

딥러닝 기반 OFDM 부반송파 간격 추정

박명철, 차대웅, 한동석*

전자전기공학부, 경북대학교

mcpark@knu.ac.kr, dwcha@knu.ac.kr, *dshan@knu.ac.kr

Deep Learning-based Blind OFDM Subcarrier Spacing Estimation

Myung Chul Park, Daewoong Cha, Dong Seog Han*

School of Electronic and Electrical Engineering, Kyungpook National University

요약

본 논문은 서로 다른 부반송파 간격을 가진 OFDM(orthogonal frequency division multiplexing) 기반 무선 통신 신호를 분별하기 위하여 MFB(multiple FFT window banks) 기반의 CNN(convolutional neural network) 모델을 제안한다. 기존 딥러닝 기반 ACM(automatic modulation classification) 모델은 단일 반송파 기반의 변조 방식에 대한 분류 정확성을 향상시켰다. 그러나 동일한 대역폭에서 서로 다른 부반송파 간격을 가진 OFDM 신호를 분류하지 못하는 문제점을 가진다. 본 논문에서 제안한 MFB 기반 CNN 모델의 분류 성능이 기존 시간영역에서의 IQ(in-phase and quadrature phase) 기반 CNN 모델과 A/P(amplitude/phase) 기반 LSTM(long-short term memory) 모델의 분류 성능보다 향상됨을 모의실험을 통하여 보였다.

I. 서론

최신 무선 통신 기술에서는 대용량 전송을 위하여 주파수 대역의 요구량이 증가하고 있다. 효율적인 주파수 사용을 위하여 DSA(dynamic spectrum access) 기술은 주파수 대역의 사용 여부를 판단하여 동적으로 통신 대역을 결정한다. 주파수 대역의 사용 여부를 판단하기 위해서는 신호를 감지하고 분류하는 AMC(automatic modulation classification) 기법이 필요하다 [1]. 기존의 통계적 AMC 접근 방식은 HOS(high-order statistics) [2]와 같은 전처리된 특징을 추출하여 SVM(support vector machine)과 KNN(K-nearest neighbour)와 같은 기계적 학습방법으로 신호를 분별하였다 [3]. 그러나 실제 채널 환경은 복잡하고 변화하기 때문에 통계적 기법의 분류 성능이 열화되는 문제점을 가진다 [4]. 이를 해결하기 위하여 전처리된 특징을 추출하지 않고 수신 신호로부터 딥러닝 기법으로 신호의 특징을 추출하는 AMC 기법들이 제안되었다 [5, 6, 7]. 수신받은 시간 영역의 IQ(in-phase and quadrature phase) 신호로부터 CNN(convolutional neural network)이 추출한 신호의 특징을 기반으로 한 AMC 시스템은 높은 분류 정확성을 달성하였다 [6]. 그리고 IQ 신호를 사용하지 않고 A/P(amplitude and phase) 신호를 사용하여 LSTM(long-short term memory) 모델을 통해 특징을 추출하는 AMC 시스템은 CNN 기반 시스템보다 계산량을 대폭 감소시켜 센서에서 구현이 가능해졌다 [7]. 그러나 이러한 기존 딥러닝 기반 AMC 시스템은 최신 무선 통신 시스템이 채택한 OFDM(orthogonal frequency division multiplexing) 기반 신호를 분류하지 못하는 한계를 가진다 [7].

본 논문에서는 서로 다른 부반송파 간격을 가진 OFDM 기반 신호를 분류하지 못하는 기존의 딥러닝 기반 AMC 시스템 한계를 극복하기 위하여 MFB (multiple FFT window bank) 기반 CNN 모델을 제안한다. 그리고 모의실험을 통하여 제안한 MFB 기반 CNN 모델의 분류 성능이 기존 딥러닝 기반 AMC 시스템의 성능보다 향상됨을 보였다.

II. 제안하는 MFB-CNN기반 AMC 분류기

최신 무선 통신 기술은 부반송파에 사용되는 변조 방식을 다양한 레벨의 QAM(quadrature amplitude modulation) 기법을 채택하고 있어서 변조 방식을 기반으로 무선 통신 기술을 분류하는 것이 어렵다. 이를 해결하기 위하여, OFDM을 기반으로 한 무선 통신 기술이 서로 다른 고유한 부반송파 간격을 가지고 있는 특징을 사용하는 것이 필요하다. 본 논문에서는 이러한 특징을 추출하기 위한 MFB 기반 CNN 모델을 제안한다.

MFB 기법은 예상되는 OFDM 유효 심볼 길이 N_i 동안 수신된 신호로부터 추출된 샘플을 FFT 처리기에 입력한다. 그리고 예상되는 OFDM 유효 심볼 길이의 종류만큼 FFT 처리기를 구성하고 각 FFT 처리기는 주파수 영역에서 동일한 샘플 수 K 를 가진다. 그리고 CNN을 통해 신호의 특징을 추출하기 위하여 수신받은 신호는 MFB 과정을 통해 다음과 같이 변환되어 CNN의 입력 데이터로 사용된다.

$$MFB_{N_i}^K = \{F_{N_i}^K(0), F_{N_i}^K(1), \dots, F_{N_i}^K(K-1)\}, \quad (1)$$

$$(1 \leq i \leq M),$$

여기서 $MFB_{N_i}^K$ 는 주파수 영역에서 샘플 수가 K 인 M 개의 FFT 처리기 중 예상되는 OFDM 유효 심볼 길이 N_i 를 가진 직사각형(rectangular) 윈도우를 사용하는 i 번째 FFT 처리기의 출력을 나타낸다. 그리고 k 번째 부반송파의 복소 신호인 $F_{N_i}^K(k)$ 는 다음과 같다.

$$F_{N_i}^K(k) = \sum_{n=0}^{N_i-1} r(n) e^{-j2\pi nk/K}, \quad (2)$$

여기서 $F_{N_i}^K(k)$ 는 수신 받은 시간영역 신호 $r(n)$ 으로부터 길이 N_i 만큼 추출하여 FFT 처리기에 입력되고 주파수 영역에서 샘플 수가 K 인 주파수 영역 출력 신호 중 k 번째 부반송파의 복소신호를 나타낸다. FFT 과정을 수행하기 위해서는 FFT 처리기의 주파수 영역에서 샘플 수와 동일한 입

력 샘플 수가 필요하다. 이를 위하여 FFT 처리기에 입력하기 위하여 사용된 윈도우의 출력 샘플 수가 주파수 영역에서 샘플 수보다 작을 때는 입력 샘플 뒤에 0으로 구성된 데이터를 덧붙인다. 반대로 윈도우의 출력 샘플 수가 주파수 영역에서 샘플 수보다 클 때는 주파수 영역에서 샘플 수만큼 윈도우의 출력 샘플을 잘라서 FFT 처리기에 입력된다 [8].

III. 모의실험 성능 결과

모의실험에서는 서로 다른 길이를 가진 OFDM 신호의 분류 성능을 분석하기 위하여 동일한 대역폭에서 주파수 영역에서의 샘플 수를 변화하며 OFDM 송신 신호를 생성하였다. 그리고 단일 부반송파와 다중 부반송파에서 사용된 변조 방식은 QPSK로 구성하여 분류 성능을 측정하였다. 실험에 사용된 채널 환경은 AWGN(additive white Gaussian noise) 채널로 설정하였고 SNR(signal-to-noise ratio) 범위는 -30dB에서 30dB에 대하여 분류 성능을 획득하였다. 딥러닝 구조를 학습하고 테스트에 사용된 데이터 크기는 약 51,200 프레임으로 구성하였고, CPU i9-9900K와 Nvidia Geforce Titan Xp 그래픽 카드를 사용하여 네트워크를 학습하였다. 학습 방법은 SGDM(stochastic gradient descent with momentum)을 채택하고, 초기 학습률은 0.01으로 설정하여 10번째 학습 에포크마다 이전 학습률의 10분의 1만큼 줄이면서 학습을 진행하였다.

그림 1은 SNR에 따른 기존 IQ-CNN [6] 기반 AMC 시스템과 제안한 MFB-CNN 기반 AMC 시스템의 분류 성능을 나타낸다. 기존 IQ-CNN 시스템은 입력 샘플의 길이가 1024이고, 제안한 MFB-CNN 시스템은 주파수 영역에서 샘플 수가 1024이고 예상되는 OFDM의 시간 영역에서 샘플 수의 후보군은 64, 128, 256, 512으로 총 4개의 FFT 처리기로 구성되었다.

그림 1에서 Total이라고 표시된 성능은 변조 분류의 총 성능을 나타내고 기존 IQ-CNN 시스템은 SNR 20dB에서 40.3%의 분류 정확성을 보인다. 각 변조 분류 성능을 살펴보면, 기존 IQ-CNN 시스템은 SNR 20dB에서 QPSK는 100%, 64-OFDM은 24.5%, 128-OFDM은 26.2%, 256-OFDM은 24.7%, 그리고 512-OFDM은 25.7%의 정확성을 가진다. 그리고 제안한 MFB-CNN 시스템은 SNR 20dB에서 91.3%의 총 분류 정확성을 보인다. 각 변조 분류 성능은 SNR 20dB에서 QPSK는 60.2%, 16-OFDM은 99.2%, 64-OFDM은 97.5%, 128-OFDM은 97.5%, 256-OFDM은 99.0%, 그리고 512-OFDM은 99.7%의 정확성을 가진다. 제안한 MFB-CNN 시스템은 기존 IQ-CNN 시스템보다 단일 반송파 신호를 분류하는 성능이 낮지만, 길이가 다른 OFDM 신호를 분별하는 성능이 높다.




그림. 1. AWGN 채널 환경에서 SNR에 따른 기존 DL 기법과 제안한 MFB-CNN기반 AMC 분류 성능

그림 2는 SNR이 20dB인 AWGN 채널 환경에서 기존 IQ-CNN기반 AMC 시스템의 혼합 행렬을 나타낸다. 단일 반송파 신호인 QPSK와 OFDM 사이에 혼동하는 경우는 0.2%로 매우 낮지만, 심볼 길이가 다른 OFDM 신호를 분류하지 못한다. 그러나 그림 3에서 보인 것과 같이, SNR이 20dB인 AWGN 채널 환경에서 제안한 MFB-CNN 기반 AMC 시스템의 혼합 행렬에서는 단일 반송파를 OFDM 신호로 혼동하는 경우가 39.8%로 높지만, 길이가 다른 OFDM 신호 분류 정확성이 약 99.1%로 매우 높다. 이를 통해서 기존 IQ-CNN기반 AMC 시스템은 단일 반송파와 다중 반송파 분류 성능이 높고, 제안한 MFB-CNN기반 AMC 시스템은 길이가 서로 다른 다중 반송파 분류 정확성이 매우 높음을 알 수 있다.

True Class	Predicted Class				
	QPSK	64-OFDM	128-OFDM	256-OFDM	512-OFDM
QPSK	100.0%				
64-OFDM		24.5%	26.2%	25.5%	23.8%
128-OFDM	0.2%	24.2%	26.2%	24.5%	24.8%
256-OFDM		26.5%	25.5%	24.8%	23.2%
512-OFDM		26.5%	26.2%	21.5%	25.8%

그림. 2. AWGN 채널 환경에서 SNR이 20dB일 때 기존 IQ-CNN기반 AMC 분류 성능

True Class	Predicted Class				
	QPSK	64-OFDM	128-OFDM	256-OFDM	512-OFDM
QPSK	60.2%	10.2%	11.0%	9.8%	8.8%
64-OFDM	0.5%	99.2%		0.2%	
128-OFDM	2.0%		97.5%	0.5%	
256-OFDM			0.5%	99.0%	0.5%
512-OFDM				0.2%	99.8%

그림. 3. AWGN 채널 환경에서 SNR이 20dB일 때 제안한 MFB-CNN기반 AMC 분류 성능

IV. 결론

본 논문에서는 부반송파 간격이 다른 OFDM 신호를 식별하기 위하여 MFB-CNN 기반 AMC 시스템을 제안하였다. 기존 딥러닝 기반 AMC 시스템은 시간영역에서의 IQ 또는 A/P 데이터를 사용하여 OFDM의 부반송파 간격을 분류하지 못하는 한계를 보였다. 모의실험을 통하여 본 논문에서 제안한 MFB-CNN 기반 AMC 시스템이 기존 딥러닝 기반 AMC 시스템보다 향상된 분류 성능을 보였다.

ACKNOWLEDGMENT

This research was supported by the Ministry of Trade, Industry & En

ergy(MOTIE), Korea Institute for Advancement of Technology(KIAT) through the 5G-based autonomous driving convergence technology demonstration platform project(P0013840).

참 고 문 헌

- [1] Nandi A.K. and Azzouz E.E. "Algorithms for automatic modulation recognition of communication signals," *IEEE Trans. Commun.*, vol. 46, no. 4, pp. 431 - 436, 1998.
- [2] W. Gardner, "Signal interception: a unifying theoretical framework for feature detection," *IEEE Trans. Commun.*, vol. 36, no. 8, pp. 897 - 906, 1988.
- [3] B. Kroon, S. Bergin, I. O. Kennedy, and G. O'Mahony Zamora, "Steadystate RF fingerprinting for identity verification: One class classifier versus customized ensemble," in *Proc. Artif. Intell. Cogn. Sci.*, 2010, pp. 198 - 206.
- [4] H. Bolcskei, "Blind estimation of symbol timing and carrier frequency offset in wireless OFDM systems," *IEEE Trans. Commun.*, vol. 49, no. 6, pp. 988 - 999, 2001.
- [5] T. J. O'Shea, J. Corgan, and T. C. Clancy, "Convolutional radio modulation recognition networks," in *Proc. Int. Conf. Eng. Appl. Neural Netw.*, pp. 213 - 226, 2016.
- [6] T. J. O'Shea, T. Roy, and T. C. Clancy, "Over-the-air deep learning based radio signal classification," *IEEE J. Sel. Topics Signal Process.*, vol. 12, no. 1, pp. 168 - 179, 2018.
- [7] S. Rajendran, W. Meert, D. Giustiniano, V. Lenders, and S. Pollin, "Deep learning models for wireless signal classification with distributed low-cost spectrum sensors," *IEEE Trans. on Cogn. Commun. Netw.*, vol. 4, no. 3, pp. 433 - 445, 2018.
- [8] M. Frigo and S. Johnson, "FFTW: an adaptive software architecture for the FFT," in *Proc. IEEE Int. Conf. on Acoust., Speech and Signal Process.*, vol. 3, 1998, pp. 1381 - 1384.