

UAV 통신 환경에서 GRU 기반 최적 송신안테나 선택

홍석진¹, 윤웅종¹, 오정은², 정의림³

¹한밭대학교 인공지능학과 석사과정, ²한밭대학교 모바일융합공학과 석사과정,

³한밭대학교 인공지능소프트웨어학과 교수

GRU Based Optimum Transmission Antenna Selection in UAV Communication Environments

Seok-Jin Hong¹, Woong-Jong Yun¹, Jeong-Eun Oh², Eui-Rim Jeong³

¹Master's Degree, Department of Artificial Intelligence, Hanbat University

²Master's Degree, Department of Mobile Convergence and Engineering, Hanbat University

³Professor, Department of Artificial Intelligence Software, Hanbat University

요약 본 논문에서는 무인 항공기(Unmanned Aerial Vehicle, UAV) 통신 환경에서 GRU(Gated Recurrent Unit) 기반 최적의 송신안테나를 선택하는 기법을 제안한다. 고려된 통신시스템은 다중 안테나를 사용하며, 시분할 이중화(TDD)를 통해 양방향 통신을 수행한다. 이 시스템은 다중 안테나를 사용하여 신호를 수신한 후, 안테나 별 수신된 신호의 신호 대 잡음 비(SNR: signal to noise ratio)를 기반으로 미래 최적의 송신안테나를 선택하여 전송한다. 송신안테나를 선택하는 기존의 방법으로는 과거 수신한 SNR의 평균을 사용하는 방법, 가장 최근에 수신한 신호의 SNR을 사용하는 방법 및 합성곱 신경망(Convolutional Neural Network, CNN)을 사용하여 송신안테나를 선택한다. 제안된 방법과 기존 방법의 성능은 모의실험을 통해 비교한다. 실험 결과 GRU에 기반 제안 방법은 광대역과 협대역 모두에서 기존 방법보다 평균 안테나 선택 정확도가 우수하다.

주제어 : 안테나 다이버시티, 안테나 선택, 다중입출력, 딥러닝, 순환 신경망, GRU

Abstract This paper proposes a technique for selecting the optimal transmission antenna in a UAV communication environment based on the Gated Recurrent Unit (GRU) model. The considered communication system employs multiple antennas and operates in a bidirectional communication mode through Time-Division Duplexing (TDD). In this system, all antennas receive signals, and the optimal transmission antenna is selected based on the Signal-to-Noise Ratio (SNR) of the past received signals for subsequent transmission. Existing methods for selecting the transmission antenna include the average method, which uses the average SNR of received signals, the recent value method, which uses the SNR of the most recently received signal, and a method based on CNN. The experimental results show that the proposed GRU-based approach outperforms the existing methods in terms of antenna selection accuracy in both wideband and narrowband scenarios.

Key Words : Antenna Diversity, Antenna Selection, MIMO, Deep Learning, RNN, Gated Recurrent Unit

* This research was supported by Research Program through the National Research Foundation of Korea (NRF) funded by the Ministry of Science and ICT (No. NRF-2021M1B3A3102358).

* Corresponding Author : Eui-Rim Jeong (erjeong@hanbat.ac.kr)

Received November 10, 2023

Revised December 12, 2023

Accepted December 18, 2023

Published December 28, 2023

I. 서론

최근 수십 년 동안, 무인 항공기 (Unmanned Aerial Vehicle, UAV)는 교통, 군사, 구조, 농업 및 통신시스템을 포함한 다양한 분야에 적용되어왔다[1,2]. 특히, UAV 통신은 지상 통신과 구별되는 뛰어난 통달거리 및 통신 안정성을 인정받아 미래의 무선통신 시스템을 위한 핵심 요소 중 하나로 인식되고 있다. 이에 UAV 중계 네트워크, UAV 지원 기지국 및 UAV 기반 센서 네트워크를 통한 데이터 수집과 같은 응용 프로그램이 연구되었다[3-6]. 이때, UAV는 지상 통신시스템과 달리 몇 가지 기본 특성을 고려해야 한다. 먼저, UAV와 지상국(Ground Station, GS) 사이의 공대지 채널을 검사하고 추적해야 한다[7,8]. 또한 UAV 통신의 이동성은 고정 지상 네트워크의 이동성보다 훨씬 높다. 따라서 UAV 통신시스템에서 도플러 효과로 인한 성능 저하를 완화하기 위한 기술이 제안되었다[9]. 마지막으로, UAV 하드웨어의 배터리 기능을 고려하여 UAV의 운영 시간을 늘리기 위해서는 에너지 효율적인 통신시스템 설계가 필요하다[10-12].

UAV 통신시스템에서 에너지 소비를 줄이면서도 통달거리 확장 및 안정적인 통신을 하는 한 가지 방법으로 송신안테나 선택 (Transmit, Antenna Selection, TAS)이 고려될 수 있다[13]. TAS는 설치된 다수의 안테나 중 하나를 선택하여 송신하는 기술이다. TAS는 하드웨어 복잡성과 무선 주파수 채널들의 수를 줄이기 위한, 간단하면서도 효과적인 방법이다. 인공지능의 급속한 성장과 함께 여러 연구에서 기계 학습 알고리즘을 안테나 선택에 대한 연구를 진행하고 있다[14-16]. [14]에서는 다중 클래스 지원 벡터 기계(Support vector machine, SVM) 기술이 TAS에 처음 사용된다. 또한 SVM 및 심층 신경망 알고리즘을 전 이중 공간 변조 시스템에서 TAS에 사용하는 연구도 발표되었다[15]. [16]에서는 안테나 선택 및 하이브리드 빔포머 결합 시스템에서 각각 합성곱 신경망(Convolutional Neural Network, CNN)과 비지도 학습을 사용하는 기술을 제안한다. 그러나 이러한 연구에서는 이동성을 고려한, 즉, 시간에 따라 변하는 채널을 고려하여 연구되지는 않았다. 반면, 고속 이동 환경에서 송신안테나

선택을 위한 CNN 연구가 진행되었다[17]. [17]에서는 입력데이터로 다수의 안테나에서 과거 수신된 신호의 SNR (signal to noise ratio)을 기록한 시계열 데이터를 사용한다. 시계열 데이터 처리에는 순환 신경망(Recent Neural Network, RNN)이 효과적이라는 사실은 널리 알려져 있다[18,19,20].

본 논문에서는 RNN의 일종인 GRU(Gated Recurrent Unit) 기반 송신안테나 선택을 제안한다. 입력데이터는 과거부터 현재까지의 수신 신호의 SNR이고, 출력은 미래 송신 시점의 각 안테나 별 SNR 예측값이다. 안테나 선택은 예측 SNR 중 가장 높은 SNR을 보이는 안테나를 선택하여 전송한다. 비교 대상인 기존 연구 방법으로는 수신한 SNR의 평균을 사용하는 평균값 방법, 가장 최근에 수신한 신호의 SNR에 기반하는 최근값 방법 및 CNN 방법이 있다. 컴퓨터 모의실험을 통해 기존의 방법과 제안 방법의 성능 비교를 진행한다. 모의실험은 광대역과 협대역 신호에 대해 각각 진행하고, 이동속도에 따라 비교한다. 모의실험 결과에 따르면, 제안하는 GRU 기반 TAS 사용 시 기존의 모든 방법보다 우수한 성능을 보인다. 기존 유사 연구인 CNN 기술과 비교할 때, 협대역에서는 송신안테나 선택 정확도가 평균 3.149% 더 우수하고, 광대역에서는 0.130% 더 우수하다.

본 논문의 구성은 다음과 같다. II절에서 제안하는 시스템 모델에 대해 설명하고 III절에서 GRU 기반 송신안테나 선택 방법을 설명한다. IV절에서는 이동 환경에서 제안하는 방법과 기존 방법의 모의실험 결과를 통한 성능을 보이고, V절에서 결론을 맺는다.

II. 시스템 모델

UAV의 움직임에 따라 부착된 다중 안테나를 이용하여 송신안테나를 선택하는 것은 통신 신뢰도를 높이고 전송속도를 최적화하는 효과를 볼 수 있다. TDD(Time Division Duplexing) 환경에서는 송신과 수신 주파수채널이 동일하여 각 안테나의 채널의 품질을 기반으로 미래 송신 시점에서 최적의 송신안테나를 선택할 수 있다. 이동 환경에서는 채널의 품질이 빠르

게 변화하므로 현재 가장 최적인 안테나가 미래 송신 시점에 반드시 최적의 안테나가 아닐 수 있다. 따라서 시간에 따라 변화하는 채널 품질의 추이를 보고 미래의 송신안테나를 선택해야 한다. 본 연구에서는 이동 통신 환경에서 다중 안테나를 이용하여 신호를 수신할 때, 과거에 수신한 신호의 안테나 별 SNR 정보를 기반으로 미래 송신안테나를 선택하는 방법을 제안한다.




Fig. 1. Proposed system model

Fig. 1은 제안하는 송신안테나 선택 시스템 블록도이다. 안테나 개수는 M 개이다. M 개의 수신안테나에서 각각 SNR을 측정한다. 일정 시간 간격으로 측정하여 얻은 SNR을 결합하여 행렬 \mathbf{S} 를 생성하고, 데이터를 전처리를 거친 후 최종 입력신호를 완성한다. 이 신호를 RNN기반 GRU 알고리즘에 입력하여 각 안테나별 SNR을 추정한 후 송신안테나를 선택한다.

측정한 SNR 정보는 $r_m(t)$ 으로 표현할 수 있다. $r_m(t)$ 은 수신받은 시간 t 에서 m 번째 안테나로 수신한 SNR 값에 대한 벡터 신호이다. 모든 안테나에 대한 SNR 벡터 신호 $r_m(t)$ 를 합쳐 하나의 행렬 신호를 만들 수 있다. 입력데이터 \mathbf{R} 는 다음과 같이 구성된다.

$$\mathbf{R} = \begin{bmatrix} r_0(t) \\ r_1(t) \\ \vdots \\ r_{M-1}(t) \end{bmatrix} = \begin{bmatrix} r_{0,0} & r_{0,1} & \cdots & r_{0,N-1} \\ r_{1,0} & r_{1,1} & \cdots & r_{1,N-1} \\ \vdots & \vdots & \ddots & \vdots \\ r_{M-1,0} & r_{M-1,1} & \cdots & r_{M-1,N-1} \end{bmatrix} \quad (1)$$

입력데이터 \mathbf{R} 의 구조는 행렬로 구성되어 있으며, 행은 수신안테나에서 샘플링된 N 개의 SNR을 의미하며, 열은 안테나의 개수 M 개에서 샘플링된 수신 SNR 값으로 구성된다. 행렬의 원소 $r_{m,n}$ 은 m 번째 안테나에서 n 번째 시점의 SNR 값을 나타낸다.




Fig. 2. Example of \mathbf{R} in proposed method

Fig. 2는 관찰 시간 T_{obs} 동안 수신받은 데이터를 전처리한 입력데이터 \mathbf{R} 의 예시이다. 실제 상황에서는 데이터 손실이 종종 발생한다. 이러한 손실이 발생하는 이유는 특정 시간에서 수신 데이터가 없으면 SNR 값도 측정할 수 없기 때문이다. 입력데이터 \mathbf{R} 은 실제 상황을 반영하여, 데이터의 회색 블록은 수신 SNR이 존재하는 경우이고, 하얀 블록은 수신 SNR이 존재하지 않는 경우이다. 본 연구에서 해결해야 할 문제는 송신 시간 N 에서 과거 수신받은 SNR을 기반으로 최적의 송신안테나를 선택하는 것이다. 이 문제를 풀기 위해 RNN을 통한 미래 송신시점에서의 각 안테나 별 SNR의 예측을 제안한다. 이 SNR 예측 값을 기반으로 가장 높은 SNR의 안테나를 선택한다. RNN 출력의 정답은 다음과 같이 \mathbf{y} 로 정의한다.

$$\mathbf{y} = [r_{0,N} \ r_{1,N} \ r_{2,N} \ \cdots \ r_{M-1,N}] \quad (2)$$

정답 벡터 \mathbf{y} 는 $M \times 1$ 크기를 가지며, \mathbf{y} 의 원소는 M 개의 안테나에 대한 N 시점에서의 SNR로 구성된다. 예를 들어 수신안테나 개수가 4개인 환경에서 샘플링된 SNR의 개수가 100일 경우 \mathbf{S} 의 크기는 4×100 이 되며, \mathbf{y} 는 101번째 시간에서의 SNR 값을 예측하게 된다. 앞서 설명한 바와 같이 수신 SNR을 기록하지 못하여 손실된 데이터는 인공지능 입력에 적합하지 않아 전처리가 필요하다. 본 논문에서 제안하는 전처리 방법은 선형 보간 및 엷지 제로 방법이다.




Fig. 3. Example of Interpolation method

Fig. 3은 데이터 보간 방법의 예시를 제시한다. 회색 영역은 데이터를 수신받은 상황을 가정하고, 흰색 영역은 데이터를 수신받지 못한 경우를 보인다. 제안하는 선형 보간 및 엷지 제로 방법은 두 가지 기술을 결합하여 사용한다. 우선 입력데이터의 중앙 부분은 이전에 수신된 SNR 값과 이후에 수신된 SNR 값 사이를 선형으로 보간한다. 그 후, 입력데이터의 양 끝단에 대해, 측정하지 못한 SNR 값을 0 dB로 채운다. 선형 보간 및 엷지 제로 방법을 사용하여 데이터를 전처리한 후, RNN에 기반하여 SNR을 예측한다. 모든 안테나에 대한 예측 SNR 값을 기반으로 최대 SNR 값을 갖는 안테나를 선택할 수 있다.

III. GRU 기반 송신안테나 선택 방법

3.1 기존 송신안테나 선택 방법

기존 송신안테나 선택 방법은 총 세 가지이다. 첫 번째 방법은 최근값 방법이다. 최근값 방법은 가장 최근에 측정된 수신 SNR을 송신 시 정답 SNR로 예측한다. 두 번째 방법은 평균값 방법으로 설정한 시간동안 측정된 수신 SNR의 평균을 송신 시 정답 SNR로 예측한다. 마지막으로 CNN을 사용한 안테나 선택 방법이 있다. CNN 기반 안테나 선택 방법은 제안하는 RNN 방법과 마찬가지로 미래 송신 시점에서 SNR 예측을 수행하며 이를 바탕으로 최적의 송신안테나를 선택한다. 구체적으로 CNN 회귀 모델을 사용하여 미래 SNR 값을 예측하고, 예측된 SNR 중 가장 높은 값을 갖는 안테나를 송신안테나로 선택한다.

3.2 제안하는 송신안테나 선택 방법




Fig. 4. GRU(Gated Recurrent Unit)

본 논문에서 제안하는 방법은 RNN을 활용하여 최적의 송신안테나를 선택한다. 제안 방법은 기존의 CNN 기반 송신안테나 선택 방법과 동일한 방식으로 전처리한 수신 SNR 행렬을 입력으로 하여 미래 SNR을 예측한다. 제안하는 RNN 모델은 신호의 대역폭에 따라 신경망 모델을 최적화하여 적용한다.

Fig. 4는 RNN 모델 중 하나인 GRU이다. GRU 알고리즘은 LSTM(Long Short-Term Memory)과 같은 RNN의 단기기억 문제의 해결책으로 고안되었다. Gate 구조가 적용된 RNN 일종으로 LSTM보다 학습에 사용될 게이트와 파라미터가 적어 간결함에도 불구하고 속도가 빠르며 LSTM과 유사한 성능을 가져 본 연구에서는 GRU 모델을 사용한다. 본 연구에서 협대역과 광대역, 두 가지 대역폭을 고려하고, 각각의 대역폭에 대한 GRU 모델은 다른 네트워크 구조를 갖는다.

IV. 모의실험

4.1 모의실험 환경

모의실험을 위해 MATLAB을 사용하여 데이터를 생성하고, TensorFlow 2.0을 활용하여 신경망 모델을 학습하고 검증하며, 성능 평가를 수행한다.

Table 1. Training data generation parameters

Parameters	Values	
	Wideband	Narrowband
Number of Rx antenna (M)	4	
Number of Tx antenna (M_t)	1	
Bandwidth	2MHz	25kHz
Carrier frequency	512MHz	88MHz
Channel model	Rayleigh (ITU Vehicular A) / Rician	
K-factor of Rician channel	14dB	
Number of time step (N)	100	
SNR range	0 ~ 30dB	
Speed	0 ~ 100km/h	
Probability of signal reception	10 ~ 100%	
LoS probability	50%	

Table 1은 모의실험의 통신 신호 파라미터를 나타낸다. 수신안테나의 수(M)는 4개이다. 모두 지향성을 갖는 안테나로 가정되며, UAV의 표면에 90° 씩 방향 차이를 갖도록 설치한다. 송신안테나의 수(M)는 1개이다. 4개의 안테나 중에서 최적의 안테나 1개를 선택하여 송신을 수행한다. 실험에서는 2가지 신호 대역폭, 즉 광대역과 협대역을 고려한다. 광대역의 경우 대역폭은 $2MHz$ 이며, 반송파 주파수는 $512MHz$ 로 가정한다. 협대역의 경우 대역폭은 $25kHz$ 이며, 반송파 주파수는 $88MHz$ 로 설정한다. 채널 모델은 가시선(Line of Sight, LoS)와 비가시선(Non-LoS) 사이에서 무작위로 선택되며, 레일리(ITU Vehicular A)와 라이시안 채널 모델을 활용한다. 라이시안 채널의 K 지수는 $14dB$ 이다. 입력데이터의 길이(N)는 100으로 설정한다. 입력 데이터에는 채널 모델에서 샘플링 간격에 따라 생성된 신호의 수신 SNR을 기록하며, 각 생성 신호의 평균 SNR은 $0 \sim 30dB$ 에서 무작위로 선택한다. 이동속도는 최소 $0km/h$ 에서 최대 $100km/h$ 의 범위에서 무작위로 선택하고, 각 시간(t)에서의 수신 확률(수신 SNR 존재 확률)은 $10 \sim 100\%$ 에서 무작위로 선택한다. 이동속도와 신호의 평균 SNR은 매 훈련 샘플 생성 시마다 무작위로 선택한다. 해당 훈련 샘플이 가시선 환경과 비가시선 환경으로 선택될 확률은 $1 : 1$ 이다.

4.2 인공지능 모델 학습

제안하는 RNN 모델은 모의실험 환경 파라미터를 기반으로 생성한 200,000개의 학습 데이터와 20,000개의 검증 데이터로 훈련한다. 모델에 입력하는 데이터는 100×4 의 구조이며, 평균 제곱 오차(Mean Squared Error, MSE) 손실 함수를 사용한다. 해당 함수는 수식 (3)으로 표현할 수 있다.

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (3)$$

n 은 데이터의 수이고, \hat{y}_i 은 모델의 예측 결과, y_i 은 실제 데이터의 정답 값이다. MSE 손실 함수는 예측값과 실제값의 차이를 제공한 후, 평균을 취하여 손실값

을 계산한다.

광대역 모델은 총 5개의 GRU 층을 사용하며, 학습 파라미터로 에폭은 500, 배치크기는 512, 옵티마이저는 Adam, 활성화 함수는 Tanh, 학습률은 0.001로 설정한다. 다음으로 협대역에서 사용한 모델은 총 4개의 GRU 층을 사용하며 에폭은 600, 배치크기는 512, 옵티마이저는 Adam, 활성화 함수는 Tanh, 학습률은 0.001로 설정한다.

4.3 모의실험 결과

제안 방법의 성능 평가는 훈련 데이터와 같은 파라미터를 사용하여 생성한 테스트 데이터로 수행한다. 이동속도에 따른 성능 변화를 실험하기 위해 이동속도 $0 \sim 100km/h$ 범위의 테스트 데이터를 $10km/h$ 간격으로 20,000개씩 생성한다. 성능 평가 지표로는 MAE(Mean Absolute Error)와 안테나 선택 정확도(TAS Accuracy)를 사용한다.

먼저 송신시점의 SNR을 예측하는 방법으로 안테나를 선택하기 위한 SNR 추정 시의 MAE를 비교한다. MAE를 구하는 수식은 수식 (4)으로 표현할 수 있다.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (4)$$

n 은 데이터의 수이고, \hat{y}_i 은 모델의 예측값, y_i 은 실제 정답 값이다. 모델이 추정한 예측값과 실제값 사이 오차의 절댓값을 모두 더해 데이터의 수로 나누어, 절댓값 평균을 계산한다. 제안하는 기법인 GRU 기반 RNN과 기존기법인 평균값 방법, 최근값 방법, CNN 방법이 비교 대상이며, 협대역과 광대역 두 가지 환경에서 모의실험을 진행한다.

Fig. 5는 이동속도에 따른 SNR 추정 성능을 보인다. Fig. 5의 (a)는 협대역 채널 환경에서의 SNR 추정 MAE를 보이고, Fig. 5의 (b)는 광대역 채널 환경에서의 SNR 추정 MAE를 보인다. 모의실험 결과에 따르면, 협대역의 경우 최근값과 CNN, 제안하는 RNN 모두 속도가 빨라질수록 MAE가 증가하는 경향을 보인다. 속도가 빠를수록 생기는 도플러 효과와 협대역에서의 빠른 신호 변화로 인해 추정된 SNR 값이 정답 값

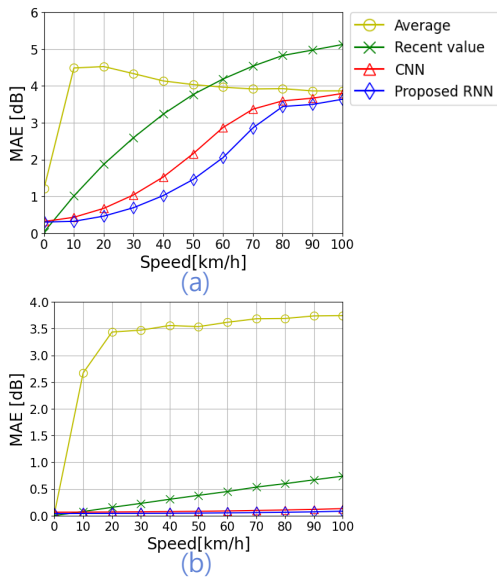


Fig. 5. MAE for speeds (a)Narrowband (b)Wideband

과 큰 차이를 보인다. 그러나 평균값 방법은 10km/h까지 추정 오차가 가파르게 증가하지만, 20km/h 이후에는 오히려 감소한다. 최근값 방법은 수신한 신호의 SNR 중 가장 최근 신호의 SNR을 송신 시점의 SNR과 동일하다고 예측한다. 그러나 속도가 증가함에 따라 시간에 따른 SNR 변화가 커져 최근 수신 SNR과 송신 시점의 SNR의 차이가 증가하는 것을 확인할 수 있다. 반면에 수신한 SNR의 평균으로 예측하는 평균값 방법의 경우 가장 최근 수신한 신호의 SNR에 대한 의존도가 줄어들어서, 55km/h 이상의 협대역 환경에서는 최근값 방법보다 SNR 예측 정확도가 더 우수하다. CNN과 제안하는 RNN, 두 인공지능 모델 또한 최근값과 마찬가지로 속도가 증가함에 따라 성능이 저하된다. 따라서 인공지능이 예측을 수행하는데 가장 최근 수신한 SNR에 높은 가중치를 두도록 학습한 것으로 추정한다. 0km/h의 경우 최근값 방법의 성능이 인공지능 모델보다 우수하지만, 10km/h 이상의 속도에서는 CNN과 RNN이 평균값과 최근값에 비해 우수한 성능을 보인다. 그중에서도 제안하는 RNN은 기존 방법인 CNN과 비교했을 때, 모든 속도 구간에서 더 우수한 성능을 보인다. 특히 40km/h에서 70km/h 구간에서는 다른 구간보다 큰 성능 차이를 보인다. 40km/h,

70km/h에서는 0.5dB 이상의 성능 차이를 보이며, 50km/h, 60km/h에서는 0.7dB에서 0.8dB 이상의 성능 차이를 보인다.

광대역의 경우는 평균값 방법의 성능이 다른 최근값, CNN, 제안하는 RNN 방법에 비해 모든 속도 구간에서 약 3dB 이상의 성능 저하를 보인다. 최근값 방법과 CNN, 제안하는 RNN 방법 모두 속도가 증가함에 따라 생기는 도플러 효과로 인해 SNR 추정 오차가 점차 커진다. 하지만 협대역에서는 0km/h에서 100km/h까지 속도 변화에 따라 4dB에서 5dB의 성능 변화가 생기지만, 광대역에서는 세 가지 방법 모두 1dB 이하의 성능 변화를 보인다. CNN, 제안하는 RNN 모두 최근값보다 모든 속도 구간에서 우수한 성능을 보이며, 0.05dB의 차이로 제안하는 RNN이 기존 CNN보다 우수한 성능을 보인다. 광대역에서는 채널 환경이 급격하게 변하지 않아 가장 최근에 수신한 신호의 SNR과 송신 시점의 SNR의 차이가 작고, 이에 협대역과 달리 SNR 추정 오차가 작기 때문이다. 광대역은 협대역에 비해 대역폭이 넓어 채널의 변화가 적게 나타난다. 따라서 제안하는 방법과 기존 방법의 성능 차이가 작게 나타나며, 채널의 변화가 큰 협대역에서는 광대역에 비해 성능 차이가 크게 나타난다.

기존 방법과 제안 방법이 추정한 SNR 값을 기반으로 송신안테나를 선택한다. 송신안테나 선택에 대한 성능 지표는 안테나 선택 정확도이다. 각 방법은 실제 정답 SNR을 기준으로 선택한 정답 안테나와 비교하여, 협대역과 광대역에서의 안테나 선택 정확도를 평가한다.

Fig. 6은 이동 속도에 따라 가장 높은 SNR로 예측되는 안테나를 선택했을 경우 정답 안테나를 올바르게 고를 확률에 대한 그래프이다. Fig. 6의 (a)는 협대역 채널 환경에서의 정답 안테나 선택 확률을 보이고, Fig. 6의 (b)는 광대역 채널 환경에서의 정답 안테나 선택 확률을 보인다.

협대역에 해당하는 Fig. 6 (a)의 경우, 평균값 방법을 제외한 모든 방법이 속도가 증가함에 따라 안테나 선택 정확도가 저하된다. 평균값 방법은 Fig. 5의 (a)에서 20km/h 이상의 속도에서 MAE가 감소하는 모습을 보이는 것과 마찬가지로 20km/h 이후부터 안테나 선




Fig. 6. TAS Accuracy (a)Narrowband (b)Wideband

택 정확도가 개선되는 것을 확인할 수 있다. 이동속도 20km/h와 100km/h의 성능을 비교했을 때 약 12%의 정확도 향상이 나타난다. 그러나 100km/h에서 58.46%의 정확도를 보임에도 다른 최근값, CNN, 제안하는 RNN 방법에 비해 정확도가 낮다. 0km/h에서 최근값은 99.635%로 가장 우수한 정확도를 보이지만, 10km/h 이상의 모든 구간에서 두 인공지능의 성능이 더 우수하다. 제안하는 RNN은 10km/h 이상의 모든 속도 구간에 대해 기존의 CNN보다 우수한 성능을 보인다. 특히 40km/h에서 70km/h 구간에서 큰 차이를 보인다. 40km/h에서 70km/h 구간의 제안하는 RNN은 기존의 CNN보다 평균 약 6.5% 더 우수한 안테나 선택 정확도를 보인다.

Fig. 6 (b)의 광대역의 경우를 보면, 100km/h 기준 안테나 선택 정확도가 65% 이하까지 저하되는 평균값 방법과는 달리 최근값, CNN, 제안하는 RNN 방법은 95% 이상의 안테나 선택 정확도가 보장된다. 0km/h의 경우 최근값이 정확도 100%로 가장 우수하지만 10km/h 이상의 속도에서는 CNN이나 제안하는 RNN 모델이 더 우수한 성능을 보인다. 100km/h 속도에서 기존의 CNN은 99.215%의 정확도를 보이고 제안하는 RNN은 평균 99.465%의 정확도를 보여, 제안하는 RNN이 0.25% 더 우수하다. 제안하는 방법과 기존 방

법의 안테나 선택 정확도 차이는 MAE와 마찬가지로 광대역보다 협대역에서 크게 나타난다.

다음 Table 2, 3은 협대역 및 광대역에서 속도에 따른 MAE와 정확도의 구체적인 수치를 보인다.

Table 2. MAE[dB] and Accuracy(%) based on speed in Narrow band

Speed (km/h)	Average		Recent		CNN		RNN	
	MAE	ACC	MAE	ACC	MAE	ACC	MAE	ACC
0	1.22	84.0	0.03	99.6	0.32	97.8	0.30	97.2
10	4.49	49.0	1.01	93.5	0.43	97.0	0.32	97.1
20	4.52	46.7	1.87	87.7	0.67	95.6	0.46	96.9
30	4.33	50.4	2.59	82.3	1.04	93.2	0.69	95.8
40	4.13	53.4	3.23	77.6	1.53	89.8	1.02	94.0
50	4.03	55.3	3.77	72.5	2.16	84.5	1.46	90.6
60	3.96	55.8	4.19	69.0	2.87	77.0	2.05	85.7
70	3.91	57.0	4.54	65.7	3.37	70.4	2.86	77
80	3.92	57.5	4.83	63.2	3.59	68.4	3.44	69.9
90	3.86	58.1	4.97	61.2	3.67	66.5	3.50	68.7
100	3.87	58.5	5.12	60.2	3.79	65.1	3.64	66.9

Table 3. MAE[dB] and Accuracy(%) based on speed in Wide band

Speed (km/h)	Average		Recent		CNN		RNN	
	MAE	ACC	MAE	ACC	MAE	ACC	MAE	ACC
0	0.02	99.7	0.004	100	0.06	99.6	0.04	99.6
10	2.67	79.3	0.08	99.5	0.07	99.6	0.04	99.6
20	3.44	70.9	0.16	98.9	0.07	99.6	0.04	99.6
30	3.47	70.0	0.23	98.6	0.07	99.7	0.04	99.6
40	3.56	68.7	0.31	98.2	0.08	99.6	0.04	99.6
50	3.54	68.9	0.38	97.7	0.08	99.5	0.05	99.6
60	3.62	67.4	0.45	97.2	0.09	99.4	0.05	99.6
70	3.68	66.7	0.53	96.8	0.10	99.3	0.06	99.6
80	3.69	65.7	0.60	96.4	0.11	99.3	0.06	99.5
90	3.74	65.1	0.67	95.8	0.12	99.2	0.07	99.5
100	3.74	64.6	0.74	95.3	0.13	99.2	0.08	99.5

V. 결론

본 논문에서는 다중 안테나 운용 시 다수의 안테나

로 수신하고 한 개의 안테나를 선택하여 송신할 때, 기존 방법보다 더 우수한 성능을 보장받을 수 있는 GRU 기반 RNN 시스템을 제안하였다. 제안하는 방법은 기존 논문에서 제안한 CNN 방법에 기반하여, 인공지능 모델의 입력으로 수신 신호의 SNR을 사용하여 제일 높게 예측한 SNR의 안테나를 선택하는 방법과 동일하게 송신 안테나를 선택한다. 기존 논문과 달리 입력되는 SNR 데이터가 시계열 데이터인 점을 이용하여 RNN의 일종인 GRU를 사용한다. 기존 CNN의 SNR 추정 MAE가 협대역에서는 모든 속도에 대하여 평균 2.13dB, 광대역에서는 평균 0.088dB였던 반면 RNN은 1.79dB, 0.053dB로 협대역과 광대역 두 가지 환경 모두에서 우수한 성능을 보인다. 제안하는 RNN 시스템이 기존 CNN 시스템보다 협대역에서는 평균 0.34dB, 광대역에서는 평균 0.035dB 적은 오차로 SNR 추정이 가능함을 의미한다. 이를 기반으로 안테나를 선택한 결과 협대역에서는 제안하는 RNN이 모든 속도에 대해 평균 3.149% 더 우수한 안테나 선택성능을 보였고, 광대역에서는 평균 0.130% 더 우수하였다.

본 연구를 통해 지향성을 가진 다중 안테나 기반 UAV 통신 시 송신에 모든 안테나를 사용하지 않아 소모되는 전력을 낮출 수 있고, 옴니 안테나 대비 같은 전력으로 더 먼 거리를 송신할 수 있으며 기존보다 높은 통신 신뢰성을 보장받을 수 있을 것으로 전망한다. 향후 연구 방향으로는, 적응형 MCS (Modulation Coding Scheme) 선택 기술을 통해 적합한 변조 방식 및 에러 정정 코드를 결정하는 연구를 수행할 계획이다. 이러한 새로운 기술은 본 연구의 결과와 통합되어 향상된 UAV 무선통신 시스템의 성능을 도모할 것으로 기대한다.

REFERENCES

- [1] H. Kang, J. Joung, J. Kim, J. Kang & Y. S. Cho. (2020). Protect your sky: A survey of counter unmanned aerial vehicle systems. *IEEE Access*, 8, 168671-168710. DOI : 10.1109/ACCESS.2020.3023473
- [2] T. H. Roh. (2020). Evaluating on the effectiveness of reservoir content surveying using UAV and echo sounder. *Journal of Next-generation Convergence Technology Association*, 4(2), 152-160. DOI : 10.33097/JNCTA.2020.04.02.152
- [3] A. Ranjha & G. Kaddoum. (2021). URLLC facilitated by mobile UAV relay and RIS: A joint design of passive beamforming, blocklength, and UAV positioning. *IEEE Internet Things J*, 8(6), 4618-4627. DOI : 10.1109/JIOT.2020.3027149
- [4] C. Qiu, Z. Wei, X. Yuan, Z. Feng & P. Zhang. (2020). Multiple UAV-mounted base station placement and user association with joint fronthaul and backhaul optimization. *IEEE Trans. Commun*, 68(9), 5864-5877. DOI : 10.1109/TCOMM.2020.3001136
- [5] J. Joung & J. Fan. (2021). Over-the-air computation strategy using space-time line code for data collection by multiple unmanned aerial vehicles. *IEEE Access*, 9, 105230-105241. DOI : 10.1109/ACCESS.2021.3099906
- [6] K. R. Lee & W. H. Lee. (2023). Generation and accuracy assessment of land surface temperature orthophoto the using unmanned aerial vehicle-mounted thermal infrared sensors. *The Journal of Next-generation Convergence Technology Association*, 7(10), 1626-1634. DOI : 10.33097/JNCTA.2023.07.10.1626
- [7] A. A. Khuwaja, Y. Chen, N. Zhao, M. Alouini & P. Dobbins. (2018). A survey of channel modeling for UAV communications. *IEEE Commun. Surv. Tutor.*, 20(4), 2804-2821. DOI : 10.1109/COMST.2018.2856587
- [8] P. S. Bithas, V. Nikolaidis, A. G. Kanatas & G. K. Karagiannidis. (2020). UAV-to-ground communications: Channel modeling and UAV selection. *IEEE Trans. Commun*, 68(8), 5135-

5144. DOI : 10.1109/TCOMM.2020.2992040
- [9] J. Wang, C. Jiang & L. Kuang. (2022). High-mobility satellite-UAV communications: Challenges, solutions, and future research trends. *IEEE Commun. Mag.*, 60(5), 38-43. DOI : 10.1109/MCOM.001.2100850
- [10] M. Umair, J. Joung & Y. Cho. (2020). Transmission power and altitude design for energy-efficient mission completion of small-size unmanned aerial vehicle. *Electron. Lett.*, 56(22), 1219-1222. DOI : 10.1049/el.2020.1943
- [11] J. Joung, H. Yu & J. Zhao. (2021). Bandwidth design for energy-efficient unmanned aerial vehicle using space-time line code. *IEEE Syst. J.*, 15(2), 3154-3157. DOI : 10.1109/JSYST.2020.3012281
- [12] H. T. Ye, X. Kang, J. Joung & Y. C. Liang. (2020). Optimization for full-duplex rotary-wing UAV-enabled wireless-powered IoT networks. *IEEE Trans. Wirel. Commun.*, 19(7), 5057 - 5072. DOI : 10.1109/TWC.2020.2989302
- [13] P. S. Bithas, A. G. Kanatas, D. B. Da Costa & P. K. Upadhyay. (2017). Transmit antenna selection in vehicle-to-vehicle time-varying fading channels. *IEEE Int. Conf. Commun., ICC, Paris, France*, 1-6. DOI : 10.1109/ICC.2017.7997379
- [14] J. Joung. (2016). Machine learning-based antenna selection in wireless communications. *IEEE Commun. Lett.*, 20(11), 2241-2244. DOI : 10.1109/LCOMM.2016.2594776
- [15] H. Liu, Y. Xiao, P. Yang, J. Fu, S. Li & W. Xiang. (2021). Transmit antenna selection for full-duplex spatial modulation based on machine learning. *IEEE Trans. Veh. Technol.*, 70(10), 10695-10708. DOI : 10.1109/TVT.2021.3111043
- [16] A. M. Elbir & K. V. Mishra. (2020). Joint antenna selection and hybrid beamformer design using unquantized and quantized deep learning networks. *IEEE Trans. Wirel. Commun.*, 19(3), 1677-1688. DOI : 10.1109/TWC.2019.2956146
- [17] J. Kim, J. Oh, E. R. Jeong & J. Joung. (2023). Convolutional neural network-based transmit antenna selection for UAV-ground station communications with time-varying channels. *ICT Express*. DOI : 10.1016/j.ict.2023.07.003
- [18] J. Wang, X. Li, J. Li, Q. Sun & H. Wang. (2022). NGCU: A new RNN model for time-series data prediction. *Big Data Research*, 27, 100296. DOI : 10.1016/j.bdr.2021.100296
- [19] Z. Zainuddin, P. A. EA & M. H. Hasan. (2021). Predicting machine failure using recurrent neural network-gated recurrent unit (RNN-GRU) through time series data. *Bulletin of Electrical Engineering and Informatics*, 10(2), 870-878. DOI : 10.11591/eei.v10i2.2036
- [20] D. Rumelhart, G. Hinton & R. Williams. (1986). Learning representations by back-propagating errors. *Nature*, 323, 533-536. DOI : 10.1038/323533a0

저 자 약 력

홍석진(Hong, Seok Jin)

[회원]




- 2023년 3월 : 한밭대학교 정보통신공학과 학사
- 2023년 3월~현재 : 한밭대학교 인공지능학과 석사 과정
- E-Mail : lf2net89@gmail.com

<관심분야>

모뎀 설계, 디지털신호처리, 딥러닝

오정은(Oh, Jeong Eun)

[회원]



- 2022년 2월 : 한밭대학교 정보통신공학과 학사
- 2022년 3월~현재 : 한밭대학교 모바일융합공학과 석사 과정
- E-Mail : wjddms1199@gmail.com

<관심분야>

모뎀 설계, 디지털신호처리, 딥러닝

윤웅중(Yun, Woong Jong)

[회원]




- 2023년 8월 : 한밭대학교 정보통신공학과 학사
- 2022년 8월~현재 : 한밭대학교 인공지능학과 석사 과정
- E-Mail : dndwhddl@naver.com

<관심분야>

모뎀 설계, 디지털신호처리, 딥러닝

정의림(Jeong, Eui Rim)

[회원]



- 1995년 2월 : 한국과학기술원 전기 및 전자공학과 학사
- 1997년 2월 : 한국과학기술원 전기 및 전자공학과 석사
- 2001년 2월 : 한국과학기술원 전기 전산학과 박사
- 2009년 1월 : 한밭대학교 정보통신공학과 교수
- 2022년 3월~현재 : 한밭대학교 인공지능소프트웨어학과 교수
- E-Mail : erjeong@hanbat.ac.kr

<관심분야>

모뎀 설계, 통신신호처리, 딥러닝