

# 전술 차량 통신에서의 MCS 선택을 위한 GRU 기반 SNR 추정

홍석진, 윤웅중, 정의림\*

국립한밭대학교

lf2net89@gmail.com, dndwhddl@naver.com, \*erjeong@hanbat.ac.kr

## GRU-Based SNR Estimation for MCS Selection in Tactical Vehicle Communication

Hong Seok Jin, Yun Woong Jong, Jeong Eui Rim\*

Hanbat National University

### 요약

본 논문에서는 전술 차량 간의 일대일 통신 시 변조 및 부호화 방식(Modulation Coding Scheme, MCS) 선택을 위해 게이트 순환 유닛(Gated Recurrent Unit, GRU)을 기반으로 한 신호 대 잡음비 (Signal-to-Noise Ratio, SNR) 추정 방법을 제안한다. 전술 차량 간의 통신은 직교 주파수 분할 다중화 (Orthogonal Frequency Division Multiplexing, OFDM)를 가정하며, 시분할 이중 전송 (Time Division Duplexing, TDD)을 통한 양방향 통신이 이루어진다. 안테나를 통한 수신 신호의 SNR을 활용하여 향후 전송 지점에서의 SNR을 예측하는 데 순환 신경망(Recurrent Neural Network, RNN)의 일종인 GRU를 사용한다. 수신된 신호로부터 SNR을 예측하는 기존 방법으로는 최근 값 방법, 평균 값 방법, 합성곱 신경망(Convolutional Neural Network, CNN)을 활용한 방법 등이 있다. 제안하는 GRU 기반 방법은 모든 기존 방법에 비해 평균 절대 오차 (Mean Absolute Error, MAE) 기준 가장 우수한 성능을 보여준다.

### I. 서론

이동 통신에서의 변조 및 부호화 방식(Modulation and Coding Scheme, MCS)은 데이터 전송 시 메시지를 심볼로 변환하는 변조 방식과 에러 확률을 줄이는 채널 코딩 방식을 의미한다. MCS는 주어진 통신 자원을 효율적으로 활용할 수 있게 하는 중요한 요소이다. 최적의 MCS 선택은 대역폭 활용 효율성을 극대화하고 높은 전송 속도를 가능하게 하는 것을 목표로 한다. 또한 통신 중 발생할 수 있는 오류를 줄이며 복구의 용이성을 촉진하며 통신의 안정성에 크게 기여한다. 전술 차량 간의 통신은 전쟁과 같은 긴급한 상황을 가정하기 때문에, 높은 전송속도와 통신 신뢰성 보장이 특히 중요하다. 이 같은 중요성으로 인해 폭넓게 사용되는 직교 주파수 분할 다중화(Orthogonal Frequency Division Multiplexing, OFDM) 시스템에서 최적의 MCS를 선택하기 위한 연구가 진행되고 있다. [1-2]. MCS를 잘 선택하기 위해서는 송신 지점의 신호 대 잡음비(Signal-to-Noise Ratio, SNR) 정보가 필요하다. 시분할 이중 전송 (Time Division Duplexing, TDD) 방법을 고려하면, 수신한 신호의 SNR로 송신 지점의 SNR을 예측할 수 있다. 기존에는 수신 신호 SNR의 평균을 계산하여 송신 지점 SNR을 예측하는 평균값 방법과 최근 수신 신호 SNR을 기반으로 SNR을 예측하는 최근 값 방법과 같은 전통적인 방법들이 일반적이었다. 최근 인공지능으로 이 문제를 해결하기 위한 시도가 있다. 한 연구에서는 송신 지점의 SNR을 추정하고 이를 기반으로 MCS를 예측하기 위해 합성곱 신경망(Convolutional Neural Network, CNN)을 사용하고 있다. [3] 그러나 합성곱 신경망은 이미지와 같은 데이터에서 특징을 추출하는 데 더 적합하며, 수신된 SNR 데이터가 시간 정보를 가지므로, 데이터의 특성을 보존하여 예측을 수행할 수 있는 순환 신경망(Recurrent Neural Network, RNN)이 더 적합하다.

본 논문에서는 게이트 순환 유닛(Gated Recurrent Unit, GRU)을 기반으로 전송 지점의 SNR 예측을 제안한다. 고려된 통신시스템은 OFDM과 TDD 방식을 사용하는 것이며, 단일 안테나가 전송 및 수신을 모두 처리

하는 상황을 가정한다. 본 논문에서는 이동하는 전술 차량의 각도나 속도에 기반하여 변화하는 환경을 모델링하고 제안하는 순환 신경망 모델의 성능을 컴퓨터 모의실험을 통해 평가한다. 시뮬레이션 결과, 제안하는 순환 신경망 방법이 모든 속도에 대해 평균 절대 오차 (Mean Absolute Error, MAE) 기준 가장 우수한 성능을 보여준다.

### II. 제안하는 시스템 및 인공지능 모델

이 연구에서 제안하는 송신 SNR 예측 시스템 모델은 다음과 같다.




그림 1 Proposed system model

그림 1은 신호의 수신부터 송신 지점의 MCS를 선택하는 과정의 블록도이다. 안테나로 수신된 신호는 첫 번째로 SNR 추정 단계를 거친다. 일정한 OFDM 심볼의 간격에 따라 SNR을 추정하고 해당 데이터는 벡터의 형태로 타임스텝에 따라 시간순으로 나열한다. 두 번째로 데이터 전처리 과정을 거친다. 실제 환경에서는 신호를 수신받지 못하게 되는 상황이 발생한다. 이런 경우를 대비해 신호를 수신받지 못한 타임스텝의 SNR값은 해당 값의 근처 성공적으로 수신한 SNR을 활용하여 보간한다. 보간 방법은 선형 엣지 제로 보간 방법을 사용하며 구체적인 방법은 다음과 같다. 수신한 SNR값 사이의 수신받지 못한 타임스텝은 선형적으로 보간함으로써 SNR값을 채운다. 처음과 끝에 수신받지 못한 SNR 데이터는 0으로 보간한다. 세 번째로 보간이 완료된 SNR 데이터는 GRU 기반 인공지능에 입력한다. 회귀 모델로 학습된 GRU 모델은 송신 지점의 SNR을 예측한다. 본 연구에서는 데이터가 시계열 데이터라는 점을 활용하여, RNN의 일종인 GRU를 사용해 송신 지점 SNR을 예측한다. GRU는 장기 의존

성 문제를 해결하기 위해 Gate 구조가 적용된 RNN이다. 제안하는 RNN은 4개의 GRU 층으로 구성되어 있으며 활성화 함수는 하이퍼볼릭 탄젠트(Tanh)를 사용한다.

### III. 시뮬레이션 환경

모의실험을 위해 MATLAB을 사용하여 데이터를 생성하고, TensorFlow 2.0을 활용하여 RNN을 학습한다.

표 1 Simulation parameters

Communication parameters	Values	
	SNR prediction	
Number of antenna, $M$	1	
Bandwidth	2 MHz	
Carrier frequency, $f_c$	512 MHz	
OFDM system FFT size	512	
Sampling period, $N_s$	6 OFDM symbol	
Window size, $N$	$N \in \{10, 30, 50, 70, 100\}$	
System SNR, $SNR$	$SNR \in \{0, 30\}$ dB	
Speed, $v$	$v \in [0, 100]$ km/h	
Measurement failure probability, $p$	$p \in [0.1, 1]$	
Rician factor, $\alpha$	10 dB	
LoS probability,	0.125	
Hyperparameters	Values	
	CNN	RNN
Optimizer	Adagrad	Adam
Learning rate	0.01	0.001
Batch size	512	1024
Number of epochs	500	100
Loss function	MSE	

표 1은 모의실험의 통신 신호 파라미터와 기존의 CNN과 제안하는 RNN의 하이퍼파라미터를 나타낸다. 수신과 송신에 사용되는 안테나의 수( $M$ )는 1개이다. 대역폭은 군용 OFDM 시스템에 따라 광대역 환경인 2MHz이며, 반송파 주파수는 512MHz로 가정한다. FFT 크기는 512이고, 수신 SNR을 샘플링하는 간격은 6 OFDM 심볼이다. Window size는 MCS를 선택하는데 사용할 수신 SNR의 총 타임스텝의 개수이다. 10, 30, 50, 70, 100 5가지의 길이로 실험을 진행하며, 각 방법에 제일 적합한 Window size를 선택해 실험을 진행한다. 매 훈련 샘플 생성 시마다 생성 신호의 평균 SNR은 0 ~ 30dB에서 무작위로 선택하며, 이동속도는 최소 0km/h 에서 최대 100km/h의 범위에서 무작위로 선택한다. 샘플마다 각 타임스텝에서의 수신 확률(수신 SNR 존재 확률)은 10 ~ 100%에서 무작위로 선택한다. 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 10dB이다. 해당 훈련 샘플이 가시선 환경과 비가시선 환경으로 선택될 확률은 12.5%이다. 기존의 CNN 모델의 경우 옵티마이저는 AdaGrad, 학습률은 0.01, 배치 크기는 512, 에포크는 500이고, 제안하는 RNN 모델은 옵티마이저 Adam, 학습률은 0.001, 배치 크기는 1024, 에포크는 100이다. 인공지능 손실함수는 Mean Square Error(MSE)를 사용한다. 훈련 데이터는 200,000개이며, 검증 데이터는 20,000개이다.

### IV. 모의실험 결과

기존의 방법인 평균값 방법, 최근값 방법, CNN 방법과 제안하는 RNN간의 성능을 비교하기 위해 0km/h부터 100km/h까지 10km/h 간격으로 각각 20,000개의 테스트 데이터를 생성한다. Window size의 경우 CNN과 RNN 모두 100이 가장 우수한 성능을 보이고, 평균값과 최근값의 경우 50이 가장 우수한 성능을 보인다. 각 방법에 대한 최적의 window size로 성

능을 비교한다.




그림 2 MAE for speed

그림 2는 수신한 SNR을 기반으로 추정된 송신 시점의 SNR의 MAE이다. 모든 방법이 속도가 빨라질수록 MAE가 나빠지는 경향을 보인다. 속도가 0km/h일 경우 평균값 방법이 가장 우수하다. 하지만 10km/h이후부터 평균값 방법은 급격하게 성능이 저하되며, 모든 방법 중 가장 성능이 열화된다. 최근값 방법은 기존의 CNN과 비교했을 때 20km/h 이하의 속도 구간에서는 MAE 성능이 우수하지만 30km/h이후 구간에서는 기존 CNN의 성능이 더 우수하다. 제안하는 RNN의 경우 0km/h를 제외한 10km/h 이상의 모든 속도 구간에서 가장 우수한 성능을 보인다. 모든 속도 구간에 대해 평균값은 평균 2.461dB의 MAE를 보이며, 최근값의 경우 1.582dB, 기존의 CNN의 경우 1.428dB, 제안하는 RNN은 1.279dB의 성능을 보인다. 제안하는 GRU 기반의 RNN이 가장 적은 오차로 SNR를 예측하는 것을 확인할 수 있다.

### V. 결론

본 논문에서는 1 대 1 전술 차량간 통신 시 MCS 선택 목적의 GRU 기반 송신 시점 SNR 예측 시스템을 제안하였다. 제안하는 방법은 수신 신호의 SNR을 사용하여 송신 시점의 SNR을 예측하는 RNN을 제안했다. 기존까지 가장 우수한 성능을 보이는 CNN과 비교했을 때, 제안하는 RNN이 예측 MAE 기준 평균 0.149dB 더 우수했다.

본 연구에서 제안한 방법을 통해 SNR을 예측한 뒤 MCS를 선택할 시 기존 방법보다 통신 두절률은 낮추고 통신 속도는 높일 수 있을 것으로 전망된다.

### 참고 문헌

- [1] Yingying Ji, Fatang Chen, Limin Liu : MCS Selection for Performance Improvement in Downlink TD-LTE System. In : 2012 Second International Conference on Business Computing and Global Informatization, Pages: 687-690, 10.1109/BCGIN.2012.184 (2012)
- [2] Jiancun Fan, Qinye Yin, Geoffrey Ye Li, Bingguang Peng, Xiaolong Zhu : MCS Selection for Throughput Improvement in Downlink LTE Systems. In : 2011 Proceedings of 20th International Conference on Computer Communications and Networks (ICCCN), 10.1109/ICCCN.2011.6005743, Lahaina (2011)
- [3] Jeong-Eun Oh, A-Min Jo, Jington Joung, Eui-Rim Jeong : CNN-Based Transmit Antenna and MCS Selection in a Mobile Communication System Using Multiple Antennas, In : The Journal of Korean Institute of Communications and Information Sciences, 23-09 Vol.48 No.09 (2023)