

단말 이동성 예측 기술 기반 심층 강화학습 비지상 네트워크 핸드오버 최적화 연구

김 준 영*, 장 희 연*, 조 인 섭**, 신 민 수**, 정 소 이°

Terminal Mobility Prediction for Deep Reinforcement Learning-Based Handover Optimization in Non-Terrestrial Networks

Junyoung Kim*, Huiyeon Jang*, In-Sop Cho**, Minsu Shin**, Soyi Jung°

요 약

저궤도 위성은 글로벌 커버리지 실시간 통신 기술 실현하기 위한 핵심 기술이다. 저궤도 위성의 빠른 이동성과 채널 특성으로 인해 기존 지상 네트워크의 핸드오버 기법은 빈번한 핸드오버가 발생하며 통신 중단과 지속적인 서비스를 받는 것에 대해 한계가 존재한다. 이에, 위성의 빠른 이동성과 단말의 무작위적인 움직임에 따른 최적화 기법이 요구된다. 본 논문에서는, 시계열적 데이터 특성을 가진 위성 and 단말의 움직임 데이터 분석을 통해 단말의 수신신호세기 예측 딥러닝 기술과, 예측된 수신신호 세기를 기준으로 최적의 타이밍에 핸드오버를 수행하는 강화 학습 기반 핸드오버 최적화 기법을 제안한다. 제안하는 딥러닝 기술과 강화학습 기법의 융합을 통해 빠른 학습 속도와 정확한 타이밍에 핸드오버를 발생하여, 단말의 수신신호세기와 전체 시스템 성능을 향상하였다.

키워드 : 비지상 네트워크, 저궤도 위성통신, 핸드오버, 심층 강화학습

Key Words : Non-terrestrial networks, LEO satellites communication, Handover, Deep reinforcement learning

ABSTRACT

Low Earth orbit (LEO) satellites are crucial for global coverage and real-time communication services. However, their rapid mobility and unique channel characteristics pose challenges for conventional handover techniques, leading to frequent disruptions and limited seamless connectivity. Optimized methods are needed to address the satellites' movement and the stochastic mobility of user terminals. This paper proposes a novel approach combining deep learning and reinforcement learning to optimize handovers. Time-series data of satellite and terminal movements are analyzed to predict the received signal strength (RSSI) using deep learning. Based on the predicted RSSI, a reinforcement learning-based framework determines the optimal handover timing. This integration achieves faster convergence and precise handover decisions, enhancing RSSI and overall system performance.

※ 본 연구는 과학기술정보통신부 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임(No. 2021-0-01715, 정지궤도 공공복합위성 통신 탑재체 개발)

• First Author : Department of Artificial Intelligence Convergence Network, Ajou University, junzero0615@ajou.ac.kr, 학생회원

° Corresponding Author : Ajou University Department of Electrical and Computer Engineering, sjung@ajou.ac.kr, 종신회원

* Department of Artificial Intelligence Convergence Network, Ajou University, timd0801@ajou.ac.kr, 학생회원

** Electronics and Telecommunications Research Institute, lookatstar@etri.re.kr; msshin@etri.re.kr, 정회원

논문번호 : 202411-296-B-RN Received November 21, 2024; Revised December 15, 2024; Accepted December 15, 2024

I. 서 론

위성 네트워크는 지상 네트워크의 한계를 보완하여 글로벌 커버리지 실시간 무선 통신 서비스 개발에 기여할 것으로 기대된다^[1]. 최근 통신 기술의 급속한 발전과 함께 저궤도(low Earth orbit satellite, LEO) 위성은 학계와 산업계에서 많은 관심을 받고 있다^[2]. LEO 위성은 전송 지연이 적고 에너지 소비가 적어 실시간 통신과 높은 처리량을 달성할 수 있다^[3]. 그러나, LEO 위성의 빠른 이동성으로 인해 중단없이 통신을 유지하기 위해서는 단말이 다른 위성으로 연결 관계를 변경하는 핸드오버 절차가 지속적으로 요구된다^[4]. LEO 위성은 지상 기지국과 비교하여 높은 고도에 위치하기 때문에 셀 간 거리에 따른 신호 세기의 차이가 매우 작다. 따라서 기존의 지상 네트워크에서 사용되는 핸드오버 기법을 사용한다면 불필요한 핸드오버, 통신 중단 증가 등 많은 문제를 유발할 수 있다. 3GPP(3rd generation partnership project, 3GPP)에서는 비지상 네트워크(non-terrestrial-network, NTN)에서 LEO의 빠른 이동성에 따른 핸드오버 문제를 해결하기 위하여 특정 조건을 만족하면 실행되는 조건부 핸드오버 절차를 제안하였으며, 거리 기반 및 타이밍 기반과 같은 다양한 핸드오버 트리거링 이벤트를 정의하였다^[5].

그러나, 위성 네트워크에서 단말과 위성의 움직임을 고려하여 수신신호를 예측하는 이동성 예측 기술 기반 핸드오버 최적화 기법에 관한 연구는 많이 진행되지 못하였다. 이에, 본 논문에서는 위성과 단말의 움직임에 따른 수신 신호 세기를 학습하여 단말이 각 핸드오버 후보 위성에 대한 수신 신호 세기를 예측하고 최적의 서비스 위성을 선택하는 예측형 이동성 인지 딥러닝 기술을 설계한다. 더하여, 딥러닝 네트워크를 통해 예측된 데이터와 DRL 기법의 융합을 통해 최적의 타이밍에서 지상 단말(user equipment, UE)이 핸드오버를 수행하여 지속적으로 LEO에 연결되어 지속적인 서비스와 서비스 품질(quality of service, QoS)을 보장하는 기법을 제안한다^[6].

II. 저궤도 위성 핸드오버 기법 연구 동향

위성 핸드오버 성능을 최적화하기 위하여 궤도를 따라 규칙적으로 이동하는 위성의 특징을 고려하여 인공지능을 활용해 핸드오버 성능을 향상하기 위한 여러 연구가 진행되었다. 본 절에서는 인공지능을 접목한 최신 연구 동향을 논한다.

2.1 위성 환경 이동성 예측 기술 딥러닝 기술 동향

위성 궤도 데이터는 시계열적 특성을 가진다. 주식 추세 변동, 계절 변동 및 순환 변동 등 일정한 시계열 데이터를 분석하는 딥러닝 기술은 보통 순환 신경망(recurrent neural network, RNN), 장단기 메모리 네트워크(long short-term memory, LSTM), 게이트 순환 유닛(gated recurrent unit, GRU), 합성곱 신경망(convolutional neural network, CNN) 등이 있다. 특히 LSTM 기법은 연속적으로 긴 데이터 처리가 가능하고, 효과적인 정보 처리 및 다양한 시계열 데이터의 문제를 해결하기에 성능이 뛰어난 모델로, 복잡하고 긴 시계열적 특성을 가진 위성 궤도 데이터와 변동성이 심한 이동체 이동성을 예측하는 기술로 적합하다.

[7]에서는 다중 LSTM 기반 도플러 주파수 편이 선보상 알고리즘을 제안하였다. 현재 궤도 데이터와 현재 시간 간의 차이를 기반으로 단일 또는 다중 LSTM 모델을 선택해 궤도 매개변수를 예측하여 향후 도플러 주파수 편이 값을 계산하고, 단말에 선보상을 수행한다. 이를 통해 기존 알고리즘 대비 주파수 편이 선보상 정확도를 향상하였다. [8]에서는 지상 단말과 위성의 시간적 상관관계를 기반으로 GNU를 활용한 지상 단말의 CSI(channel state information, CSI) 예측 모델을 제안하였다. 제안 모델은 기존 방식 대비 우수한 성능을 보이며, 위성의 상승 및 하강 이동성에 대한 CSI 패턴을 효과적으로 학습함을 보였다.

2.2 심층 강화학습 기반 핸드오버 기법 연구 동향

[9]에서는 심층 강화학습 기법(deep reinforcement learning, DRL)을 기반으로 사전 정의된 위성의 궤도 패턴에 대하여 단말의 핸드오버 성공 여부를 강화학습을 통해 학습한다. 이를 통해 단말이 언제 핸드오버 요청을 보낼지를 예측하고 접속 지연과 충돌률을 최소화하는 핸드오버 결정을 내린다. 이를 통해 전파 지연을 제거하며 접속 지연, 충돌률 및 핸드오버 성공률 측면에서 좋은 성능을 보였다. [10]에서는 multi-agent deep Q-learning(MADQL)을 통하여 단말의 시야에서 고도 각 제한을 만족하는 위성에 대해서 위성에 대한 부하와 남은 가시 시간을 고려하여 불필요한 핸드오버를 최소화하고 가용 자원이 많은 위성에 연결하도록 한다. 이를 통해 변화하는 트래픽 패턴을 가지는 단말의 핸드오버 성공률을 향상시켰다. [11]에서는 multi-agent double deep Q-network(MADDQN)을 통해 단말의 위성에 대한 가시 시간, 현재 위성 연결 정보, 예상 전송 속도, 패킷 대기열 정보와 같은 단말 로컬 상태 정보와 이전에 인접한 다른 단말들이 한 핸드오버 결정 정보를 기반으

로 데이터 전송 효율을 극대화하고 핸드오버와 패킷 손실을 최소화하도록 학습하도록 한다. 이를 통해 데이터 전송 성능을 최적화하면서 핸드오버를 최소화한다. [12]에서는 multi-agent Q-learning(MAQL)을 통한 부하 균형 핸드오버 기법을 제안한다. 각 단말이 위성의 커버리지 포함 여부, 위성 부하, 남은 가시 시간과 같은 정보를 기반으로 가시 시간이 길고 부하가 적은 위성에 연결하도록 학습한다. 이를 통해 핸드오버 빈도를 감소시키고 실시간 위성 부하 균을 맞추어 네트워크 혼잡을 방지하고 낮은 핸드오버 차단율을 보였다.

2.3 시계열 데이터 예측 기술 및 심층 강화학습 융합 기술 연구 동향

위성과 단말의 이동성 예측 딥러닝 기술과 심층 강화학습을 통한 핸드오버 최적화 기법의 융합은 지상 UE와 비지상 네트워크 기지국(non-terrestrial network base station, NT-BS)이 다수 존재하는 mega-constellation 시나리오에서 상호 간의 연계를 통해 throughput을 향상하기에 적합한 기법이다. LSTM과 심층 강화학습 기법 중 deep-q-network(DQN)을 활용해 지상 UE와 NT-BS 간의 핸드오버 최적화 기법에 대해 연구가 진행되었다^[13]. 본 연구에서는, DQN 네트워크의 상태 입력값으로 LSTM 신경망을 통해 얻은 위성 궤도 이동 데이터가 입력된다. 입력 데이터는 연속된 시간 슬롯 데이터가 포함되며, 입력 게이트(i_t), 망각 게이트(f_t), 출력 게이트(o_t)로 이루어진 총 3개의 게이트로 LSTM 유닛이 구성되며, 각 유닛은 NT-BS의 시계열적 특성을 분석해 지상 셀 상태(c_t)를 출력한다. LSTM 네트워크를 통해 출력된 c_t 는 DQN의 상태 값에 영향을 주며, 지상 UE 에이전트는 시간 슬롯 t 에서 전송률을 보상 값으로 설정하고, 핸드오버가 수행될 때마다 패널티를 부여해 빈번한 핸드오버가 발생하지 않도록 시스템 모델을 설계한 것이 가장 큰 특징이다. 시뮬레이션 결과, 제안하는 기법이 타 기법에 비해 최적 결과에 가장 유사하게 도출되었다.

위성 네트워크에서 고정된 단말에 대한 핸드오버 최적화 연구는 활발히 진행되고 있지만, 단말의 움직임을 고려한 핸드오버 최적화 연구는 부족하다. 이에 본 논문에서는 위성과 단말의 움직임에 따른 수신 신호 세기를 학습하여 단말이 위성에 대한 수신 신호 세기를 예측하고 최적의 핸드오버 위성을 선택하는 예측형 이동성 인지 핸드오버 최적화 기법을 제안한다.




그림 1. LEO 안테나 패턴
Fig. 1. LEO antenna pattern

III. 비지상 네트워크 시스템 모델

본 논문에서는 시계열적 데이터를 활용하여 UE의 이동 경로 예측 데이터 및 수신 신호 세기 예측 데이터를 기반으로 LEO가 이동하는 환경에서 UE가 최적의 타이밍에 핸드오버를 수행하는 강화학습 기법을 제안한다. 고도 600 km에 위치한 저궤도 위성이 정해진 궤도에 따라 속도 v 로 이동하는 시나리오를 고려한다. 총 I 개의 LEO 위성으로 구성되며, $I = \{i | i = 1, 2, \dots, I\}$ 로 나타낼 수 있다. 각각의 LEO는 19개의 빔으로 총 K 개의 지상 셀을 커버하며, 이는 $K = \{k | k = 1, 2, \dots, K\}$ 로 표현한다.

본 시스템 모델은 시간 슬롯 t 에서 LEO 위성의 좌표를 $s_{i,m}(t) = [x_{i,m}(t), y_{i,m}(t), z_{i,m}(t)]$ 으로 정의한다. 본 논문의 NTN LEO 시스템 모델은 전체 서비스 시간 T 가 여러 시간 슬롯 t 로 구성되었으며, 각 슬롯의 지속 시간 Δt 이다. 따라서 LEO 위성의 이동은 $s_{i,m}(t+1) = s_{i,m}(t) + v\Delta t$ 로 정의한다.

3.1 LEO 위성 안테나 패턴

본 논문에서는 3GPP 표준 문서를 기반으로 위성의 안테나 패턴을 고려하였다^[14]. 정규화된 안테나 이득 패턴은 원형 개구를 가진 전향적인 반사 안테나에 해당되며, 그림 1과 같이 표현되고 3GPP 표준 TR 38.811 문서에 기재된 안테나 패턴 수식 (1)을 기준으로 한다.

$$G(\theta_{i,k}^{i,k}) = \begin{cases} 1 & \text{if } \theta_{i,k} = 0, \\ 4 \left| \frac{J_1(ka \sin \theta_{i,k})}{ka \sin \theta_{i,k}} \right|^2 & \text{if } 0 < \theta_{i,k} \leq 90^\circ \end{cases} \quad (1)$$




그림 2. 3GPP 표준 기반 LEO 위성 빔 구성도
Fig. 2. 3GPP LEO satellite beam configuration

함수 J_1 은 알종의 베셀 함수이며, a 는 안테나의 원형 개구 반지름을 나타낸다. GHz 단위의 반송 주파수(f_c), 빛의 속도(c)의 관계로 파수(k)는 $k = 2\pi f_c / c$ 로 나타낸다. LEO 위성의 구성된 빔은 총 19개로, 각 빔도 속도 v 를 기반으로 움직이는 무빙 셀 환경을 고려하였으며, $\theta_{i,k}$ 는 LEO 위성 i 와 지상 셀 k 간의 빔 중심선 사이의 각도다. 그림 1을 기반으로 형성된 지상의 LEO 위성 빔은 그림 2와 같이 19개 빔으로 시뮬레이션을 진행한다.

3.2 채널 감쇠 모델

LEO 위성과 지상 셀 간의 채널 모델은 여러 감쇠에 영향을 받는다. 본 논문에서 사용한 감쇠 모델은 large scale model을 채택하였다^[13]. 이에 LEO 위성 i 와 지상 셀 k 간의 경로 손실($PL_{i,k}$)은 수식 (2)와 같이 정의한다.

$$PL_{i,k} = PL_b + PL_g + PL_s + PL_e. \quad (2)$$

경로 손실($PL_{i,k}$)은 기본 경로 손실(PL_b), 대기 가스에 의한 감쇠(PL_g)와 전리층 또는 대류권 난류에 의한 감쇠(PL_s), 도시 빌딩에 의한 감쇠(PL_e)로 정의되며, PL_b 는 수식 (3)과 같이 정의된다.

$$PL_b = FSPL_{i,k} + SF + CL. \quad (3)$$

PL_b 는 free-space-path-loss($FSPL_{i,k}$), shadow fading(SF), 그리고 clutter loss(CL)의 관계로 표현되며 특히, $FSPL_{i,k}$ 는 지상 UE와 LEO 위성 까지의 거리(d), 주파수(f_c)로 수식 (4)와 같이 정의한다.

$$FSPL_{i,k} = 32.45 + 20\log_{10}(f_c) + 20\log_{10}(d). \quad (4)$$

본 논문에서는 3GPP 표준 문서의 시골 시나리오에 서의 지상 UE와 LEO 위성 간의 고도각(elevation angle) 기반 LoS(line-of-sight)과 NLoS(non-line of-sight)의 분포도의 SF 와 CL 값을 참조하였고, 경로 손실 모델은 기본 경로 손실 모델만 고려하였다^[14,15].

3.3 위성 네트워크 신호 모델

위성과 지상 UE의 수신 신호 세기와 신호 대 잡음비(signal to noise ratio, SINR)를 계산하기 위해 3GPP 문서에 명시된 수식을 활용한다^{[5],[14]}. 먼저 하향링크(downlink, DL)와 상향링크(uplink, UL) 시나리오에서 수신 신호 세기($P_{rx}^{i,k}$)는 송신 전력($P_{tx}^{i,k}$), 경로 손실($PL_{i,k}$), 송신기 안테나 이득(G_{tx}), 수신기 안테나 이득(G_{rx})으로 수식 (5)와 같이 정의한다^[14].

$$P_{rx}^{i,k} = P_{tx}^{i,k} - PL_{i,k} + G_{tx} + G_{rx}. \quad (5)$$

위성 송신 파워($P_{tx}^{i,k}$)는 $EIRP_{den}$ (effective isotropically radiated power density, EIRP), 위성 채널 대역(b_n), 그리고 위성 송신 안테나 이득($G_{tx}^{i,k}$)간의 관계로 수식 (6)과 같이 정의한다.

$$P_{tx}^{i,k} = EIRP_{den} + 10\log_{10}(b_n) - G_{tx}^{i,k}. \quad (6)$$

신호 대 잡음 비(signal to noise ratio, SNR)를 도출해 내기 위해 안테나 이득 대 잡음 온도 비율(G/T)은 수신기 안테나 이득(G_R), 수신기 잡음 지수(N_f), 주위 온도(ambient temperature, T_0), 그리고 수신기 안테나 온도(antenna temperature, T_a)의 관계로 수식 (7)과 같이 정의한다.

$$\begin{aligned} G/T &= G_R - N_f \\ &- 10\log_{10}(T_0 + (T_a - T_0)10^{-0.1N_f}). \end{aligned} \quad (7)$$

위 정의된 파라미터를 기반으로 SNR은 $EIRP$, G/T , 볼츠만 상수(k), 자유 공간 경로 손실($FSPL$),




그림 3. LSTM 구조
Fig. 3. LSTM structure

그리고 위성 채널 대역폭(B)으로 수식 (8)과 같이 정의한다.

$$SNR = EIRP + G/T - k - FSPL - B. \quad (8)$$

신호 대 간섭 비(signal to interference ratio, SIR)은 현재 단말의 수신 신호 세기($P_{rx}^{i,k}$)와 간섭 신호의 총합 ($\sum_{i,k=1}^{LK} P_{rx}^{i,k}$)의 비율로 수식 (9)와 같이 정의한다.

$$SIR = \frac{P_{rx}^{i,k}}{\sum_{i,k=1}^{LK} P_{rx}^{i,k}}. \quad (9)$$

따라서, 최종적으로 본 논문의 주요 성능 지표인 SINR 은 SIR과 SNR의 관계로 수식 (10)과 같이 정의한다.

$$SINR = -10 \log_{10}(10^{-0.1SNR} + 10^{-0.1SIR}). \quad (10)$$

IV. 단말 이동성 및 수신신호 세기 예측 기법

4.1 LSTM

LSTM은 시간 연속성 특성을 가진 시계열 데이터를 처리하는데 효과적인 딥러닝 모델이다. LSTM은 기존의 RNN이 가지는 기울기 소실 문제를 해결하기 위해 게이트 메커니즘을 도입하였다. 이를 통해 데이터의 단기 및 장기적인 변화에 대하여 더 중요한 정보를 학습하고 기억한다. 그림 3은 LSTM 구조를 나타낸다.

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i), \quad (11)$$

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f), \quad (12)$$




그림 4. RSRP 예측 LSTM 모델 구조도
Fig. 4. RSRP predict LSTM model structure

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o), \quad (13)$$

$$\tilde{c}_t = \tanh(W_c[h_{t-1}, x_t] + b_c), \quad (14)$$

$$c_t = f_t * c_{t-1} + i_t * \tilde{c}_t, \quad (15)$$

$$h_t = o_t * \tanh(c_t). \quad (16)$$

LSTM에서 각 게이트는 활성화 함수를 통하여 정보를 얼마나 반영할지 결정한다. 수식 (11)의 입력 게이트 i_t 는 이전 시점 은닉 상태 h_{t-1} 와 현재 입력 x_t 에 대해서 입력 게이트의 가중치 W_i 와 입력 게이트 편향 b_i 을 기반으로 현재 입력 정보의 셀 상태 반영 정도를 결정한다. 수식 (12)의 망각 게이트 f_t 는 이전 은닉 상태 h_{t-1} 와 현재 입력 x_t 에 대해서 망각 게이트의 가중치 W_f 와 편향 b_f 를 통해 이전 셀 상태에서 제거할 정보를 결정한다. 수식 (13)의 출력 게이트 o_t 는 이전 은닉 상태 h_{t-1} 와 현재 입력 x_t 에 대해 출력 게이트의 가중치 W_o 와 편향 b_o 를 통하여 다음 시점 은닉 상태를 결정한다. 마지막으로, 시점 t 에서의 출력 h_t 는 수식 (14)와 (15)를 기반으로 수식(16)을 통해 결정된다^[7]. 수식 (14)의 후보 셀 상태 $\tilde{c}_t$ 는 이전 은닉 상태 h_{t-1} 와 현재 입력 x_t 에 대하여 후보 셀 상태의 가중치 W_c 와 편향 b_c 을 통해 입력 게이트를 통해 새로 추가될 정보를 계산한다. 수식 (15)의 현재 셀 상태 c_t 는 망각 게이트 f_t 와 이전 시점 셀 상태 c_{t-1} 를 통해 이전 셀 상태의 유지 비율을 반영




그림 5. 제안하는 CNN-LSTM 모델 구조도
Fig 5. Proposed CNN-LSTM model structure

하고, 입력 게이트 i_t 와 후보 셀 상태 $\tilde{c}_t$ 를 통해 새로운 정보 반영 비율을 결정한다. 수식 (16)의 은닉 상태 h_t 는 출력 게이트 o_t 와 현재 셀 상태 c_t 를 통해 계산되며, 이는 다음 시점으로 전달된다.

시계열 데이터의 장기적 의존성을 학습하는 LSTM 모델은 각 위성에 대한 단말의 시간에 따른 수신 신호 세기 변화를 학습하기에 적합하다. 그림 4는 단말 이동성에 따른 위성의 수신 신호 세기 예측을 위한 LSTM 모델 구조이다. 위성고도 및 단말의 위치 정보와 이때 단말의 수신 신호 세기 정보에 대한 시계열 데이터를 입력으로 받아 다음 시점에서 단말의 수신 신호 세기를 예측한다.

4.2 CNN-LSTM

LSTM 모델은 시계열 데이터 예측에 효과적이지만, 연속적으로 긴 시퀀스 모델 학습 과정에서 새로운 데이터에 대한 학습 성능이 좋지 않다. 또한 CNN과 비교하여 LSTM은 주어진 입력에서 가장 영향력 있는 feature를 추출하는 능력이 부족하다. CNN은 예측 성능이 약하지만, 시계열 데이터 분류에서 서로 다른 신호를 연관시키는 능력이 강하다^[18]. 이에 이동성이 큰 저 궤도 위성 네트워크에서 단말 이동성에 따른 수신신호를 예측하는데 예측 성능을 향상하기 위해 CNN-LSTM 기반 수신 신호 세기 예측 모델을 제안한다. 그림 5와 같이, 제안하는 CNN-LSTM 기법은 convolution layer를 추가하여 각 입력 특징에 대한 관계를 반영하여 LSTM layer에서 입력된 시계열 데이터에 대한 관계를 학습하고 다음 time step에서 단말이 수신할 수신 신호 세기를 예측한다^[19].

4.3 단말 이동성 및 수신 신호 세기 예측 시스템 모델

제안하는 CNN-LSTM을 통해 UE의 이동성 예측 데이터와, 위성 위치에 따른 UE 수신 신호 세기 데이터를




그림 6. 네트워크 시나리오
Fig 6. Network scenario




그림 7. 제안하는 RSRP 예측 모델 구조
Fig 7. Proposed RSRP predict model structure

산출하기 위해 본 논문에서는 그림 6과 같은 서로 다른 고도 및 궤도를 가진 저 궤도 위성군 환경을 가정한다. 각 위성은 global navigation satellite system (GNSS) 기능을 탑재하여 각 위성에 대한 위치 데이터를 주기적으로 지상 단말에 전송한다. 또한 위성의 위치 및 속도 데이터를 통해서 단말에 대한 위성의 LoS remain-time을 계산할 수 있다. 그림 7과 같은 절차를 기반으로 지상 단말은 자신과 각 위성의 위치 정보와 수신 신호 세기, 계산한 각 위성의 LoS remain-time을 기반으로 각 위성에 대한 수신 신호 세기를 예측한다.

V. 심층 강화학습 기반 핸드오버 최적화 기법

5.1 A3 핸드오버 기법

NTN에서 지상 UE는 지속적인 서비스를 유지하기 위해서는 LEO의 빠른 이동성을 고려하여 적절한 시점에 핸드오버를 수행하는 것이 중요하다. 주로 활용되는 핸드오버 이벤트인 A3 event는 target cell의 수신 신호 세기(u_t) 현재 서비스 중인 UE의 수신 신호 세기(u_s)와 handover margin(HOM)의 합보다 초과할 시 서비스 기지국이 핸드오버가 발생 되는 기준으로서 이는 수식 (17)로 정의한다.

$$u_t > u_s + HOM. \quad (17)$$




그림 8. DQN 알고리즘 구조도
Fig. 8. DQN algorithm structure

5.2 Deep Q-Network 기법

일반적인 심층 강화학습의 목표는 주어진 환경에서 강화학습 에이전트가 현재 상태(s_t) 공간에서 행동(a_t)을 통해 보상(r_t)을 최대화하는 정책(π)을 학습을 진행하는 것이 주된 목표다. DQN은 벨만 방정식을 기반으로 현재 상태에서 특정 행동을 수행하여 획득한 Q값을 최대화하는 Q-learning의 성능을 개선하기 위한 기법이다. DQN은 특정 상태에서의 행동 가치 함수

$$Q^\pi(s_t, a_t) = E_{s, a, \pi} \left[\sum_{i=t}^T \gamma^{i-t} r_i \right]$$

를 최대화하는 방향으로 학습을 진행한다. DQN의 주된 특징은, replay memory에 저장된 experience replay sample을 Q-network와 target network의 입력값이 되어 학습의 안정성을 향상하고, 손실 함수(L) 값을 최소화하는 행동을 선택할 수 있게 주기적으로 Q-network를 복제하여 생성되는 target network 구조를 통해 지나치게 급격한 업데이트를 방지하며, 빠른 학습이 가능한 것이 주된 특징이다. Replay buffer에 저장된 샘플을 활용하게 되면 데이터 효율성이 증가하고, 데이터 간의 상관성이 제거되며, 안정적이고 균등한 학습이 가능하다. Target network를 형성하는 기준 값인 target value는 수식 (18)와 같으며, 에이전트의 행동 값에 따른 DQN의 손실 함수(L)는 수식 (19)로 정의한다.

$$Y_t = r_t + \gamma \max_{a'} Q(s_{t+1}, a'; \theta), \quad (18)$$

$$L = (Y_t - Q(s_t, a_t; \theta))^2. \quad (19)$$

DQN의 알고리즘 절차는 환경 초기화, 현재 s_t 에서




그림 9. 제안하는 LSTM-DQN 융합 최적화 기법
Fig. 9. Proposed LSTM-DQN integrated optimization handover method

입실론 그리디 정책을 사용한 행동 a_t 를 선택하고, 보상 r_t 와 다음 상태 s_{t+1} 를 관찰한다. 이후, (s_t, a_t, r_t, s_{t+1}) 를 replay buffer에 저장하고 해당 buffer에서 mini-batch를 샘플링하여 Q-network를 학습한다. 손실 함수(L) 값을 계산하고 이를 기반으로 네트워크 파라미터(θ)를 업데이트 하며, 주기적으로 target network를 형성하는 방식으로 진행되며 알고리즘 개요도는 그림 8과 같다.

5.3 제안하는 이동성 예측 딥러닝 모델 기반 핸드오버 강화학습 융합 기법

본 논문에서는, 5.1 절에서 정의한 A3 핸드오버 기법을 기반으로 지상 UE 에이전트가 최적의 시점에 핸드오버를 수행하여 에이전트의 수신 신호 세기를 최대화하는 스케줄링 문제를 강화학습 DQN 알고리즘으로 최적화하는 것을 목표로 그림 9와 같이 제안한다¹⁹⁾. UE가 LEO의 이동성에 따른 수신 신호 세기를 최대화하기 위해 제안하는 DQN 기법에서 마르코프 결정 프로세스(Markov decision process, MDP)의 상태, 행동, 보상에 관한 정의는 다음과 같이 표현한다.

- 1) 상태(states): $s_t^{i,k} = [s_d^{i,k}, s_e^{i,k}, s_g^{i,k}, s_r^{i,k}]$ 로 정의한다. UE와 각 LEO 까지의 거리($s_d^{i,k}$), UE와 LEO 간 elevation angle($s_e^{i,k}$), UE의 수신 신호 세기($s_g^{i,k}$), 그리고 UE의 signal-to-interference-plus-noise 적으로 정보를 수집할 수 있도록 한다. 특히, UE가 LEO를 선택하는 과정에서 $s_e^{i,k}$ 의 값이 최소 30° ratio (SINR) 값($s_r^{i,k}$)으로 설정하여 에이전트가 지속 조건을 만족해야 핸드오버가 가능한 LEO로 분류하였다.




그림 10. 제안하는 시스템 모델
Fig. 10. Proposed system model

표 1. 3GPP 시스템 레벨 시뮬레이션 파라미터
Table 1. 3GPP system level simulation parameters

Parameter	Value
Satellite type & altitude	LEO 600 km
Satellite DL frequency	Ka-band(20 GHz)
Satellite EIRP density	4 dBW
Satellite tx max gain	58.5 dBi
Satellite beam diameter	20 km
UE characteristics	VSAT
UE rx antenna gain	39.7 dBi
UE noise figure	1.2 dB
T_0, T_a	290 K, 150 K

- 2) 행동(actions): $a_t^{i,k} = [a_m^{i,k}, a_h^{i,k}]$ 으로 정의한다. UE가 서비스 받을 LEO를 선택하는 스케줄링 관점에서 UE의 action($a_t^{i,k}$)으로는 현재 시점에서 서비스 중인 LEO 신호 세기($s_g^{i,k}$)가 좋으면 지속적으로 연결을 유지하는 행동($a_m^{i,k}$), s_e 의 각도가 최소 각도 30° 를 만족하여 연결 가능 후보 위성 중에서 핸드오버 조건 수식 (1)을 동시에 만족하여 핸드오버를 수행하는 행동($a_h^{i,k}$)으로 정의한다.
- 3) 보상(rewards): 본 논문에서 제시하는 심층 강화학습 기반 핸드오버 기법의 목표로 단말의 이동성 예측에 기반한 최적 시점의 핸드오버를 수행하는 것이 목표인 것을 고려하여, UE 에이전트의 수신 신호 세기(s_g) 및 데이터 전송 속도(ω_t)가 개선되는 방향으로 설계하였다. ω_t 는 채널 대역폭(B), 현재 기지국에 액세스 되어 있는 UE의 수(N_t), 그리고 s_r 간의 관계로 수식 (20)과 같이 정의한다.

표 2. LSTM 모델 학습 파라미터
Table 2. LSTM model learning parameters

Parameter	Value
Input Feature	8
Hidden Parameter	250
LSTM Layer	6
CNN Layer	1
Learning Rate	0.001
Batch Size	64
Dropout Rate	0.2
Time Step	0.1
Data Window	20

표 3. CNN-LSTM 모델 학습 파라미터
Table 3. CNN-LSTM model learning parameters

Parameter	Value
Input Feature	8
Hidden Parameter	250
LSTM Layer	6
CNN Layer	1
Learning Rate	0.001
Batch Size	64
Dropout Rate	0.2
Time Step	0.1
Data Window	20

$$\omega_t = \left(\frac{B}{N_t}\right) \times \log_2(1 + s_r^{i,k}). \quad (20)$$

UE 에이전트가 지속적으로 LEO로부터 서비스를 제공받을 수 있도록 서비스 지속 시간($\varphi_t^{i,k}$) 보상과, 빈번한 핸드오버 발생을 방지하기 위해 핸드오버 비용을 추가하여 에이전트가 최적의 타이밍에 핸드오버를 수행하여 데이터 전송 시간, 수신 신호 세기를 확보하고 서비스 지속 시간을 증가할 수 있도록 보상을 수식 (21)로 정의한다.

$$\begin{cases} \omega_t + \eta \varphi_t^{i,k} & \text{if } a_t = a_m, \\ \omega_t + \eta \varphi_t^{i,k} - C & \text{if } a_t = a_h. \end{cases} \quad (21)$$




그림 11. RSRP 예측 오차 누적 분포 함수

Fig. 11. RSRP predict error CDF




그림 12. RSRP 예측값과 실제값

Fig. 12. Predicted and actual values of RSRP

핸드오버 비용(C)은 에이전트의 액션이 핸드오버를 수행하였을 때만 부가하도록 하였고, 기중치 요소(η)를 설정하여 데이터 전송 속도와 서비스 제공 시간을 적절히 조절하였다. 에이전트가 핸드오버 수행하는 액션(a_h)을 많이 수행하면 할수록 핸드오버 비용의 패널티로 인해, 획득하는 보상은 감소하게 된다. 따라서, 서비스 중인 serving cell과 target cell이 영역이 혼재하는 위치에 있는 상황에서, UE 에이전트는 학습 시 얻는 패널티 보상 C 를 기반으로 더욱 최적화된 타이밍에 target cell 혹은 위성으로 핸드오버를 수행하도록 설계하였다.

VI. 시뮬레이션 결과

6.1 시뮬레이션 환경

본 논문에서 제안하는 단말 이동성 예측 데이터 기반 강화학습 시스템 모델은 그림 10과 같다. 지상 UE 에이전트 위로 각기 다른 LEO 위성 궤도가 존재하며, 시계열적 위성 궤도 데이터를 기반으로 서로 다른 궤도로 LEO 위성 시나리오에서 RSRP 예측 딥러닝 학습을 진행하였다. UE는 학습이 수행되는 스텝마다 LSTM 네트워크를 통과한 위성 궤도 데이터를 수신하며, UE는 자신의 이동성 데이터를 교환하는 방식을 수행한다. 강화학습 UE 에이전트는 RSRP 예측 데이터를 입력값으로 받고, 후보 LEO 위성 중, 수식 (17) 조건을 만족할 때 핸드오버 수행을 결정하며, 빈번한 핸드오버가 발생하지 않도록 핸드오버 발생 시 부과되는 패널티를 달리 하면서 실험을 진행하였다. LEO와 에이전트 사이 채널 모델링은 모두 3GPP 표준에 기반하여 설계하였고, 해당 파라미터는 표 1과 같다. 제안하는 기법은 python 환경에서 진행하였으며, 상세 학습 하드웨어 스펙은 Intel core i7-13700KF, RAM 64GB, NVIDIA GeForce RTX 4060 Ti 환경에서 진행하였다.

6.2 단말 수신신호세기 예측 기술 결과

단말과 위성의 이동에 따른 단말의 수신 신호 세기 예측을 위한 LSTM 모델의 학습 파라미터는 표 2에, CNN-LSTM 모델의 학습 파라미터는 표 3에 나타내었다. 시뮬레이션 시간 간격은 0.1초로 설정하였으며, 데이터 윈도우 크기는 20으로 설정하였다. 따라서 제안하는 모델은 20초 동안의 위성 및 단말의 위치 정보를 기반으로 향후 위성에 대한 단말의 RSRP를 예측한다. 그림 11은 각 모델의 위성에 대한 단말 RSRP 예측 오차값의 누적 분포 함수를 나타낸다. 기존의 LSTM 모델

표 4. 강화학습 파라미터

Table 4. Reinforcement learning parameters

Parameter	Value
Batch size	32
Learning rate	0.001
Discount factor	0.98
Replay buffer size	50,000




그림 13. 강화학습 보상 수렴도

Fig. 13. Reinforcement learning reward convergence

은 넓은 오차 범위를 보이며, 이는 LSTM 모델의 데이터에 대한 학습 과정에서의 불안정성을 나타낸다. 반면, 제안하는 CNN-LSTM 모델의 RSRP 예측 오차값의 약 80%가 25 dBm 이하로, 매우 높은 예측 정확도를 보인다. 특히, RSRP는 노이즈 및 셰도잉으로 인해 짧은 시간에 큰 값의 변화를 보일 수 있음에도 불구하고, CNN-LSTM 모델은 이를 효과적으로 학습하여 높은 예측 정확도를 나타낸다.

그림 12는 실제 RSRP 값과 예측된 RSRP 값을 나타낸 것이다. 위성의 이동에 따른 RSRP 변화양상을 비교해보았을 때, 기존의 LSTM 모델은 위성의 이동에 따른 RSRP 변화양상을 학습하지 못하고 일직선 형태의 RSRP 예측값을 보인다. 반면에 CNN-LSTM 모델은 데이터의 공간적 특성 및 시간적 특성을 효과적으로 학습하여 위성의 이동에 따른 RSRP 변화양상을 정확히 예측한다. 이는 CNN-LSTM 모델이 핸드오버를 결정하는 데 있어 신뢰성 있는 RSRP 예측값을 제공할 수 있음을 나타낸다. 따라서 제안하는 CNN-LSTM 모델이 핸드오버 최적화를 위한 단말 및 위성의 이동성을 반영한 RSRP 예측 모델에 대한 적합성을 확인하였다.




그림 14. UE 에이전트 수신 RSRP

Fig. 14. UE agent received RSRP




그림 15. UE 에이전트 SINR

Fig. 15. UE agent SINR

6.3 이동성 예측 데이터 기반 강화학습 핸드오버 최적화 결과

핸드오버 최적화 기법을 도출하기 위한 강화학습 기법의 학습 파라미터는 표 4를 활용하였다. UE 에이전트는 현재 서비스 중인 서빙 위성과 핸드오버를 진행한 타겟 위성 간 최적 타이밍의 핸드오버를 수행함으로써, ω_t 를 최대화 하는 방향으로 학습을 진행하였고, 수식 (20)의 값의 범위를 0~1 사이로 선형화하여 안정적으로 학습하도록 하였다. 강화학습 핸드오버 최적화 기법의 성능 평가를 위해 reward 구성 요소 중 handover cost에 따른 강화학습 모델의 성능 분석을 진행하였으며, 성능 분석 결과는 그림 13과 같다. 그림 13과 같이, handover cost가 0일 경우 잦은 핸드오버가 발생할 가능성이 크기 때문에, 가장 수렴이 늦게 되는 경향을 확인할 수 있었다. 더하여, handover cost를 지나치게 부여한 경우

보다, 적당한 handover cost를 부여했을 경우, 다른 cost에 비해 가장 빨리 수렴한 것을 확인할 수 있다. Handover cost에 따른 보상 함수 수렴도 결과에 따른 지상 UE agent의 수신 신호 세기 결과는 그림 14와 같다. 학습 결과, 적당한 handover cost를 부여한 경우의 agent 수신 신호 세기가 가장 빠르게 수렴하는 경향을 확인했다. 더하여 에피소드가 진행되는 동안 수신 신호 세기가 일정 경향 수렴되는 이유는 정해진 학습 episode 동안 동일 위성의 예측 위치 데이터를 활용하여 학습하기 때문인 것으로 파악된다. 이에, RSRP가 일정 수렴하는 경향은 최적의 타이밍에 타겟 LEO 위성에 핸드오버를 수행하여 도출되었다고 할 수 있다. 그림 15는 수식 (8), (9), (10)을 통해 계산된 UE 에이전트의 SINR 결과 그래프이다. 그림 14와 같이 그림 15의 결과 그래프도 마찬가지로, 수렴하는 경향이 보인다는 것은 최적의 타이밍에 핸드오버를 수행하였기 때문인 것으로 유추할 수 있다. 더불어, NTN LEO 네트워크에서는 SINR 값이 -8 dB 이하로 측정된 값은 무선 링크 실패 (radio link failure, RLF)로 간주한다^[20]. 그러나, 제안하는 DQN 기반 강화학습 핸드오버 최적화 기법은 해당 범위에 크게 상회하는 값인 13 dB에 수렴하는 것을 보아 UE 에이전트가 최적의 타이밍에 핸드오버를 수행하여 수신 신호 세기 및 데이터 전송률을 극대화하는 제안하는 강화학습 기법의 강건성을 확인할 수 있다.

VII. 결 론

본 논문에서는 LEO의 빠른 이동성과 지상 단말의 움직임에 따른 신호 세기 예측 데이터를 LSTM 네트워크를 통해 예측하고, 예측 데이터를 기반한 핸드오버 최적화 강화학습 기법을 제안하였다. 먼저, 제안하는 CNN-LSTM 모델은 위성의 이동에 따른 단말의 수신 신호 세기 변화양상을 예측 성공률이 높은 것을 확인했고, 이를 통해 추출된 예측 데이터를 강화학습 상태 입력값에 반영하여, 빠르고 정확한 타이밍에 핸드오버를 발생할 수 있도록 하였다. 성능 분석 결과, 적정선의 핸드오버 비용을 추가한 보상 함수 설계를 통해 핸드오버 최적화 강화학습 모델을 추출하였다.

제안하는 기법을 통해 향후 정지궤도 위성과 저궤도 위성이 혼재하는 시나리오에서 서로 다른 주파수 대역을 사용하는 시나리오에서 핸드오버 이슈, 천음속 급이동체의 무작위 이동성으로 인한 핸드오버 이슈가 존재하는 상황에서 최적 핸드오버 연구를 멀티 에이전트 심층 강화학습 기법을 적용하는 방향으로 확장한다.

References

- [1] Starlink, Sep. 2021, [Online] Available: <https://www.starlink.com>.
- [2] A. Roy, H. B. Nemade, and R. Bhattacharjee, "Symmetry chirp modulation waveform design for LEO satellite IoT communication," *IEEE Commun. Lett.*, vol. 23, no. 10, pp. 1836-1839, Oct. 2019. (<https://doi.org/10.1109/LCOMM.2019.2933211>)
- [3] C. Han, L. Huo, X. Tong, H. Wang, and X. Liu, "Spatial anti-jamming scheme for Internet of satellites based on the deep reinforcement learning and stackelberg game," *IEEE Trans. Veh. Technol.*, vol. 69, no. 5, pp. 5331-5342, May 2020. (<https://doi.org/10.1109/TVT.2020.2982672>)
- [4] S. Zhang, A. Liu, C. Han, X. Ding, and X. Liang, "A network-flows-based satellite handover strategy for LEO satellite networks," *IEEE Wireless Commun. Lett.*, vol. 10, no. 12, pp. 2669-2673, Dec. 2021. (<https://doi.org/10.1109/LWC.2021.3111680>)
- [5] 3GPP TR 38.821 v16.1.0, "Solutions for NR to support non-terrestrial networks(NTN) (Release 16)," 3rd Generation Partnership (3GPP), Technical Report 38.821, May 2021. (<https://portal.3gpp.org/>)
- [6] H. Lee and J. Kim, "Survey on deep reinforcement learning applied for LEO satellites," *J. KICS*, vol. 48, no. 2, pp. 196-205, Feb. 2023. (<https://doi.org/10.7840/kics.2023.48.2.196>)
- [7] H. Li, Y. Liu, J. Shi, Y. Zhou, R. Zhuo, and S. Li, "Multimodal LSTM forecasting for LEO satellite communication terminal access," in *Proc. 2023 IEEE 97th VTC2023-Spring*, Florence, Italy, 2023. (<https://doi.org/10.1109/VTC2023-Spring57618.2023.10199836>)
- [8] G.-Y. Chang, C. K. Hung, and C.-H. Chen, "A CSI prediction scheme for satellite-terrestrial networks," *IEEE Internet of Things J.*, vol. 10, no. 9, May 2023.

- (<https://doi.org/10.1109/JIOT.2022.3229683>)
- [9] J. Lee, C. Park, S. Park, and A. Molish, "Handover protocol learning for LEO satellite networks: Access delay and collision minimization," *IEEE Trans. Wireless Commun.*, vol. 23, no. 7, pp. 7624-7637, Jul. 2024.
(<https://doi.org/10.1109/TWC.2023.3342975>)
- [10] N. Badini, M. Jaber, M. Marchese and F. Patrone, "User centric satellite handover for multiple traffic profiles using deep Q-learning," *IEEE Trans. Aerospace and Electr. Syst.*, Early Access.
(<https://doi.org/10.1109/TAES.2024.3434771>)
- [11] F. Yang, W. Wu, Y. Gao, Y. Sun, T. Sun, and P. Si, "Multi-agent fingerprints-enhanced distributed intelligent handover algorithm in LEO satellite networks," *IEEE Trans. Veh. Technol.*, vol. 73, no. 10, pp. 15255-15269, Oct. 2024.
(<https://doi.org/10.1109/TVT.2024.3412287>)
- [12] N. Badini, M. Jaber, M. Marchese, and F. Patrone, "Reinforcement learning-based load balancing satellite handover using NS-3," in *Proc. IEEE ICC*, Rome, Italy, 2023.
(<https://doi.org/10.1109/ICC45041.2023.10279521>)
- [13] Y. Cao, S. Lien, and Y. C. Liang, "Deep reinforcement learning for multi-user access control in non-terrestrial networks," *IEEE Trans. Commun.*, vol. 69, no. 3, Mar. 2021.
(<https://doi.org/10.1109/TCOMM.2020.3041347>)
- [14] 3GPP TR 38.811 v 15.4.0, "Study on new radio(NR) to support non-terrestrial networks (Release 15)," 3rd Generation Partnership (3GPP), Technical Report 38.811, Sep. 2020.
(<https://portal.3gpp.org/>)
- [15] B. Lee, N. Lee, J.-H. Kim, and W. Shin, "A survey of LEO satellite networks for 5G and beyond: Channel modeling, research trends, and open challenges," *J. KICS*, vol. 46, no. 7, pp. 1097-1108, Jul. 2021.
(<https://doi.org/10.7840/kics.2021.46.7.1097>)
- [16] 3GPP TR 38.863 v 18.2.0, "Non-terrestrial networks(NTN) related RF and co-existence aspects(Release 18)," 3rd Generation Partnership(3GPP), Technical Report 38.864, Jun. 2024.
(<https://portal.3gpp.org/>)
- [17] K. Greff, R. K. Srivastava, J. Koutnik, B. R. Steunebrink, and J. Schmidhuber, "LSTM: A search space odyssey," *IEEE Trans. Neural Netw. and Learn. Syst.*, vol. 28, no. 10, pp. 2222-2232, Oct. 2017.
(<https://doi.org/10.1109/TNNLS.2016.2582924>)
- [18] J. Wang, Y. Chen, S. Hao, X. Peng, and L. Hu, "Deep learning for sensor-based activity recognition: A survey," *Pattern Recognition Lett.*, vol. 119, pp. 3-11, Mar. 2019.
(<https://doi.org/10.1016/j.patrec.2018.02.010>)
- [19] M. Alhussein, K. Aurangzeb and S. I. Haider, "Hybrid CNN-LSTM model for short-term individual household load forecasting," *IEEE Access*, vol. 8, pp. 180544-180557, Oct. 2020.
(<https://doi.org/10.1109/ACCESS.2020.3028281>)
- [20] 3GPP TR 36.839 v11.1.0. "Evolved universal terrestrial radio access(E-UTRA):Mobility enhancements in heterogeneous networks (Release 11)," 3rd Generation Partnership (3GPP), Technical Report 36.839, Dec. 2012.
(<https://portal.3gpp.org/>)

김 준 영 (Junyoung Kim)



2023년 2월 : 한림대학교 소프트웨어학부 학사

2023년 3월~현재 : 아주대학교
AI융합네트워크학과 석사과정
<관심분야> 모빌리티, 자율주행, 저궤도 위성통신, 인공지능

장 희 연 (Huiyeon Jang)



2023년 8월 : 아주대학교 전자
공학과 학사
2023년 9월~현재 : 아주대학교
AI융합네트워크학과 석사과
정
<관심분야> 저궤도 위성통신
시스템, 이동통신

신 민 수 (Minsu Shin)



2000년 8월 : 한국항공대학교 항
공전자공학과 석사
2011년 8월 : 충남대학교 정보통
신공학과 박사
2000년 8월~현재 : 한국전자통
신연구원 책임연구원

<관심분야> 위성통신시스템, 위성통신네트워크, 저궤
도위성통신

조 인 섭 (In-Sop Cho)



2011년 2월 : 고려대학교 전파
통신공학과 학사
2021년 2월 : 고려대학교 컴퓨
터·전파통신공학과 박사
2021년 3월~2021년 12월 : 한
국전력공사 전력연구원 선임
연구원

2022년 1월~현재 : 한국전자통신연구원 선임연구원
<관심분야> 위성통신시스템, 네트워크 최적화

정 소 이 (Soyi Jung)



2013년 2월 : 아주대학교 전자
공학과 학사
2015년 2월 : 아주대학교 전자
공학과 석사
2021년 2월 : 아주대학교 전자
공학과 박사
2021년 3월~2021년 8월 : 고려

대학교 정보통신기술연구소 연구교수
2021년 3월~2022년 8월 : 한림대학교 소프트웨어학
부 조교수
2021년 9월~2022년 8월 : University of California
at Irvine 방문교수
2022년 9월~현재 : 아주대학교 전자공학과 조교수
<관심분야> 모빌리티, 자율주행, 이동통신, 저궤도
위성통신, 인공지능