

NR V2X에서 GRU 기반 자동 물리계층 채널 분류

박민규, 위다영, 김유민, 김태형

국민대학교

alsrb20511@kookmin.ac.kr, windy9161@kookmin.ac.kr, kym0739@kookmin.ac.kr, th.kim@kookmin.ac.kr

GRU-based automatic physical layer channel classification in NR V2X

Mingyu Park, Dayoung Wi, Yumin Kim, Taehyoung Kim

Kookmin Univ.

요 약

5G NR(New Radio) sidelink 환경에서는 PSCCH(Physical Sidelink Control Channel)와 PSSCH(Physical Sidelink Shared Channel)가 동일한 시간 - 주파수 자원을 공유하므로, 수신단에서 두 채널을 정확히 구분하는 것이 중요하다. 본 논문에서는 두 채널의 DMRS 매핑 구조 및 물리 계층 파라미터 차이에 의해 형성되는 수신 신호 패턴에 착안하여, 이를 입력 특징으로 활용한 자동 채널 분류(Automatic Channel Classification, ACC)문제를 다룬다. 다양한 딥러닝 모델을 적용한 실험 결과, GRU 기반 모델이 전반적인 채널 환경 변화에 대해 가장 안정적인 성능을 유지함을 확인하였다.

I. 서론

딥러닝 기반 신호 분류 기법은 무선 통신 수신기의 성능 향상을 위한 핵심 기술로 주목받고 있다. 5G NR(New Radio) sidelink 환경에서는 PSCCH(Physical Sidelink Control Channel)와 PSSCH(Physical Sidelink Shared Channel)가 동일한 시간 - 주파수 자원을 공유하여 전송되므로, 수신단에서 두 채널을 정확히 판별하는 것이 중요하다. 두 채널은 DMRS 매핑 구조, OCC 길이 등 물리계층 구조가 서로 상이하다[1]. 이러한 구조적 차이는 수신 신호의 시간 - 주파수 패턴 차이로 나타나며, 채널 타입 판별을 위한 유의미한 단서로 작용할 수 있다. 그러나 기존 블라인드 디코딩 기반 판별 방식은 연산 복잡도와 전력 소모 측면에서 한계가 있다. 이를 보완하기 위해 CNN(Convolutional Neural Network) 기반 딥러닝 모델을 활용하여 채널을 분류하는 기법이 제안되고 있다[2].

본 논문에서는 GRU(Gated Recurrent Unit)[3] 기반 자동 채널 분류 기법을 제안한다. 수신 신호에 포함된 구조적 특징을 바탕으로 PSCCH와 PSSCH를 자동으로 분류하며, 다양한 채널 환경에서의 분류 성능을 검증한다.

II. 시스템 모델

PSCCH와 PSSCH는 서로 다른 DMRS(Demodulation Reference Signal) 매핑 구조를 가진다. PSCCH의 DMRS는 자원 블록(Resource Block)당 제한된 자원 요소(Resource Element)에 희소하게 매핑되는 고정된 패턴을 따르는 반면, PSSCH의 DMRS는 OFDM 심볼 전반에 걸쳐 상대적으로 조밀하게 배치되며 SCI(Sidelink Control Information)에 따라 동적으로 결정된다. 또한 두 채널에는 서로 다른 길이의 OCC가 적용된다. PSCCH에는 길이 3의 OCC가 적용되어 제어 채널 간의 간섭을 완화하도록 설계된 반면, PSSCH에는 길이 2의 OCC(Orthogonal Cover Code)가 적용된다. 이러한 OCC 길이의 차이는 동일한 자원 격자 상에서도 신호의 상관 구조 및 특성에 차이를 발생시키는 요인으로 작용한다.

DMRS 매핑 및 OCC 구조의 차이는 수신 신호의 시간 - 주파수 특성에 차이를 형성하며, PSCCH와 PSSCH를 구분하기 위한 중요한 구조적 단서로 작용한다.

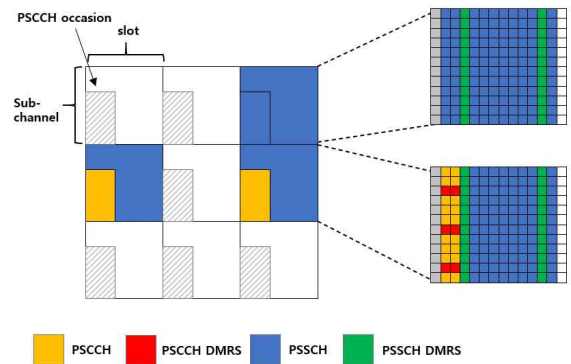


그림 1 NR V2X PSCCH 및 PSSCH 물리계층 구조

III. GRU 기반 자동 채널 분류

본 연구에서는 NR sidelink 환경에서 PSCCH와 PSSCH를 자동으로 구분하기 위한 딥러닝 기반 채널 분류기로서 GRU 기반 분류기를 중심으로 고려한다. PSCCH와 PSSCH는 DMRS 자원 매핑 방식, OCC 구조 등 물리 계층 프레임 구조가 서로 상이하며, 이러한 구조적 차이는 수신 신호의 시간 - 주파수 영역에서 서로 다른 특성으로 나타난다. 본 논문에서는 이러한 차이가 반영된 수신 신호의 주파수 축 패턴을 순차적으로 배열한 시퀀스를 분류기의 입력으로 사용한다.

GRU는 순환 신경망(RNN) 계열 모델로서, 은닉 상태 갱신 과정에서 업데이트 게이트와 리셋 게이트를 통해 시퀀스 내에서 유의미한 정보는 유지하고 잡음에 의한 불필요한 변동은 효과적으로 억제할 수 있다. 이러한 특성은 저 신호 대 잡음비 환경이나 다중경로로 인한 채널 왜곡이 큰 환경에서 수신 신호 시퀀스의 구조적 패턴을 안정적으로 학습하는 데 적합하다. 특히 PSCCH와 PSSCH의 DMRS 구조 차이에 의해 형성되는 주파수 상관 특성은 인접 서브캐리어 간의 의존성을 가지므로, 이를 시퀀스로 모델링하는 GRU 구조가 효과적인 분류 성능을 제공할 수 있다.

표 1 시뮬레이션 파라미터 설정

Parameter	Value
Channel model	Tapped-Delay Line-A
Bandwidth	20 [MHz]
Subcarrier spacing	30 [kHz]
Number of RBs	2
Number of PSSCH OFDM symbols	12
Modulation	QPSK
Noise	AWGN
Delay Spread	10~300 [ns]
Velocity	30~150 [km/h]
SNR	0~20 [dB]
Number of training data	10,000
Optimizer	Adam

표 2. 모델별 학습 파라미터 수 비교

Model	Total Parameter
CNN	57,386
GRU	58,861
LSTM	75,757
ResNet	289,174
Transformer Encoder	67,404

또한 GRU는 LSTM에 비해 상대적으로 적은 파라미터 수로 구성될 수 있어 학습 복잡도가 낮고, 다양한 채널 환경 변화에 대해 안정적인 성능을 유지하는 장점이 있다. 본 연구에서는 이러한 GRU의 구조적 특성을 활용하여 수신 신호 시퀀스에 내재된 구조적 차이를 학습하고, 이를 기반으로 PSSCH와 PSSCH를 분류하는 자동 채널 분류기를 구성하였다.

IV. 실험 결과

표 1은 본 논문에서 사용한 주요 시뮬레이션 파라미터를 정리한 것으로, 지연 확산은 10 ~ 300 ns, SNR은 0 ~ 20 dB 범위로 설정하였다. 모든 딥러닝 모델은 동일한 데이터셋과 전처리 조건하에서 학습 및 평가되었다. 비교 실험을 위해 제안하는 GRU 기반 자동 채널 분류기를 중심으로 CNN, LSTM, ResNet 모델을 적용하였다. CNN은 주파수 축에서의 국소적인 수신 신호 패턴을 학습하며, LSTM과 GRU는 시퀀스 기반 구조를 통해 주파수 전반에 걸친 의존성을 모델링한다. ResNet은 잔차 연결을 통해 안정적인 특징 학습이 가능하도록 설계되었다.

그림 2는 SNR 변화에 따른 테스트 정확도를 나타낸다. 모든 모델이 SNR 증가에 따라 정확도가 향상되는 경향을 보였으나, 특히 저 SNR 구간에서 제안하는 GRU 기반 모델이 가장 높은 정확도와 가장 안정적인 성능을 나타냈다. 이는 순환 구조를 통해 잡음에 의해 변동하는 수신 신호 시퀀스에서 유의미한 패턴을 효과적으로 누적·보존할 수 있기 때문으로 해석된다.

그림 3은 지연 확산 변화에 따른 테스트 정확도를 나타낸다. 지연 확산이 증가함에 따라 일부 모델에서는 성능 저하가 관찰되었으나, 제안하는 GRU 기반 모델은 전 지연 확산 구간에서 비교적 일정한 정확도를 유지하며 우수한 전반 성능을 보였다. 또한 표 2에 제시된 바와 같이, GRU 기반 모델은 비교 모델 대비 상대적으로 적은 파라미터 수를 가지면서도 다양한 채널 환경에서 우수한 분류 성능을 달성하여, 모델 복잡도 대비 성능 효율이 높은 구조임을 확인할 수 있다.

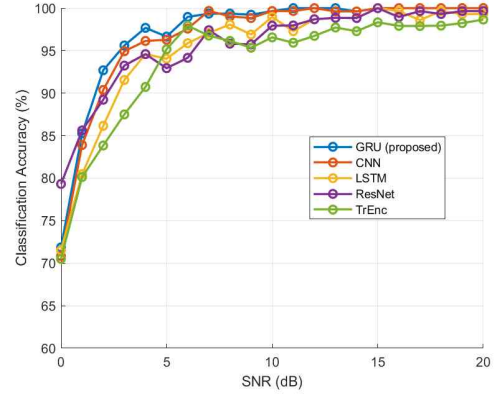


그림 2 SNR 변화에 따른 모델별 정확도

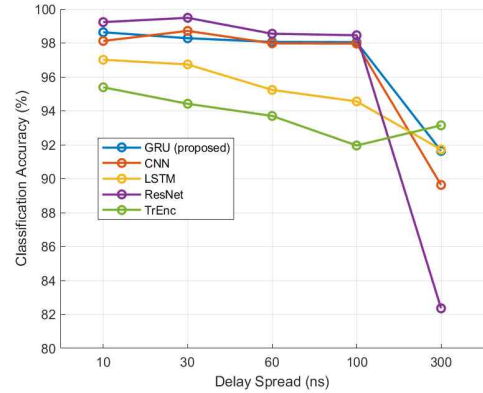


그림 3 DS 변화에 따른 모델별 정확도

V. 결론

본 논문에서는 NR sidelink 환경에서 PSSCH와 PSSCH를 구분하기 위한 딥러닝 기반 자동 채널 분류 기법을 제안하고, 수신 신호 시퀀스를 입력 특징으로 활용하여 다양한 모델의 성능을 비교하였다. 실험 결과, GRU 기반 모델은 비교적 적은 파라미터 수로 구성됨에도 불구하고 다양한 SNR 및 지연 확산 조건에서 전반적으로 안정적인 분류 성능을 보였다.

ACKNOWLEDGMENT

이 논문은 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임 (No.RS-2024-00397789)

참고 문헌

- [1] 3GPP TS 38.211, "NR; Physical channels and modulation (Release 17)," V17.3.0, September 2023.
- [2] T. Kim, Y. Kim, M. Jung, and H. Son, "Intelligent partial-sensing-based autonomous resource allocation for NR V2X," IEEE Internet of Things Journal, vol. 11, no. 2, Jan. 2024.
- [3] J. Chung, Ç. Gülçehre, K. Cho, and Y. Bengio, "Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling," arXiv preprint arXiv:1412.3555, 2014.