

심층 학습을 이용한 인공위성 광학 관측 데이터의 궤도결정 정밀도 향상

Improving Orbit Determination Precision of Satellite Optical Observation Data Using Deep Learning

윤현만·김찬호·최인수·이성섭*

세종대학교 우주항공시스템공학부

Hyeon-man Yun · Chan-Ho Kim · In-Soo Choi · Soung-Sub Lee*

Department of Aerospace Systems Engineering, Sejong University, Seoul 050061, Korea

[요 약]

본 논문에서는 관측소에서 위성을 관측할 때 나오는 광학 관측 데이터인 각도 정보를 통해 A.I 기법 중 하나인 심층 학습을 적용하여 관측소에서 위성까지의 거리 정보를 학습시켜 거리 정보를 예측하게 만들어 위성의 궤도결정 정밀도를 높였다. 이를 위해 GMAT에서 관측 데이터를 생성하고, 생성된 관측 데이터를 전처리 과정을 통해 심층 학습의 학습 데이터 오차를 줄였으며, MATLAB을 통해 심층 학습을 진행하였다. 학습을 통해 나온 예측된 거리 정보를 토대로 궤도결정의 필터링 기법 중 하나인 확장 칼만 필터를 GMAT을 통해 사용하여 궤도결정을 실시 하였다. 거리 정보가 없는 각도 정보를 가지고 한 궤도결정과 모델을 통해 나온 예측된 거리 정보가 있는 궤도결정 결과를 비교 분석하여 모델의 신뢰성을 검증하였으며, 실제 관측 데이터를 기반으로 결과를 비교 분석하여 궤도결정의 정밀도가 향상됨을 보여준다.

[Abstract]

In this paper, by applying deep learning, one of the A.I. techniques, through angle information, which is optical observation data generated when observing satellites at observatories, distance information from observatories is learned to predict range data, thereby increasing the precision of satellite's orbit determination. To this end, we generated observational data from GMAT, reduced the learning data error of deep learning through preprocessing of the generated observational data, and conducted deep learning through MATLAB. Based on the predicted distance information from learning, trajectory determination was performed using an extended Kalman filter, one of the filtering techniques for trajectory determination, through GMAT. The reliability of the model was verified by comparing and analyzing the orbital determination with angular information without distance information and the orbital determination result with predicted distance information from the model.

Key word : Deep learning, Observation data, Orbit determination, Optical observation, Range prediction.

<http://dx.doi.org/10.12673/jant.2024.28.3.262>



This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

Received 9 May 2024; Revised 26 June 2024

Accepted (Publication) 28 June 2024 (30 June 2024)

*Corresponding Author; Soung-Sub Lee

Tel: +82-2-2209-3671

E-mail: biscoprop@naver.com

I. 서 론

최근 몇 년 동안, 우주상황인식(SSA; space situational awareness) 분야의 중요성이 증가하고 있다. 이는 우주가 더 이상 먼 곳의 대상이 아닌, 현대 생활에 필수적인 자원과 공간으로 자리 잡았기 때문이다. 위성 통신, GPS 서비스 등이 일상생활의 필수 요소가 되면서 우주 공간은 점점 더 붐비게 되었고 현재 수천 개의 위성과 우주에서 운용되는 다양한 기기들이 지구 궤도를 돌고 있다. 이와 동시에, 사용되지 않는 위성, 로켓의 일부, 그리고 다양한 크기의 우주 쓰레기가 우주 공간을 가득 메우고 있다. 지구 궤도에는 10cm보다 큰 물체가 36,000개 이상, 더 작은 조각은 수백만 개 이상 존재하는 것으로 추정된다 [1].

이러한 배경하에, 우주상황인식은 우주자산을 보호하고, 우주 활동의 안전성과 지속 가능성을 보장하는 데 필수적인 역할을 하게 되었다. 국제적으로도, 우주상황인식의 중요성은 더욱 강조되고 있으며, 여러 국가와 기관이 우주상황인식 정보의 공유와 협력을 증진하기 위한 노력을 기울이고 있다.

한반도의 경우 우주상황인식을 위해 우주를 관측할 때 대한민국 공군의 우주자산인 EOSS(전자광학위성감시체계, electro optical satellite system) 및 한국천문연구원의 OWL-Net(우주물체 전자광학 감시시스템, optical wide field patrol network)이 있다. 두 시스템은 광학 관측을 통한 관측소와 위성과의 각도 정보를 얻을 수 있는데, 관측소와 위성과의 거리 정보는 얻을 수 없다.

우주상황인식을 위해선 관측된 위성의 궤도결정 또한 중요한데 위성 및 우주 물체의 궤도결정을 위해서는 어떤 관측 데이터를 기반으로 궤도를 결정하는지가 중요하다. 궤도결정(OD; orbit determination) 방법을 구분하자면 CSPOC에서 제공하는 공개된 정보인 TLE(two-line element)를 기반으로 궤도를 결정하는 방법과 GPS 데이터 및 SLR(satellite laser ranging)을 활용한 정밀궤도결정(POD; precise orbit determination) 방법이 있으며, 마지막으로 광학 관측 데이터를 기반으로 하는 궤도결정 방법이 있다. 본 논문은 한반도 상황에 맞는 광학 관측 데이터 기반의 궤도결정 방법을 기준으로 궤도결정 정밀도 향상 방안을 연구하였다.

광학 관측은 관측소에서 위성을 관측할 때 나오는 각도 정보인 Azimuth angle, Elevation angle을 통해 궤도결정을 사용한다. 본 논문에서는 AI기법을 활용하여 관측소와 위성까지의 거리 정보를 학습 및 예측하게 만드는 모델을 제작하였고, 이 모델을 통해 궤도결정 정밀도를 향상 시켰다. NASA에서 제공하는 우주 임무 분석 소프트웨어인 GMAT 및 공학용 애플리케이션 소프트웨어인 MATLAB을 활용하였으며 최종적으로 실제 광학 관측 정보를 통해 모델을 검증하였다. 그 후 TLE 정보를 기준으로 STK(satellite tool kit) 시뮬레이션 결과 비교를 통해 궤도결정 정밀도 향상 가능성을 확인하였다.

II. 관측 데이터

AI기법 중 심층 학습을 통해 광학 관측 데이터인 각도 정보로 거리 정보를 예측하기 위해서는 학습에 필요한 관측 데이터를 생성하는 절차가 우선적으로 실행되어야 한다. 본 절에서는 이러한 관측 데이터 생성 및 전처리 과정을 분석한다.

2-1 관측 데이터 생성

NASA에서 제공하는 우주 임무 분석 소프트웨어인 GMAT을 활용하여 가상의 관측 데이터를 생성하였는데, 관측 위성의 초기 정보는 타겟 위성의 TLE 정보에서 추출한 정보를 사용하였으며 타겟 위성은 Cosmos-2503, Yaogan-35, Skymed-3, Kompsat-5, Ariane-40이다[2]. 생성할 가상의 환경은 그림 1과 같으며, 관측소는 한반도 기준으로 생성하였고 각 관측소의 Angle noise sigma는 0.05, Range noise sigma는 1e-05로 설정하였으며 관측 시간은 하루 동안 시간 간격은 10초로 설정하여 가상의 관측 데이터를 생성하게 했다.

Force model은 단순한 환경으로 다른 영향도를 고려하지 않은 JGM-2로 모델링 했으며, Propagator로는 고도의 정밀도와 긴 시간 간격에 걸친 안정적인 수치 해석이 요구되는 상황에서 우수한 성능을 발휘하는 Rungekutta 89를 사용하였다[3]. 또한 한반도의 지리적 및 환경적 특성을 고려하여, 지평선 근처의 관측을 방해할 수 있는 지형적 장애물과 대기 굴절, 그리고 광해의 영향을 최소화하기 위해 고도 각(Elevation angle) 제약을 기존의 관측소에 비해 상대적으로 높은 15도 이상으로 설정하였다.

최종적으로 GMAT으로 생성된 가상의 관측 데이터는 각 타겟 위성마다 2,000개의 데이터 세트를 생성하였으며, 각 데이터 세트에 하루 기준 10초 간격으로 Azimuth angle, Elevation angle, Range data를 저장하게 했다.

2-2 관측 데이터 전처리

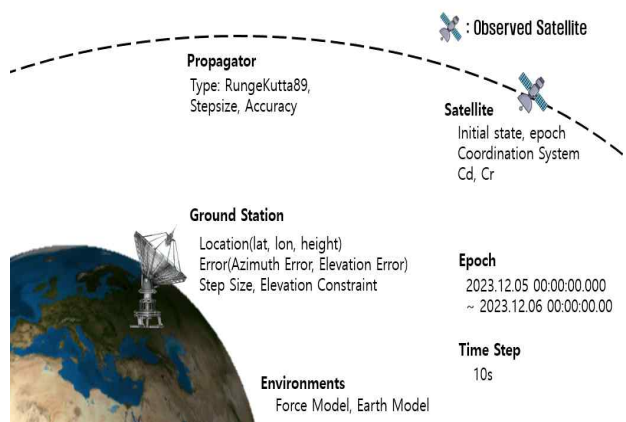


그림 1. GMAT 프로그램 환경
Fig. 1. GMAT program environment.

생성된 가상의 관측 데이터를 심층 학습에 사용하기 위해 데이터 전처리 과정이 필요하다. 본 논문에서는 MATLAB을 통해 심층 학습을 가동하게 시키므로 GMAT에서 나온 가상의 관측 데이터를 mat 파일로 변환하는 과정이 필요하다. 이 과정에서 학습에 사용할 데이터를 구분시켜 Azimuth angle, Elevation angle을 Xdata, Range data는 Ydata로 구분하여 mat 파일로 저장하였다.

Azimuth angle과 Elevation angle을 그대로 학습에 사용하게 되면 각도 오차 및 각도의 특성을 학습에 적용하기 어려우므로 2가지 방법을 사용하여 각도 오차를 감소하였다.

첫 번째 방법으로는 LOS(line of sight) vector 특성을 적용하였다. LOS 벡터인 \hat{L} 은 관측소에서 천체를 향하는 방향 벡터로 이는 천체의 적경(right ascension, α)과 적위(declination, δ)을 사용하여 정의되며, 천체의 위치 또는 위성의 위치를 천구 좌표계에서 정확하게 결정하는 데 사용된다[4].

$$\hat{L} = \begin{bmatrix} \cos\delta \cos\alpha \\ \cos\delta \sin\alpha \\ \sin\delta \end{bmatrix} \quad (1)$$

$$\vec{r} = \rho \hat{L} + \vec{r}_{site} \quad (2)$$

LOS 벡터는 위의 식과 같으며 \vec{r} 은 지구 중심 관성(ECI; earth centered inertial) 좌표계에서의 위성의 위치 벡터이며, ρ 는 관측소와 위성까지의 거리 정보이다. 이 특성을 적용하여 Azimuth angle과 Elevation angle에 삼각함수인 sin, cos을 적용하였다.

두 번째 방법으로는 생성된 가상의 관측 데이터는 10초 간격이므로 1초 간격의 각속도(Angle rate)는 시간에 따른 위성의 위치 변화를 더 정밀하게 이해할 수 있게 만들기 때문에 4가지 절차를 통해 각속도를 계산하였다. 첫 번째로 각도 정보를 관측 경로(Path)별로 분류한다. 두 번째, 스플라인 보간법(Interpolation)을 사용하여 1초 간격으로 데이터를 세분화한다. 세 번째, 1초 간격의 데이터의 각속도 값을 계산한다. 네 번째, 분석의 일관성을 유지하기 위해, 1초 간격으로 계산된 각속도 값을 다시 10초 간격으로 원복하여 최종 데이터 세트가 원본 데이터와 동일한 시간 간격을 가지도록 한다.

두 방법을 통하여 학습에 들어갈 각도 정보는 총 6개의 정보로 전처리 과정을 통해 들어가며, 이와 같은 데이터의 세밀한 처리와 분석을 통해 각도 오차 감소 및 보다 정밀한 거리 정보 예측 모델이 생성된다.

III. A.I 모델 생성

본 절에서는 여러 A.I 기법 중 관측 데이터의 특성상 시계열 형식을 가지므로 심층 학습을 활용하여 모델을 생성한다.

3-1 심층 학습 과정

전처리 과정을 통해 나온 6개의 입력 정보를 통해 AI 기법을 적용하여 거리 정보를 예측할 수 있는 심층 학습 모델을 MATLAB을 통하여 만든다. 여러 가지 심층 학습 기법 중 본 연구는 Bi-LSTM(bidirectional long short term memory)과 GRU(gated recurrent unit)를 사용하여 모델을 만들었다.

Bi-LSTM과 GRU는 각각 다른 방식으로 시퀀스 데이터의 학습 문제를 해결하기 위해 설계된 순환 신경망(RNN; recurrent neural networks)의 변형이다[5],[6]. 이 두 모델은 시계열 데이터나 시퀀스 데이터의 학습에 있어서 RNN이 가지고 있는 단점을 보완하며, 특히 장기 의존성 문제를 해결하는 데 효과적이다 [7].

Bi-LSTM은 LSTM의 양방향 버전으로, 시퀀스를 순방향과 역방향, 두 가지 방향에서 모두 학습한다. 이는 각 시점에서 과거와 미래의 정보를 모두 고려할 수 있게 하여, 학습에 있어서 더욱 풍부한 정보를 제공하며, GRU는 LSTM의 간소화된 변형으로, LSTM에 비해 파라미터 수가 적음에도 불구하고 비슷한 성능을 제공한다. GRU는 업데이트 게이트와 리셋 게이트 두 가지 게이트를 사용하여 정보의 흐름을 조절해 모델이 필요한 정보를 장기간 기억하면서도, 불필요한 정보는 제거할 수 있도록 한다.

본 연구에서 사용된 관측 데이터는 시간에 따라 변화하는 값들을 포함하고 있는 시계열 데이터로 표 1의 LSTM, Bi-LSTM, GRU의 단순한 모델링 결과를 통해 최적의 Layer를 보았으며 모델의 구조는 그림 2와 같다. 시간에 비례한 평균 거리 오차(Range error) 수준을 통해 단독으로 사용하여 학습하는 경우보다 Bi-LSTM과 GRU를 같이 사용하는 모델의 결과가 더 좋게 나오는 걸 확인하였으며 또한, LSTM의 경우 Bi-LSTM보다 RMSE 값이 낮게 나오지만, 거리 오차가 높게 나오는 이유는 데이터 분석 시 마지막 에포크에서 값이 크게 치솟는 경향을 보이나 Bi-LSTM은 양방향 학습을 진행하므로 평균 거리 오차가 LSTM보다 낮아짐을 알 수 있었다. 이를 통해 데이터의 시간적 순서와 패턴을 파악하여 거리 정보를 예측하거나, 시퀀스 내의 불규칙적인 정보를 학습하는 것이 가능하였다.

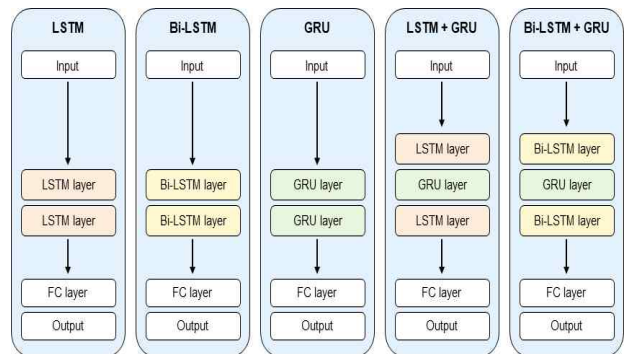


그림 2. 심층 학습 전체 모델 계층
Fig. 2. Layer of the entire deep learning model.

표 1. 심층 학습 계층 비교

Table 1. Deep learning layer comparison

Model	RMSE	Elapsed Time (s)	Range Error (km)
LSTM	0.0066375	402	5.2511
Bi-LSTM	0.0070392	572	5.0124
GRU	0.0051658	393	3.0574
LSTM + GRU	0.0041107	728	2.8852
Bi-LSTM + GRU	0.0029709	963	2.5113

표 2. 심층 학습 모델 매개변수

Table 2. Deep learning model hyper parameters

Parameter	Value	Parameter	Value
Algorithm	ADAM	Shuffle	every-epoch
Max Epoch	1,000	Validation Frequency	5
Mini Batch Size	90	Gradient Threshold	l2norm
Environment	GPU	Output Network	best validation loss
Initial Learn Rate	1e-05	L2 Regularization	1e-06

학습에 사용한 하이퍼 파라미터는 표 2와 같으며 알고리즘에는 ADAM(adaptive moment estimation), max epoch는 1,000, mini batch size는 90, 초기 학습 속도는 1e-05 및 전체 data 70% 학습 후 30% data로 검증하였다. L2 규제와 매 에포크마다 data를 섞이게 하여 모델 학습 과정에서 과적합을 방지하고 일반화 성능을 향상하게 시켰으며, 데이터를 섞음으로써 모델이 특정 순서나 패턴에 과하게 의존하지 않고, 전체 데이터 분포를 더 잘 학습할 수 있게 하였다. 또한 학습 전에 정규화(Normalization) 과정을 통해 특성의 과다함 방지 및 local minima에 빠질 위험을 감소하였다.

학습의 전체 Layer는 그림 3과 같으며 Layer 중간에 Hyperbolic tangent layer, Drop out, Fully connected를 사용하여 모델의 예측 정확도를 높이고, 과적합을 방지하였다.

Tanh는 출력값을 -1과 1 사이로 정규화하여, 모델의 학습 과정에서 Gradient 소실 문제를 완화한다. RNN의 단점으로 Gradient가 사라지거나 폭발하는 문제가 발생하는데 이를 보완하는 LSTM이라 해도 혹시 모를 학습에서 발생할 수 있는 Gradient의 급격한 감소를 방지하기 위해 Hyperbolic tangent layer를 사용했으며, Drop Out은 네트워크의 과적합을 방지하는 효과적인 방법으로 각 뉴런이 더 독립적으로 유용한 특징을 학습하도록 한다. 이는 네트워크의 일반화 능력을 향상하게 시키며, 새로운 데이터에 대한 모델의 성능을 개선한다. Fully connected layer는 모델의 마지막 부분에서 고차원 특징들을 결합하여 최종 예측을 생성한다. 이러한 계층들은 모델이 추출한 특징을 바탕으로 복잡한 패턴과 관계를 학습할 수 있도록 해, 더 정확한 출력을 생성하는 데 기여하며 모델의 학습 능력을 극대화하고, 예측 정확도를 높이며, 실제 세계의 다양하고 복잡한 데이터에 대한 모델의 적용 가능성을 높인다.

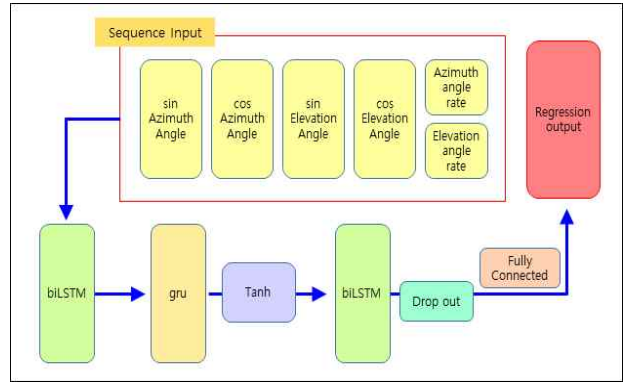


그림 3. 심층 학습 전체 모델 계층

Fig. 3. Layer of the entire deep learning model

3-2 모델 재교육

본 연구에서 개발된 심층 학습 모델은 여러 층의 Layer와 하이퍼 파라미터를 활용하여 설계하였다. 모델의 초기 학습 결과로는 RMSE(root mean square error)가 0.0017347, 그리고 거리 오차가 2.2362km로 나왔다. 이러한 거리 오차는 비교적 높은 수준이지만, 광학 관측 데이터의 복잡성을 고려할 때 단일 학습만으로 예측 정밀도를 향상시키는 것은 어려운 점이 발생한다. 따라서, 본 연구에서는 기존 관측 데이터의 TLE Epoch로부터 다음 Epoch까지의 변화를 반영한 새로운 관측 데이터를 생성하였다. 이후, 섹션 2.1과 2.2에서 설명한 단계를 따라 Input data의 전처리 과정을 진행하고, 이 데이터를 사용하여 모델의 재교육(Re-training) 과정을 수행하였다.

재교육 과정에서는 초기 학습 때 사용된 것과 동일한 Layer와 하이퍼 파라미터 설정을 유지하되, 이미 학습된 패턴과 데이터의 특성을 고려하여 과적합(Overfitting)을 방지하기 위해 max epoch 값을 500으로 수정하였다. 이는 모델이 기존의 데이터 패턴을 유지하면서도, 과적합을 피하게 학습할 수 있도록 함으로써, 모델의 예측 정밀도를 향상시키기 위한 방법이다.

기존 모델과 마찬가지로 MATLAB을 통하여 재교육 과정을 수행하였으며, 그 결과는 표 3에 요약되어 있다. 재교육 과정은 세 번에 걸쳐 진행되었으며, 각각 R¹, R², R³으로 표시된다.

첫 번째 재교육에서는 RMSE가 약 0.0005 감소하였고, 거리 오차는 1.3738km 개선되었다. 이는 초기 학습 대비 상당한 향상을 보여준다. 그러나 두 번째와 세 번째 재교육에서는 첫 번째 재교육에 비해 상대적으로 미미한 개선을 보였다. 구체적으

표 3. 재교육 결과 비교

Table 3. Comparison of Re-training results

Model	RMSE	Mean range error (km)	Max range error (km)
Initial Learning	0.0017347	2.2362	34.0173
R ¹ Learning	0.0012547	0.8624	29.4385
R ² Learning	0.0010431	0.7192	21.4885
R ³ Learning	0.0009198	0.6500	17.1226

로, RMSE는 각각 약 0.0002와 0.0001 정도 감소했으며, 거리 오차는 각각 0.11km와 0.07km 개선되었다.

이러한 결과를 바탕으로, 세 번째 재교육 후에는 시간 대비 효율성이 저하되는 경향을 보여 본 연구에서는 두 번째 재교육을 거친 모델을 최적의 모델로 선정하였다. 이 결정은 추가적인 학습이 모델의 성능 향상에 비해 상대적으로 적은 이득을 제공한다는 판단에 기반하며 심층 학습 모델의 재교육이 궤도 데이터 예측의 정확성을 개선할 수 있음을 보여준다.

3-3 심층 학습 모델 결과

본 연구에서 구축한 심층 학습 모델의 결과는 그림 4에 나타나 있으며, RMSE는 0.0010431, 관측 데이터인 거리 정보와 모델을 통해 예측된 거리 정보 간의 평균오차는 0.7192km이다. 그림 5는 Cosmos-2503 위성의 결과를 무작위로 추출한 것으로 여기서 파란색 선은 관측 데이터의 거리 정보를, 빨간색 점은 모델을 통해 예측된 거리 정보를 나타낸다. 이 데이터는 Cosmos-2503의 각도 정보를 모델에 입력하여 얻은 결과이며 그림에서 볼 수 있듯이, 예측된 거리 정보의 포인트가 실제 데이터 선과 밀접하게 일치함을 확인할 수 있으며, 이는 모델이 관측 데이터를 기반으로 정확한 예측을 수행할 수 있음을 보여준다.

이러한 결과는 모델이 실제 관측 데이터에 대한 정밀한 예측을 제공할 수 있는 높은 수준의 학습 성능을 달성했음을 보여주는데 특히, 본 모델은 우주 물체의 궤도를 예측하는 데 있어 중요한 요소인 거리 정보를 관측소에서 위성까지의 거리 정보가 없는 광학 관측 데이터를 기반으로 예측에 성공하여 궤도결정 정밀도를 높이는 데 기여할 수 있다는 걸 보여준다.




그림 4. 심층 학습 모델 결과
Fig. 4. Deep learning model outcomes.

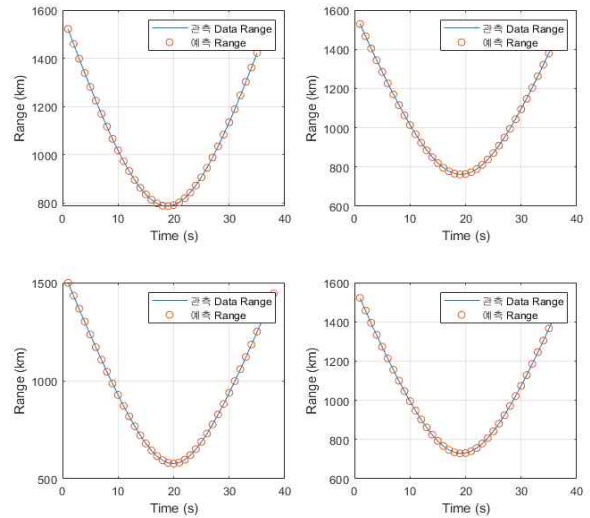


그림 5. 예측된 거리 오차
Fig. 5. Predicted range error.

IV. 궤도 결정 결과

본 절에서는 생성된 모델의 궤도결정 결과를 통해 모델의 수준 및 신뢰성 여부를 확인한다.

4-1 TLE 기반 모델 검증

본 연구에서는 생성된 거리 정보 예측 모델의 정확도를 검증하기 위하여 타겟 위성 Cosmos-2503의 TLE 데이터를 활용하였다. 특히, 기존에 생성된 TLE와 다른 Epoch에서 TLE를 기반으로, 가상의 관측 데이터를 생성하고 이를 예측 모델에 적용하여 거리 정보의 예측치를 도출하였다. 이렇게 예측된 거리 정보를 포함한 관측 데이터를 이용하여 궤도결정을 수행하였고, 이 과정에서 GMAT 프로그램의 EKF(extended kalman filter) 기능을 활용하여 모델의 유효성을 검증하였다[8].

궤도결정 과정에서 초기궤도결정(IOD; initial orbit determination)은 매우 중요하며, 이 연구에서는 위성의 초기 상태 추정에 TLE 데이터를 활용하였다[9].

EKF를 사용한 궤도결정 과정에서 적용된 환경 설정은 표 4에 요약되어 있으며, 관측 데이터 생성 환경과 같은 환경을 만들었다. Force model은 JGM-2이며 Propagator는 Rungekutta89

표 4. GMAT 확장 칼만 필터 환경
Table 4. GMAT EKF environment.

Parameter	Value	Parameter	Value
Dry Mass	10	Cr	1.8
Cd	2.0	Cd Sigma	0.1
Drag Area	10	SRP Area	10

이다. 대기 모델(Atmosphere model)은 Jacchia-roberts 모델로 대기 밀도를 계산하는 데 사용되며 특히 고도가 높은 지역, LEO의 대기 밀도 추정에 유용하다[10]. 대기 마찰 모델, 대기 마찰 계산 및 다른 요소들은 레퍼런스 값을 활용했다.

EKF 결과로는 Report file, Matlab file, Ephemeris file이 나오게 된다. Report file을 통해서 관측 데이터의 사용 빈도와 공분산 행렬(Covariance matrix)의 값이 나오게 되는데, 이 결과는 표 5에 나타나 있다. 공분산 행렬에서 도출된 위치 오차는 425.553m로 계산되었다.

Matlab file의 결과를 통해 공분산 행렬의 전체 결과를 그림6,

표 5. 거리 예측 모델 공분산 행렬 (6x6)

Table 5. Range prediction model covariance matrix (6x6).

0.0767	-0.0224	0.0309	0.0003	-0.0001	0.0002
-0.0224	0.0747	-0.0221	-0.0001	0.0003	-0.0000
0.0309	-0.0221	0.0297	0.0002	-0.0001	0.0001
0.0003	-0.0001	0.0002	0.0000	-0.0000	0.0000
-0.0001	0.0003	-0.0001	-0.0000	0.0000	-0.0000
0.0002	-0.0000	0.0001	0.0000	-0.0000	0.0000




그림 6. 예측된 거리 모델의 위치 오차

Fig. 6. Predicted range model position error.

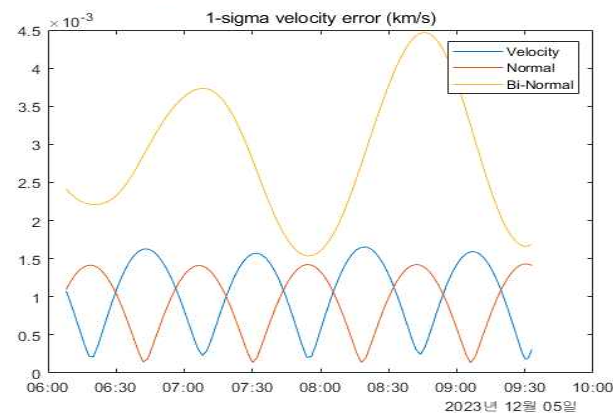


그림 7. 예측된 거리 모델의 속도 오차

Fig. 7. Predicted range model velocity error.

그림 7과 같이 나타냈으며, 이를 통해 시간의 경과에 따른 수치들을 보면 궤도결정이 잘 이루어졌다고 볼 수 있다. 위치 오차의 최댓값은 Velocity 방향의 5.526km이며 속도 오차의 최댓값은 Bi-Normal 방향의 4.451m/s이다.

모델을 통해 예측된 거리 정보의 신뢰성 비교를 위해 거리 정보가 없는 각도 정보만 있는 관측 데이터 결과를 비교 분석하였다. 동일 조건의 결과 비교를 위해 EKF의 여러 인자들은 변경 없이 그대로 사용한다.

표 6. 각도 모델 공분산 행렬 (6x6)

Table 6. Angle only model covariance matrix (6x6).

0.1072	0.0311	0.0704	0.0004	0.0000	0.0003
0.0311	0.1927	0.0801	0.0002	0.0008	0.0002
0.0704	0.0801	0.1263	0.0005	0.0003	0.0004
0.0004	0.0002	0.0005	0.0000	0.0000	0.0000
0.0001	0.0008	0.0003	0.0000	0.0000	0.0000
0.0003	0.0002	0.0004	0.0000	0.0000	0.0000




그림 8. 각도 모델의 위치 오차

Fig. 8. Angle only model position error.




그림 9. 각도 모델의 속도 오차

Fig. 9. Angle only model velocity error.

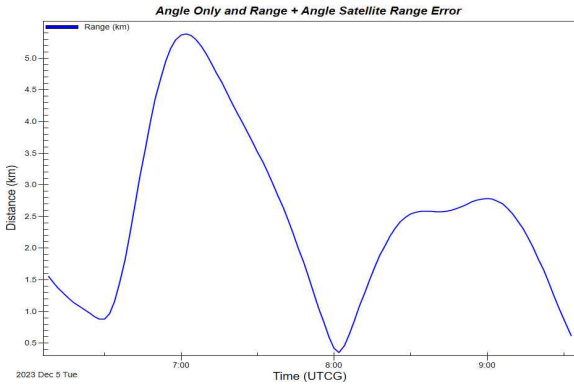


그림 10. TLE 기반 거리 예측 모델
 Fig. 10. TLE based range prediction model error

거리 정보만 있는 EKF의 결과는 표 6과 같으며 공분산 행렬의 위치 오차는 652.87m이며, 예측된 거리 정보가 있는 결과와 비교 시 공분산 행렬의 위치 오차는 약 227.32m이며, 공분산 행렬의 전체 결과는 그림 8, 그림 9와 같다. 전체 결과 비교 시 심층 학습을 통해 나온 거리 정보의 궤도결정 수준이 좋다는 걸 알 수 있으며 거리 정보의 예측을 통해 궤도결정 정밀도를 향상시킬 수 있다는 걸 보여준다.

보다 세밀한 비교 분석을 위하여, STK 시뮬레이션을 이용해 궤도결정을 통해 얻은 Ephemeris file의 결과를 확인하였다. 각도 정보만 있는 위성의 궤도결정 결과와 각도 정보와 예측된 거리 정보가 있는 위성의 궤도결정 결과를 비교하였는데 비교 결과는 두 위성의 거리 차이로 확인하였다. 결과는 그림 10과 같으며 최대 거리 차이는 5.387km이며 평균 2.497km의 차이를 가지고 있다.

이 결과를 통해 심층 학습으로 거리 정보를 예측하는 방식이 궤도결정의 정밀도를 높일 수 있다는 걸 확인 할 수 있었다.

4-2 실제 관측 데이터 결과

GMAT을 통해 생성된 가상의 관측 데이터를 통해 거리 정보 예측 모델의 유효성을 확인했으나 실제 관측 데이터를 통해 거리 정보의 예측 및 궤도결정을 통해 모델의 신뢰성을 검증한다.

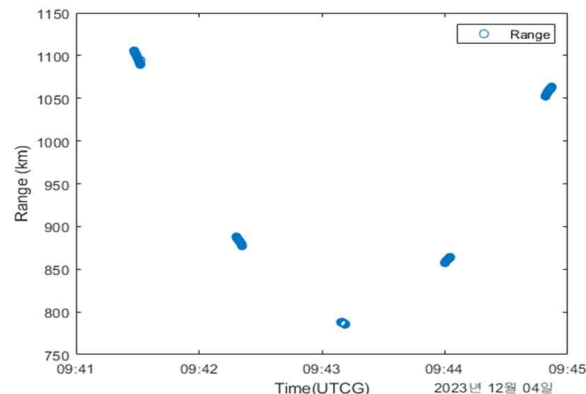


그림 11. Cosmos-2503 거리 정보 예측
 Fig. 11. Cosmos-2503 range data prediction.

타겟 위성들에 대한 거리 정보 예측 모델을 생성 후 실제 관측 데이터를 앞선 검증과 같이 모델을 통해 거리 정보를 예측하였다. 그림 11은 Cosmos-2503의 예측된 거리 정보이며, 이와 같은 방식으로 각 타겟 위성들의 실제 관측 데이터를 통하여 거리 정보를 예측하였다.

GMAT을 활용하여 궤도결정시 실제 관측 데이터는 GMAT을 통해 생성된 가상의 관측 데이터에 비해 한반도 상황에서 기상 악화 및 여러 요인으로 인해 각도 정보의 Noise 및 Bias를 고려해야 한다. 본 연구에서는 최적의 Noise 값 대신 Angle noise sigma는 0.05, Range noise sigma는 모델의 평균 거리 오차인 0.7 기준으로 고정하여 궤도결정을 실시 하였다.

표 7. Cosmos 모델 공분산 행렬 (6x6)
 Table 7. Cosmos range model covariance matrix (6x6).

0.0146	-0.0008	0.0021	0.0001	-0.0000	0.0000
-0.0008	0.0142	0.0036	-0.0000	0.0001	0.0000
0.0021	0.0036	0.0199	0.0000	0.0000	0.0001
0.0001	-0.0000	0.0000	0.0000	0.0000	0.0000
-0.0000	0.0001	0.0000	0.0000	0.0000	0.0000
0.0000	0.0000	0.0001	0.0000	0.0000	0.0000

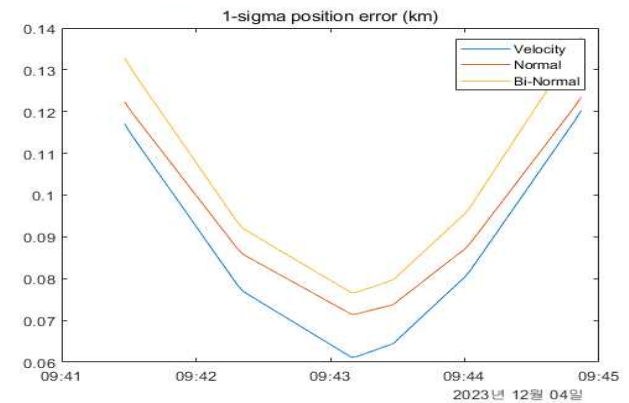


그림 12. Cosmos 거리 예측 모델 위치 오차
 Fig. 12. Cosmos range prediction model position error.




그림 13. Cosmos 거리 예측 모델 속도 오차
 Fig. 13. Cosmos range prediction model velocity error.

Cosmos-2503의 궤도결정의 결과로는 표 7에 공분산 행렬, 그림 12과 그림 13에는 공분산 행렬의 위치 및 속도 오차를 그렸다. 공분산 행렬에서 도출된 위치 오차는 220.71m로 계산되며, 위치 오차의 최댓값은 Bi-Normal 방향의 136.71m이며 속도 오차의 최댓값은 Bi-Normal 방향의 1.087m/s로 나타났다.

섹션 4.1과 마찬가지로 거리 정보 예측 심층 학습 모델의 유효성 확인을 위해 실제 관측 데이터를 가지고 궤도결정을 실시한 결과와 비교 분석을 하였다. 실제 관측 데이터인 각도 정보를 궤도결정 한 결과는 표 8, 그림 14, 그림 15에 나와 있으며 공분산 행렬에서 도출된 위치 오차는 1.622km로 계산되며 예측된 거리 정보가 있는 궤도결정 결과와 비교 시 1.401km 차이가 발생하는 걸 확인할 수 있다.

표 8. Cosmos 관측 정보 공분산 행렬 (6x6)
Table 8. Cosmos observation data covariance matrix (6x6).

0.0233	-0.0345	-0.1029	0.0007	0.0002	-0.0006
-0.0345	0.2845	0.7905	-0.0035	-0.0007	0.0045
-0.1029	0.7905	2.3228	-0.0104	-0.0023	0.0133
0.0007	-0.0035	-0.0104	0.0001	0.0000	-0.0001
0.0002	-0.0007	-0.0023	0.0000	0.0000	-0.0000
-0.0006	0.0045	0.0133	-0.0001	-0.0000	0.0001

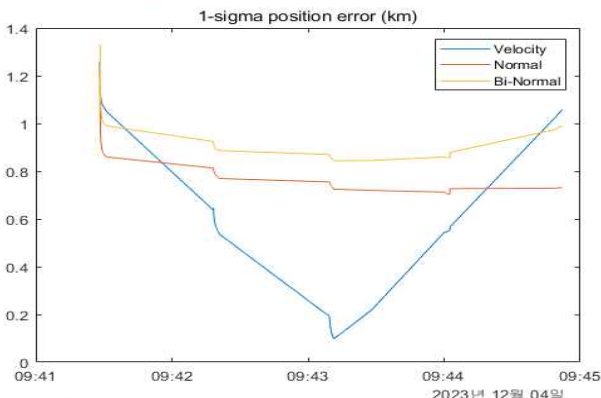


그림 14. Cosmos 관측 정보 위치 오차
Fig. 14. Cosmos observation data position error.

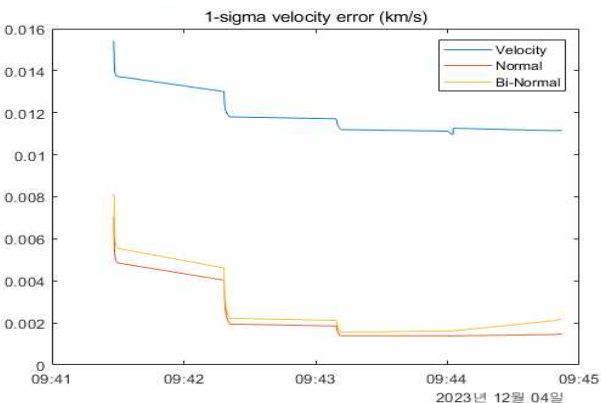


그림 15. Cosmos 관측 정보 속도 오차
Fig. 15. Cosmos observation data velocity error.

실제 관측 데이터의 결과 비교 분석을 위하여, STK 시뮬레이션을 이용해 궤도결정을 통해 얻은 Ephemeris file과 기준 위성의 궤도를 대조하였다. 이러한 비교에서 기준으로 삼은 위성의 궤도는 TLE 데이터를 바탕으로 하였다. TLE 데이터에는 오차가 존재함을 인지하면서도, 본 연구에서는 실제 정확한 위성의 위치 정보가 없으므로 TLE 데이터를 실제 궤도로 간주하고, 이를 통해 TLE 데이터 및 실제 관측 데이터와 예측된 거리 정보가 있는 관측 데이터 비교로 세 위성의 위치 차이를 분석하였다.

STK 결과로 지구중심관성좌표계에서 동일한 시간대의 세 위성의 위치를 그림 16에 나타내었다. 검은색 선이 TLE 위성이며 파란색 선은 심층 학습으로 나온 예측된 거리 정보가 있는 위성, 빨간색 선은 실제 관측된 위성이다. 빨간색 선의 경우 TLE 위성과 비교 시 오차가 최대 350km 이상 발생하며, 추가적인 관측 데이터의 필터링으로 최소 2.11km 수준으로 나오게 된다. 파란색 선인 예측된 거리 정보가 있는 위성의 경우 TLE 위성과 비교 시 최대 1.9km, 최소 140.26m로 실제 관측 데이터와 확연한 차이를 보여준다.

그림 17의 경우 TLE 위성의 거리 정보와 예측된 거리 정보가 있는 위성의 거리 정보를 비교한 결과인데 최대 6km, 최소 1km로 평균 3.51km의 오차를 보여주며, 시간이 지날수록 오차가 줄어드는 걸 확인할 수 있다.

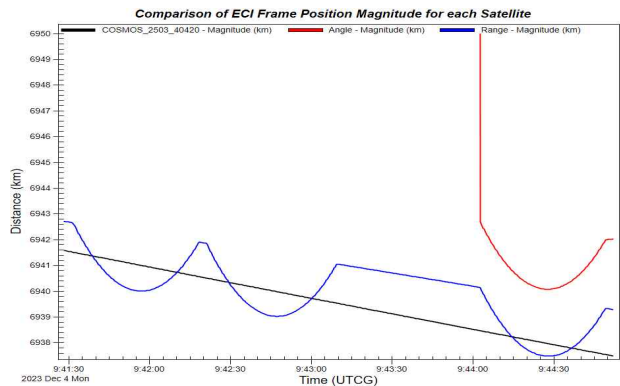


그림 16. ECI 프레임 위치 오차 비교
Fig. 16. ECI frame position error comparison.

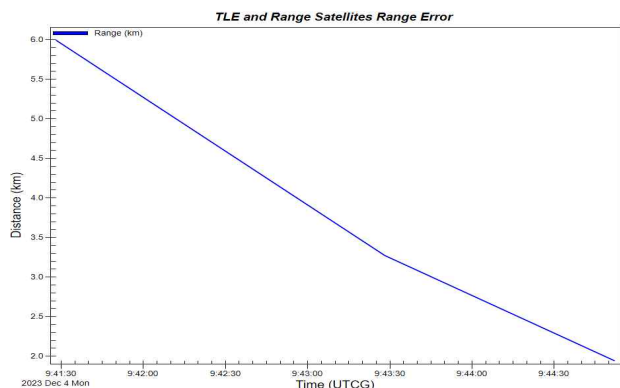


그림 17. 관측 정보 거리 오차
Fig. 17. Observation data range error.

표 9. 궤도 결정 결과

Table 9. Orbit determination results.

< OD Result >		Cosmos-2503	Yaogan-35	Skymed-3	Kompsat-5	Ariane-40	
Orbit Element	Altitude	689.696km	503.505km	585.749km	553.055km	581.461km	
	Inclination	97.899°	34.995°	97.882°	97.619°	98.303°	
	Eccentricity	0.0014110	0.0004857	0.0015015	0.0001904	0.0017222	
Orbit Determination	Range Error		3.509km	4.716km	5.838km	4.3148km	4.2755km
	Covariance Matrix	Angle Only	1.622km	1.845km	1.630km	1.553km	1.561km
		Angle & Range	220.71m	304.491m	189.42m	258.86m	251.11m

앞선 결과들을 통해 거리 정보 예측 모델의 유효성을 검증하였으며, 궤도결정의 정밀도가 향상된 것을 알 수 있다. 이제 다른 타겟 위성들의 결과를 비교하여 모델의 신뢰성을 확인한다.

타겟 위성들의 결과는 표 9에 요약되어 있으며 각 위성들의 고도와 경사각, 이심률을 TLE 기준으로 작성했다. 궤도결정의 결과로는 지구중심관성좌표계에서 TLE 위성과 예측된 거리 정보가 포함된 위성의 궤도결정 결과의 평균 거리 오차값을 적었으며, 실제 관측 데이터의 궤도결정 결과의 공분산 행렬값 및 예측된 거리 정보가 포함된 위성의 궤도결정 결과의 공분산 행렬값을 적었다. 각 위성의 결과를 확인하면 실제 관측 데이터만 사용한 결과와 예측된 거리 정보가 있는 결과 비교 시 심층 학습을 통해 나온 궤도결정의 결과가 좋은 걸 확인 할 수 있으며, 본 연구의 모델의 신뢰성을 검증할 수 있었다.

V. 결론

본 연구에서는 광학 관측 데이터를 활용하여 기존에 알려진 위성들의 궤도를 예측하는 신뢰도 높은 거리 정보 예측 모델을 개발하였다. 이 모델은 심층 학습 기법 중 Bi-LSTM과 GRU를 결합한 구조를 사용하여, 위성 궤도의 정밀도를 효과적으로 향상시킬 수 있는 기반을 마련하였으며, 특히 심층 학습을 이용하여 광학 관측만으로는 획득하기 어려운 거리 정보를 예측할 수 있는 모델을 개발하였고 이 모델의 유효성을 검증하기 위해 실제 관측 데이터를 사용하였다. 이를 통해 모델의 실용성과 신뢰성을 높였으며, STK 시뮬레이션을 통해 궤도결정 시 발생할 수 있는 에러를 줄이고, 궤도결정의 정밀도를 실질적으로 개선하였음을 확인하였다. 이 모델은 현재 공군과 한국천문연구원 등에서 사용 중인 광학 관측 시스템에 적용하여 궤도결정의 정밀도를 실질적으로 개선할 수 있음을 보여준다. 그러나, 현 연구의 모델은 미식별 위성에 대해서는 적용에 한계가 있으며 미식별 위성에 대한 예측된 거리 정보는 현재 2km에서 7km 범위의 정확도를 보이고 있으며, 이는 아직 실용적인 수준에 도달하기에는 부족하다. 따라서 향후 연구에서는 미식별 위성에 대한 정밀도를 더욱 향상시키기 위한 모델 개선이 필요하다.

우주 상황 인식의 중요성이 점차 증가하는 현시점에서, 특히

한반도와 같은 지역에서는 광학 관측만으로는 정밀한 임무 수행이 어려운 경우가 많다. 본 연구에서 개발한 거리 정보 예측 모델은 이러한 문제를 해결하는 데 기여할 수 있으며, 우주 상황 인식의 정밀도와 신뢰성을 크게 향상시킬 것으로 기대된다. 결론적으로, 본 논문은 기존 광학 관측 데이터를 심층 학습을 통해 더욱 유용하게 활용하고자 하는 시도로서 중요한 기초를 제공하였다. 향후 연구를 통해 이러한 기법들을 보다 발전시켜, 우주 상황 인식의 정밀도를 높이고, 국제적인 우주 환경에서의 협력과 정보 공유에 기여할 수 있기를 기대한다.

Acknowledgments

본 논문은 2023년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임(No. 1711195701, 우주상황인식을 위한 국방 메타버스 교육훈련 기술 개발)

References

- [1] ESA’s Space Debris Office, Space debris by the numbers, 2022, May. 2022. Retrieved from https://www.esa.int/Safety_Security/Space_Debris/Space_debris_by_the_numbers.
- [2] M. Jah, S. Hughes, M. Wilkins, and T. Kelecy. “The general mission analysis tool(GMAT): A new resource for supporting debris orbit determination, tracking and analysis,” in *Proceedings of the Fifth European Conference on Space Debris*, ESA SP-672, July 2009. Retrieved from <https://conference.sdo.esoc.esa.int/proceedings/sdc5/paper/14>
- [3] F. Caldas and C Soares, “Machine learning in orbit estimation: A survey,” *Acta Astronautica*, Vol. 220, pp. 97-107, July 2024, DOI: <https://doi.org/10.1016/j.actaastro.2024.03.072>.
- [4] Schaeperkoetter, Andrew Vernon. “A comprehensive

comparison between angles-only initial orbit determination techniques.” PhD Thesis, Texas A & M University. USA. 2012. Retrieved from <http://www.oaktrust.library.tamu.edu>.

[5] N. Salleh, N. F. Mohd Azmi, and S. S. Yuhaniz, “An adaptation of deep learning technique in orbit propagation model using long short-term memory,” in *2021 International Conference on Electrical, Communication, and Computer Engineering, ICECCE, Institute of Electric and Electronics Engineers (IEEE)*, Kuala Lumpur: Malaysia, pp. 1–6, 2021. DOI: <https://doi.org/10.1109/icecce52056.2021.9514264>.

[6] R. Dey and F. M. Salem, “Gate-variants of gated recurrent unit (GRU) neural networks,” in *2017 IEEE 60th International Midwest Symposium on Circuits and Systems (MWSCAS)*, Boston: MA, pp. 1597-1600, 2017. DOI: <https://doi.org/10.1109/mwscas.2017.8053243>.

[7] G. Curzi, D. Modenini, and P. Tortora, “Two-line-element propagation improvement and uncertainty estimation using recurrent neural networks.” *CEAS Space Journal*, Vol. 14,

No. 1, pp 197–204, 2022. DOI: <https://doi.org/10.1007/s12567-021-00375-3>.

[8] Q. M. Lam, D. Junker and D. Anhalt. “Analysis of an extended Kalman filter based orbit determination system,” in *AIAA Guidance, Navigation, and Control Conference*, Toronto, Ontario: Canada, Aug. 2010. DOI: <https://doi.org/10.2514/6.2010-7600>.

[9] H. Hwang, S-Y Park, and E. Lee, “Angles-only initial orbit determination of low earth orbit (LEO) satellites using real observational data.” *Journal of Astronomy and Space Sciences*, Vol. 36, No. 3, pp. 187-197, 2019. DOI: <https://doi.org/10.5140/jass.2019.36.3.187>.

[10] B. R. Bowman, W.K. Tobiska, F.A. Marcos, C.Y. Huang, C.S. Lin, and W.J. Burke, “A new empirical thermospheric density model JB2008 using new solar and geomagnetic indices,” in *AIAA/AAS Astrodynamics Specialist Conference and Exhibit*, Honolulu: HI, p. 19, 2008. DOI: <https://doi.org/10.2514/6.2008-6438>.



윤 현 만 (Hyeon-Man Yun)

2019년 8월 : 동아대학교 기계공학과 (공학사)
 2022년 9월 ~ 현재 : 세종대학교 우주항공시스템공학부 석사과정
 ※ 관심분야 : 머신러닝/딥러닝 기반 위성궤도 역학, 궤도결정 및 궤도예측 등



김 찬 호 (Chan-Ho Kim)

2007년 3월 : 공군사관학교 경제경영학과 (문학사)
 2007년 3월 ~ 현재 : 공군 장교 복무 중
 2023년 3월 ~ 현재 : 세종대학교 우주항공시스템공학부 석사과정 (공군 위탁교육생)
 ※ 관심분야 : 머신러닝/딥러닝 기반 위성궤도 역학, 궤도결정 및 궤도예측 등



최 인 수 (In-Soo Choi)

2020년 2월 : 공군 우주정보분석담당
 2022년 2월 ~ 현재 : 세종대학교 군집위성 궤도공학 연구소 연구원
 ※ 관심분야 : 머신러닝/딥러닝 기반 위성궤도 역학, 궤도결정 및 궤도예측 등



이 성 섭 (Soung-Sub Lee)

2009년 3월 : 미국 버지니아공대 우주공학 박사
 2018년 1월 : 국방부 미사일 우주정책 과장
 2021년 3월 ~ 현재 : 세종대학교 우주항공시스템공학부 교수
 ※ 관심분야 : 군집위성 궤도설계 및 제어, 머신러닝/딥러닝 기반 위성궤도 역학 등