.326>.
- [9] S. Kim, I. Petrunin, and H.-S. Shin, "A Review of Kalman Filter with Artificial Intelligence Techniques," in 2022 Integrated Communication, Navigation and Surveillance Conference (ICNS), Dulles, VA, USA: IEEE, pp. 1-12, Apr. 2022.  
 DOI: <https://doi.org/10.1109/ICNS54818.2022.9771520>.
- [10] M. Sajjad et al., "A Novel CNN-GRU-Based Hybrid Approach for Short-Term Residential Load Forecasting," IEEE Access, Vol. 8, pp. 143759-143768, Jul. 2020.  
 DOI: <https://doi.org/10.1109/ACCESS.2020.3009537>.
- [11] A. Khan, A. Sohail, U. Zahoor, and A. S. Qureshi, "A Survey of the Recent Architectures of Deep Convolutional Neural Networks," Artif Intell Rev, Vol. 53, No. 8, pp. 5455-5516, Dec. 2020.  
 DOI: <https://doi.org/10.1007/s10462-020-09825-6>.
- [12] S. M. Shahid, S. Ko, and S. Kwon, "Performance Comparison of 1D and 2D Convolutional Neural Networks for Real-Time Classification of Time Series Sensor Data," in 2022 International Conference on Information Networking (ICOIN), Jeju-si, Korea,

Republic of: IEEE, pp. 507-511, Jan. 2022.

DOI: <https://doi.org/10.1109/ICOIN53446.2022.9687284>.

- [13] J. Chung, C. Gulcehre, K. Cho, and Y. Bengio, "Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling," Dec. 2014.  
 DOI: <http://arxiv.org/abs/1412.3555>

## 저 자 소 개

### 이 민 규(준회원)



- 2019년 3월 ~ 현재 : 광운대학교 전자융합공학 학사 재학
- 관심분야 : 인공지능, 영상처리, 측위 시스템

### 황 병 선(준회원)



- 2023년 2월 : 광운대학교 전자융합공학 학사 졸업
- 2023년 3월 ~ 현재 : 광운대학교 전자융합공학과 석박사통합과정
- 관심분야 : 측위 시스템, 인공지능, 무선통신시스템

### 김 수 현(준회원)



- 2019년 2월 : 광운대학교 전자융합공학과 졸업
- 2019년 3월 ~ 현재 : 광운대학교 전자융합공학과 석박사통합과정
- 관심분야 : 차세대이동통신, 인공지능, 스마트 그리드

### 선 준 호(준회원)



- 2021년 2월 : 광운대학교 전자융합공학 학사 졸업
- 2021년 3월 ~ 현재 : 광운대학교 전자융합공학과 석박사통합과정
- 관심분야 : 딥러닝, 이상 탐지, 스마트 그리드, 위성통신

김 정 호(준회원)



- 2023년 2월 : 광운대학교 전자융합공학 학사 졸업
- 2023년 3월 ~ 현재 : 광운대학교 전자융합공학과 석박사통합과정
- 관심분야 : 인공지능, 무선통신시스템

김 진 욱(준회원)



- 2023년 2월 : 광운대학교 전자융합공학 학사 졸업
- 2023년 3월 ~ 현재 : 광운대학교 전자융합공학과 석박사통합과정
- 관심분야 : 딥러닝, 무선통신시스템, 시맨틱통신시스템

김 진 영(정회원)



- 1998년 2월 : 서울대학교 전자공학과 공학박사
- 2001년 2월 : SK텔레콤 네트워크 연구소 책임연구원
- 2001년 3월 ~ 현재 : 광운대학교 전자융합공학과 교수
- 관심분야 : 인공지능, 차세대이동통신, 전력선통신, 가시광통신, 무선 측위 시스템

※ 이 논문은 2022년도 정부(방위사업청)의 재원으로 국방기술진흥연구소의 지원을 받아 수행된 연구임  
(No. 20-302-H00-002(KRIT-CT-22-070), 비레이저 기반 차세대 마일즈 개발)