

IEEE 802.11p에서 딥러닝 기반 V2X 채널 추정 연구 동향

박지훈, 이상철, 채승호*

한국공학대학교

{wlgn4457, shng9522, shchae}@tukorea.ac.kr

Research Trends on Deep Learning-Based V2X Channel Estimation for IEEE 802.11p

Jihoon Park, Sangcheol Lee, Seong Ho Chae*

Tech University of Korea

요약

고 이동성을 가지는 환경에서 무선통신 채널은 도플러 천이(Doppler shift)와 다중경로 페이딩(Fading)의 영향으로 이중 분산되는 특징을 가진다. 전통적 채널 추정 방식에서는 높은 전송률을 위해 제한된 수의 파일럿(Pilot) 신호를 사용하게 되는데, 이를 고 이동성 시나리오에 적용하게 되면 채널 추정에 상당한 성능 저하가 나타난다. 본 논문에서는 이러한 문제를 해결하기 위한 IEEE 802.11p에서 딥러닝(Deep learning) 기반 채널 추정 기법들에 관한 최신 연구 동향 및 한계점을 살펴본다.

I. 서론

채널 추정은 통신 시스템의 성능을 결정하는 중요한 요소로서, 지난 수년 동안 IoT(Internet-of-Things), 저궤도 위성 등 다양한 지상 및 비지상 통신 네트워크에서의 채널 추정 연구가 활발히 이루어지고 있다[1],[2]. 특히, 높은 이동성을 가지는 환경에서 무선통신 채널은 시간 및 주파수 도메인에서 동적으로 변화하며, 이러한 채널을 추정하는 것은 지연시간 등 다양한 요인으로 인해 매우 어렵다. 최근, 이동 차량용 무선통신을 지원하기 위한 표준인 IEEE 802.11p에서 다양한 딥러닝(Deep learning) 기법을 적용한 채널 추정 연구들이 활발하게 진행되고 있다[3]-[8]. 본 논문에서는 IEEE 802.11p에서의 채널 추정에 관한 연구들을 대표적 딥러닝 모델 별로 구분하여 소개하고, 최신 연구 동향 및 그 한계점을 살펴본다.

II. 딥러닝 기반 채널 추정 연구 동향

A. IEEE 802.11p 표준 및 채널 추정의 한계점




그림 1. IEEE 802.11p 패킷 구조

IEEE 802.11p은 차량 통신을 지원하기 위해 개발된 무선 통신 표준으로, 물리계층은 OFDM(Orthogonal Frequency Division Multiplexing)을 기반으로 하고 있다. 그림 1에서 확인할 수 있듯이 하나의 데이터 패킷은 프리앰블 영역(Preamble Field), 신호 영역(SIGNAL field), 데이터 영역(DATA field)으로 구성되어 있다. 프리앰블 영역은 신호의 동기화와 초기 채널 추정을 위해 사용되고, 신호 영역은 변조 방식, 데이터 길이 등 패킷에 대한 정보를 전달하는 데 사용되며 데이터 영역은 실제 정보를 전달하기 위해 사용된다. 하나의 OFDM 심볼은 64개의 서브캐리어(Sub-Carrier)로 구성되어 있다. OFDM 심볼의 각 서브캐리어에 -32에서 31까지의 인덱스를 부여했을 때 64개의 서브캐리어 중 {-21, -7, 7, 21}에 해당하는 4개의 서브캐리어에는 채널의 추적을 위한 파일럿(Pilot) 신호가 할당된다. 또한 {-32, ..., -27, 0, 27, ..., 31}에 해당하는 12개의 서브캐리어는 가드밴드(Guard Band)의 역할을 하는 빈 서브캐리어로 사용된다. 그리고 나머지 48개의 서브캐리어는 실제 데이터 전송에 사용된다.

구분	논문 번호	채널 추정기 구조	채널모델	채널 추정 방식	metric	패킷 구조 변경
DNN	[3]	STA-DNN	VTV-UC, VTV-SDWW	SBS	BER 성능 NMMSE	X
CNN	[4]	ADD-TT-SR-ConvLSTM	VTV-UC	FBF	BER 성능 NMMSE	X
	[5]	WI-FP-ALS-DN-CNN	VTV-UC, VTV-SDWW	FBF	BER 성능 NMMSE	O
RNN	[6]	LSTM-MLP-DPA	WINNER-II	SBS	BER 성능 NMMSE	X
	[7]	DPA-LSTM-NN	V2V-UC	SBS	BER 성능 NMMSE	X
	[8]	DPA-GRU	V2V-UCO	SBS	BER 성능 NMMSE	X

표 1. 딥러닝 기반 채널 추정 기법들의 주요 특성

채널의 상태가 하나의 OFDM 심볼 시간 동안 변하지 않는다고 가정하면, l 번째 심볼의 k 번째 서브캐리어에 수신된 신호는 다음과 같이 표현할 수 있다.

$$Y[l, k] = H[l, k]X[l, k] + N[l, k], \quad (1)$$

여기서 $H[l, k]$, $X[l, k]$ 그리고 $N[l, k]$ 은 각각 채널 주파수 응답(CRF), 전송된 신호, 가우시안 노이즈를 의미한다.

IEEE 802.11p 표준에서는 각 OFDM 심볼마다 4개의 파일럿 신호를 할당한다. 하지만, 제한된 파일럿 수로 인해 채널 변화를 추적하기에는 부족하다. 이러한 문제를 해결하기 위해, 기존의 IEEE 802.11p 표준의 데이터 프레임 구조를 유지하면서 채널 추정 성능을 개선하는 방식과 추가적인 파일럿 신호 할당을 통해 채널 추정 성능을 개선하는 방식이 제안되었다. 또한, 채널 추정을 심볼 단위로 수행하는 SBS(Symbol by Symbol) 채널 추정 방식과 프레임 단위로 수행하는 FBF(Frame by Frame) 방식이 제안되었다. 표 1에서 본 논문에서 소개하는 딥러닝 기반 채널 추정 기법들의 주요 특성들을 요약해 두었으며, 다음 절에서 상세히 소개한다.

B. DNN 기반 채널 추정 연구[3]

[3]에서 제안된 채널 추정 기법은 전통적인 SBS 채널 추정 방식인 STA(Spectral Temporal Averaging) 채널 추정을 통해 얻은 채널 추정값을 DNN(Deep Neural Network)의 입력값으로 하여 최종적으로 추정된

채널 값을 얻게 되는 STA-DNN 구조를 가진다. 이러한 방식을 통해 제안된 방식은 기존 STA 방식에 비해 향상된 BER(Bit Error Rate) 성능을 보여준다. 하지만 DNN은 학습 과정에서 연속적으로 수신된 신호의 채널들 사이의 상관관계를 고려하지 않는 한계를 가지며, 이를 개선하기 위해 시간에 따라 변하는 채널 특성을 포착하고 학습할 수 있는 CNN(Convolutional Neural Network) 및 RNN(Recurrent Neural Network)을 기반으로 한 채널 추정 기법들이 제안되었다.

C. CNN 기반 채널 추정 연구[4],[5]

CNN 기반의 FBF 채널 추정 방식은 전체 수신된 프레임의 파일럿 신호를 기반으로 구한 초기 추정 채널 행렬의 특징을 CNN을 활용하여 학습한다. 이를 통해 연속적인 심볼들 사이 변화하는 채널의 상관관계를 학습에 반영할 수 있다. [4]에서는 초기 채널 추정값을 기반으로 ADD-TT(Average Decision-Directed with Time Truncation) 보간법을 사용하여 채널을 저해상도 이미지 형태로 모델링 한다. 이후 SR-ConvLSTM(Super Resolution Convolutional Long Short Term Memory) 네트워크를 통해 프레임 내 채널의 시간 및 주파수 영역에서의 상관관계를 학습하여 채널 추정 성능을 향상시킨다. 하지만 이러한 방식은 SR-ConvLSTM 네트워크가 높은 계산 복잡도를 가지고 있다는 점과 전체 프레임을 수신한 후에 채널 추정이 이루어진다는 점 때문에 긴 지연시간을 가진다는 단점이 있다.

문헌 [4]의 높은 계산 복잡도를 극복하기 위해, 문헌 [5]에서는 WI-CNN(Weighted Interpolation-CNN) 기반의 채널 추정 기법을 제안하였다. 제안된 기법은 [4]의 SR-ConvLSTM 네트워크보다 계산복잡도를 감소시키고, 이동 환경에 따른 각 프레임 내 파일럿 할당 방식 변경을 통해 특히 매우 높은 이동성 환경에서 우수한 채널 추정 성능을 가짐을 보였다. 하지만, 채널 추정을 위해 전체 프레임을 수신한 후 채널 추정이 수행되므로 긴 지연시간에 대한 한계점은 여전히 가지고 있다.

D. RNN 기반 채널 추정 연구[6]-[8]

채널의 시간에 따라 변화하는 특성을 학습하기 위한 또 다른 방식으로 RNN을 기반으로 한 SBS 채널 추정 기법들이 제안되었다[6]-[8]. 문헌 [6]에서는 채널 변화를 추적하기 위해 RNN 모델의 일종인 LSTM(Long Short Term Memory)과 추가적인 노이즈 제거를 위한 MLP(Multi-Layer Perceptron) 네트워크를 사용하고 마지막으로 DPA(Data-Pilot-Aided) 채널 추정 기법을 통해 최종적인 채널 추정 값을 얻게 되는 LSTM-MLP-DPA 구조의 채널 추정 방식을 제안하였다. 이러한 방식은 문헌 [3]의 기법 대비 우수한 채널 추정 성능을 보여주지만 2개의 딥러닝 네트워크를 사용하기 때문에 계산 복잡도가 증가한다는 단점이 있다.

문헌 [7]에서는 2개의 딥러닝 네트워크를 사용하여 생기는 계산 복잡도 문제를 개선하기 위한 채널 추정 방식을 제안하였다. 이 방식은 먼저 DPA 방식을 통해 얻은 채널 추정 값을 샘플링을 통해 차원을 축소한 후, LSTM-NN의 입력으로 받아 최종적인 채널 추정값을 얻는 DPA-LSTM-NN 구조의 채널 추정 방식을 제안하였다. 이러한 방식은 문헌 [6] 대비 계산 복잡도를 49.9% 감소시키고 HPA(High Power Amplifier Distortion)를 고려한 상황에서 우수한 채널 추정 성능을 가짐을 보였다. 하지만 낮은 SNR 환경에서는 [6]의 방식과 비교시 상대적으로 성능이 낮아지는 단점을 보여준다.

문헌 [8]에서는 LSTM 모델의 간소화된 버전인 GRU(Gated Recurrent Unit) 기반 채널 추정 기법을 제안하였다. 제안된 방식에서는 DPA 채널

추정을 수행한 후 GRU를 이용하여 시간 및 주파수 영역에서의 특징을 추출해 DPA 과정에서 발생하는 오류 전파를 억제한다. 제안된 방식은 문헌 [6], [7]와 같이 LSTM을 사용한 방식과 비교하여 계산 복잡성이 감소하고 향상된 채널 추정 성능을 가짐을 보여주었다.

III. 결론

본 논문에서 IEEE 802.11p에서 정확한 채널 정보 획득을 위한 딥러닝 기반 채널 추정기법들에 대한 최신 연구결과들 및 한계점들을 소개 및 분석하였다. 향후, 실제 시스템 적용시 발생하는 계산복잡도와 지연 시간 등의 문제는 해결해야 할 문제로 남아있다.

ACKNOWLEDGMENT

이 논문은 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 ICT혁신인재4.0사업(IITP-2024-RS-2022-00156326, 50%)과 지역지능화혁신인재양성사업(IITP-2024-2020-0-01741, 50%) 연구임

참 고 문 헌

- [1] T. Kim and S. H. Chae, "A channel estimator via non-orthogonal pilot signals for uplink cellular IoT," *IEEE Access*, vol. 7, pp. 53419-53428, May 2019.
- [2] M. J. Kang, J. H. Lee, and S. H. Chae, "Channel estimation with DnCNN in massive MISO LEO satellite systems," in *Proc. 14th Int. Conf. on Ubiquitous and Future Netw.(ICUFN)*, pp. 825-827, Jul. 2023.
- [3] A. K. Gizzini, M. Chafii, A. Nimr, and G. Fettweis, "Deep learning based channel estimation schemes for IEEE 802.11p standard," *IEEE Access*, vol. 8, pp. 113751 - 113765, Jun. 2020.
- [4] X. Zhu, Z. Sheng, Y. Fang, and D. Guo, "A deep learning-aided temporal spectral channelNet for IEEE 802.11p-based channel estimation in vehicular communications," *EURASIP J. Wireless Commun. Netw.*, vol. 2020, no. 1, pp. 1 - 15, Dec. 2020.
- [5] A. K. Gizzini, M. Chafii, A. Nimr, R. M. Shubair, and G. Fettweis, "CNN aided weighted interpolation for channel estimation in vehicular communications," *IEEE Trans. Veh. Tech.*, vol. 70, no. 12, pp. 12796 - 12811, Dec. 2021.
- [6] J. Pan, H. Shan, R. Li, Y. Wu, W. Wu, and T. Q. Quek, "Channel estimation based on deep learning in vehicle-to-everything," *IEEE Comm. Letters*, vol. 25, no. 6, pp. 1891-1895, Jun. 2021.
- [7] A. F. D. Reis, Y. Medjahdi, B. S. Chang, J. Sublime, G. Brante, and C. F. Bader, "Low Complexity LSTM-NN-based Receiver for vehicular Communications in the Presence of High-Power Amplifier Distortions," *IEEE Access*, vol. 10, pp. 121985-122000, Nov. 2022.
- [8] J. Hou, H. Liu, Y. Zang, W. Wang, and J. Wang, "GRU-Based Deep Learning Channel Estimation Scheme for the IEEE 802.11p Standard," *IEEE Commun. Lett.*, vol. 12, no 5, pp. 764-768, May 2023.