

Mid-amble를 이용한 딥러닝 기반 양방향 평균화 V2X 채널추정 기법에 관한 연구

김창현, 송창익*
한국교통대학교

c.kim@ut.ac.kr c.song@ut.ac.kr

A Study on V2X Channel Estimation Scheme based on Deep Learning and Bi-directional Averaging Using Mid-ambles

Kim, Chang Hyun, Song, Changick*
Korea National University of Transportation.

요약

최근 딥러닝과 양방향 평균화 기법을 결합하여 채널 추정의 정확도를 향상시키기 위한 기법이 제안된 바 있으나, 인공신경망을 통해 획득한 채널추정 정확도 이득이 인접 OFDM 심볼에 전이되지 못하는 한계가 있었다. 본 연구에서는 이러한 한계점을 극복할 수 있는 새로운 딥러닝 기반 양방향 평균화 기법을 제안한다. 이후 시뮬레이션 결과를 통해 제안하는 기법이 기존 기술 대비 성능이득이 있음을 확인한다.

I. 서론

5G 통신기술이 발전함에 따라 자율주행자동차 산업이 성장하게 되었고 차량과 차량 간 통신 뿐 아니라 차량과 사물과의 통신인 Vehicle-to-everything(V2X) 통신 기술에 관한 연구가 활발하게 이루어지고 있다. V2X 통신 기술의 목표는 차량의 고속 이동환경에서도 고신뢰 저지연의 통신을 달성하는 것이다. V2X 표준 중 Direct Short Range Communication(DSRC) 기반의 Wireless Access in Vehicular Environment(WAVE) 기술이 있다. WAVE 기술은 OFDM (Orthogonal Frequency Division Multiplexing)을 기반으로 하며 대표적인 물리계층 규격으로는 IEEE 802.11p와 이의 진화된 버전으로 최근 활발하게 연구되고 있는 IEEE 802.11bd가 있다[1].

IEEE 802.11p/bd 규격은 근본적으로 실내에서 사용되는 무선랜 규격을 기반으로 개발되었기 때문에 시변동성이 높은 환경인 V2X 통신에 적용하기에 많은 어려움을 가지고 있었다. 이러한 문제점을 해결하고 통신의 정확성을 높이기 위해 이전 시간에서 추정된 채널을 활용하여 현재 시간 데이터 심볼을 연속적으로 하나의 파일럿 신호처럼 활용하는 DPA(Data pilot Aided) 알고리즘을 바탕으로 Spectral Temporal Averaging (STA)[2], Time domain Reliability Test and Frequency domain Interpolation(TRFI)[3] 방식과 같은 다양한 채널추정 알고리즘이 개발되었고 복잡도 대비 우수한 성능 이득을 가져왔다. 또한 11bd에서는 data field내에 하나의 파일럿 신호처럼 활용가능한 mid-amble[4]를 사용하여 왜곡된 채널정보를 보정했다. mid-amble를 통해 채널추정의 정확성은 비약적으로 상승시켰으나 주파수 효율을 떨어뜨리는 단점을 보유하고 있다. mid-amble의 효율적인 활용을 위해 기존 DPA 채널추정 방식인 TRFI에 양방향 평균화를 결합한 방식이 연구되었다[5].

최근에는 딥러닝을 이용한 V2X 채널추정에 관한 연구가 활발하게 진행되고 있다. 특히 Auto Encoder(AE)[6] 와 TRFI-DNN[7]과 같이 DPA 및 TRFI과정에서 발생하는 왜곡을 인공신경망을 이용하여 보상함으로써 채널추정의 정확도를 비약적으로 향상시킬 수 있다는 연구결과들이 보고된 바 있다. 또한 딥러닝과 [5]의 양방향 평균화 기법을 결합하여 추가적인 성능 이득을 얻고자 하는 TRFI-BiAvg-DNN[8] 기법이 제안되었으나 DN N에서 발생하는 성능이득이 인접 OFDM 심볼에 전이되지 못하는 한계가 있었다. 본 연구에서는 이러한 한계점을 극복할 수 있는 새로운 양방향 평균

화 TRFI-DNN기법을 제안한다. 제안하는 기법은 기존과 달리 학습된 TRFI-DNN 인공신경망을 이용하여 채널을 보상한 후 인접 심볼로 전달하는 과정을 포함한다. 마지막으로 시뮬레이션 결과를 통해 제안하는 기법이 기존 TRFI-DNN[7], TRFI-BiAvg-DNN[8] 기술 대비 성능이득이 있음을 확인한다.

II. 본론

2.1 패킷구조

본 논문에서의 패킷구조는 [5]의 패킷구조와 동일하며 미드앰블의 삽입 위치와 갯수 또한 양방향 평균화 이득을 극대화하는 위치에 배치되었다.

IEEE 802.11p/bd에서 정의된 OFDM(Orthogonal Frequency Division Multiplexing) 기술을 사용하였고 아래와 같은 수식을 따른다.

$$Y_{(i)}(k) = H_{(i)}(k) \cdot X_{(i)}(k) + W_{(i)}(k) \quad (1)$$

위 수식(1)에서 i 는 총 OFDM 심볼의 개수, k 는 부반송파의 개수를 의미한다. $Y_{(i)}(k)$ 는 i 번째 심볼에서의 송신신호, $X_{(i)}(k)$ 는 i 번째 심볼에서의 수신신호를 의미하고, $W_{(i)}(k)$ 는 가우시안 분포를 따르는 잡음을 의미한다. 이때 $H_{(i)}(k)$ 는 페이딩에 의해 발생하는 채널의 주파수 응답을 의미한다.

2.1.1 인공신경망 학습 데이터 구축

먼저 그림2와 같이 양방향으로 TRFI채널추정을 수행한 후 평균을 취한다. 이후 추정된 채널을 학습용 데이터로 수집한다.




그림2. 학습용 데이터 생성

인공신경망 모델은 AE 구조를 사용하며 인공신경망의 입력값은 상기 수집된 데이터를 사용하고 출력값을 해당 OFDM심볼의 ideal 채널 값으로 설정하여 두 채널을 MSE(Mean Square Error)를 최소화하도록 모델

파라미터를 학습시키게 된다. 위 과정을 수식으로 표현하면 아래와 같다.

$$MSE = \frac{1}{N_{Train}} \cdot \sum_{i=1}^{N_{Train}} \| h_{ideal} - h_{Train} \|^2$$

위 수식에서 N_{Train} 은 총 훈련횟수를 의미하고, h_{ideal} 은 AE의 출력값을 의미하고, h_{Train} 은 양방향 평균화를 거친 AE의 입력값을 의미한다. 인공 신경망을 학습하는데 활용한 파라미터는 아래의 표1에 표시하였다.

Parameter	Value
Number of hidden Layer	3
Neurons per hidden Layer	15-10-15
Activation function	ReLU
Epoch	500
Batch size	128
Optimizer	Adam
loss function	MSE
Learning Rate	0.001
Mid-amble 심볼	4개 : 26,52,78,104번

표1. 인공신경망 하이퍼 파라미터

2.2 테스트 과정

본 논문에서는 미드앰블이 있는 802.11bd 패킷구조를 가정하며 [5]와 같이 제일 마지막 OFDM심볼에 mid-amble이 항상 존재함을 가정한다. 또한 [7]에서처럼 각각의 심볼에서 추정된 채널 값에 인공신경망 학습을 끝낸 파라미터를 활용하여 오류보정을 수행한 후 다음 심볼의 채널추정에 영향을 주도록 설계하였다. 자세한 채널 추정 과정은 아래와 같다.

- (1) i번째 OFDM 심볼에서 TRFI 채널추정을 수행한 채널 $\hat{H}_{TRFI,i}$ 로 표시
- (2) $\hat{H}_{TRFI,i}$ 를 2.1에서 학습된 인공신경망의 input으로 피드하여 오류보정 수행
- (3) 보정된 채널을 i+1번째 OFDM 심볼에 전달하여 연속적으로 TRFI 채널 추정 수행.
- (4) 동일한 과정을 역방향으로 수행한 후, 정방향과 역방향에서 각각 추정된 채널의 평균값 도출

2-3 시뮬레이션 결과

본 논문에서는 모의실험을 위해 Cohda Wireless V2X 채널모델 중 가장 열악한 환경인 Highway NLOS(Non Line of sight)를 활용하였고 표2는 환경에 대한 파라미터이다.

	Tap1	Tap2	Tap3	Tap4
Power	0dB	-2dB	-5dB	-7dB
Delay	0ns	200ns	433ns	700ns
Doppler	0Hz	689Hz	-492Hz	886Hz

표2. Highway NLOS 채널모델

TRFI-DNN과 TRFI-BiAvg-DNN 모두 4개의 미드앰블을 사용하였고 TRFI-DNN은 양방향 평균화를 수행하지 않기 때문에, [5]와 달리 마지막 데이터 심볼에 미드앰블이 존재하지 않는다. TRFI-BiAvg-DNN과 본 논문에서 제안하는 미드앰블의 분포위치는 [5]의 규칙을 따른다. 그림2에서 보는바와 같이, 모든 SNR에서 제안하는 기법이 기존 기법대비 우수한 PER성능을 갖는 것을 확인할 수 있다.

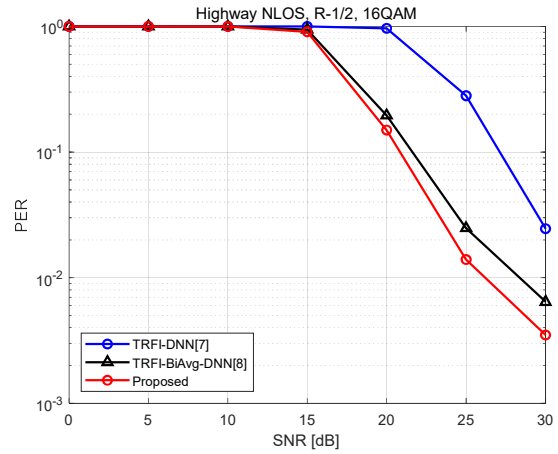


그림 2. Highway NLOS 16QAM 환경에서의 PER 성능

III. 결론

본 논문에서는 기존 TRFI-DNN 기술과 미드앰블이 포함된 새로운 양방향 평균화를 결합한 방식을 제안하였다. 시뮬레이션 결과를 통해 기존 기술대비 성능이득이 있음을 입증하였다.

ACKNOWLEDGMENT

이 연구는 2023년도 정부(과학기술정보통신부)의 재원으로 한국연구재단 이공분야기초연구사업(No.2021R1A2C2012558) 및 정보통신기획지원 자율주행기술개발혁신사업(No.2022-0-01053, 다중통신기술 네트워크 로드맵링 기술개발)의 지원을 받아 수행된 연구임.

참고 문헌

- [1] Naik, Gaurang, Biplav Choudhury, and Jung-Min Park. "IEEE 802.11 bd & 5G NR V2X: Evolution of radio access technologies for V2X communications." IEEE access 7 (2019): 70169-70184.
- [2] Fernandez, Joseph A., et al. "Performance of the 802.11 p physical layer in vehicle-to-vehicle environments." IEEE transactions on vehicular technology 61.1 (2011): 3-14.
- [3] Kim, Yoon-Kyeong, et al. "Time and frequency domain channel estimation scheme for IEEE 802.11 p." 17th International IEEE Conference on Intelligent Transportation Systems (ITSC). IEEE, 2014.
- [4] Kim, Sang In, Hyun Seo Oh, and Hyun Kyun Choi. "Mid-amble aided OFDM performance analysis in high mobility vehicular channel." 2008 IEEE Intelligent Vehicles Symposium. IEEE, 2008.
- [5] 김주혁, 송창익. (2022). 양방향 평균화를 이용한 새로운 Mid-amble 기반 V2X 채널추정 기법에 관한 연구. 전기전자학회논문지, 26(2), 287-291.
- [6] Han, Seungho, Yeonji Oh, and Changick Song. "A deep learning based channel estimation scheme for IEEE 802.11 p systems." ICC 2019-2019 IEEE International Conference on Communications (ICC). IEEE, 2019.
- [7] Gizzini, Abdul Karim, et al. "Joint TRFI and deep learning for vehicular channel estimation." 2020 IEEE Globecom Workshops (GC Wkshps. IEEE, 2020.
- [8] 김창현, 송창익. (2023). Mid-amble 기반 양방향 평균화 기법과 인공신경망을 결합한 V2X 채널추정 기법에 관한 연구. 한국통신학회 추계종합학술발표회, 2023, pp. 614-615.