

IEEE 802.11ac 변조 방식의 딥러닝 기반 분류

강 석 원*·김 민 재*·최 승 원**

Deep learning-based classification for IEEE 802.11ac modulation scheme detection

Kang Seokwon·Kim Minjae·Choi Seungwon

〈Abstract〉

This paper is focused on the modulation scheme detection of the IEEE 802.11 standard. In the IEEE 802.11ac standard, the information of the modulation scheme is indicated by the modulation coding scheme (MCS) included in the VHT-SIG-A of the preamble field. Transmitting end determines the MCS index suitable for the low signal to noise ratio (SNR) situation and transmits the data accordingly. Since data field decoding can take place only when the receiving end acquires the MCS index information of the frame. Therefore, accurate MCS detection must be guaranteed before data field decoding. However, since the MCS index information is the information obtained through preamble field decoding, the detection rate can be affected significantly in a low SNR situation. In this paper, we propose a relatively robust modulation classification method based on deep learning to solve the low detection rate problem with a conventional method caused by a low SNR.

Key Words : IEEE 802.11ac, Deep Learning, Modulation Classification, Decoding

I. 서론

무선 인터넷 기능이 탑재된 모바일 휴대폰 및 IoT 기기가 늘어남에 따라서 IEEE 802.11 표준을 따르는 AP(Access Point)들에 대한 의존도가 높아지고 있다. IEEE 802.11ac는 IEEE 802.11 표준 중 하나로 5GHz 대역을 지원하는 고속 근거리 무선통신망 표준이다 [1].

이러한 근거리 무선통신의 특징은 SNR(Signal to Noise Ratio)에 매우 민감하다는 것이다[2]. 그렇기에

IEEE 802.11ac 표준에서는 SNR 상황에 따라서 적절한 MCS(Modulation Coding Scheme)을 선택해 데이터를 전송한다. 수신단에서는 어떠한 MCS를 사용했는지를 알아야 데이터를 디코딩할 수가 있기 때문에 송신단에서 MCS index에 대한 정보를 보내주어야 하고, 이 정보는 프리앰블 필드(preamble 필드)에 포함된다. 따라서 수신단의 디코딩 과정에서 프리앰블 필드를 먼저 디코딩하고 난 뒤 데이터 필드 디코딩이 이루어진다. 만약 이 과정에서 프리앰블 필드 디코딩이 잘못된다면, MCS를 잘못 선택하는 것이기 때문에 데이터 필드 디코딩이 의미 없게 된다. 따라서 이 MCS detection rate이 BER(Bit Error Rate)에 큰 영향

* 한양대학교 전자컴퓨터통신공학과 석사과정

** 한양대학교 전자컴퓨터통신공학과 교수(교신저자)

을 미친다. 그러나 프리앰블 필드를 디코딩하여 MCS 를 알아내는 방식은 SNR에 큰 영향을 받는다. 바꿔 말하면 MCS detection rate이 개선된다면 전체적인 성능 개선이 이루어질 수 있다는 뜻이다. SNR이 낮은 상황에서도 올바른 MCS detection이 이루어져서 성능이 개선된다면 더 낮은 세기로 신호를 쏘아도 디코딩이 가능하다는 의미이므로 AP와 단말기의 전력 효율을 개선할 수 있기에 전력 효율에 민감한 IoT 기기에 적용할 수 있다.

최근 딥러닝(Deep Learning)이 여러 분야에 많이 응용되고 있다[3, 4]. 무선통신 분야도 마찬가지로 딥러닝을 이용한 연구가 활발히 진행되고 있다[5]. 딥러닝을 효과적으로 통신 분야에 적용 가능한 방향 중 하나가 Modulation classification이다[6]. 본 논문에서는 딥러닝 기반 modulation classification을 IEEE 802.11ac MCS detection에 활용하는 방법을 소개한다. 딥러닝 기반 modulation classification 방법은 다음과 같다. 우선 MCS index를 알고 있는 데이터를 이용하여 딥러닝 신경망을 학습시킨다. 이렇게 학습된 신경망을 기반으로 MCS index를 맞추는 방법으로 MCS detection을 진행하고 기존 방식과의 성능을 비교한다.

논문의 순서는 다음과 같다. II에서 IEEE 802.11ac 표준과 프리앰블 필드, 그리고 MCS index에 대해서 소개하며, 관련 연구에 대한 내용도 다룬다. III에서 본 논문에 사용된 딥러닝 모델에 대해서 설명한다. IV에서는 시뮬레이션 결과를, V에서는 시뮬레이션 결과에 대한 분석 및 결론을 이야기한다.

II. 관련 연구

2.1 IEEE 802.11ac

IEEE 802.11ac는 2014년 초에 최종 승인된 802.11

표준 중 하나이다. 이전 표준인 802.11n[7]과의 차이점은 대역폭과 프리앰블 필드의 변화이다. 802.11n의 경우는 최대 40MHz까지의 대역폭만 지원했었으나, 802.11ac는 40MHz부터 160MHz까지 더 넓은 대역폭을 지원함으로써 더 높은 데이터 전송률을 지원할 수 있도록 하였다. 또한 기존 프리앰블 필드에 추가적으로 VHT(Very High Throughput) 필드를 추가하여 기존 표준과의 호환성을 만족시키고 동시에 변조에 사용 가능한 옵션들을 추가하였다.

IEEE 802.11ac 표준은 BPSK부터 256QAM까지의 총 5가지 변조 방식(modulation scheme)과 1/2, 2/3, 3/4, 5/6 등 다양한 부호화율(coding rate)을 지원한다. 변조 방식과 부호화율의 조합을 MCS(modulation coding scheme)라고 하고, IEEE 802.11ac 표준에는 이 MCS 조합이 총 10개가 존재한다. MCS는 서로 다른 SNR 값에 따라서 제한이 존재한다. <표 1>은 MCS index에 따른 변조방식과 부호화율, 그리고 그에 따른 데이터 전송 속도(throughput)과 SNR 제한에 대한 표이다.

송신단에서는 <표 1>에 표기된 SNR 값을 기준으로 하여 채널 상황에 따라 적절한 MCS index를 결정해서 데이터를 코딩하여 전송하게 되며 이에 따라서 데이터 전송 속도가 바뀐다. 수신단에서는 송신단에서 어떤 MCS index를 결정해서 보냈는지 알아야 데이터 디코딩이 가능하다.

<표 1> MCS에 따른 throughput 및 요구 SNR

MCS Index	Modulation	Code rate	Throughput [Mbps]	SNR [dB]
0	BPSK	1/2	6.5	2
1	QPSK	1/2	13	5
2	QPSK	3/4	19.5	9
3	16QAM	1/2	26	11
4	16QAM	3/4	39	15
5	64QAM	2/3	52	18
6	64QAM	3/4	58.5	20
7	64QAM	5/6	65	25
8	256QAM	3/4	78	29
9	256QAM	5/6	86.7	31

<그림 1>은 802.11ac의 프리앰블 필드에서의 MCS index 정보의 위치를 나타낸 것이다. 프리앰블 필드는 다른 표준에도 존재하는 legacy 필드와 802.11ac에만 존재하는 VHT 필드로 나누어져 있다. Legacy 필드는 동기화와 채널 추정 및 보상에 이용된다. VHT 필드는 802.11ac에서 더 높은 데이터 전송 속도를 위해 도입된 필드이다. VHT 필드는 VHT-SIG-A, VHT-STF, VHT-LTF, VHT-SIG-B라는 네 가지 필드로 구성되어 있으며 SU-MIMO(Single-User MIMO)의 경우 MCS index 정보는 VHT-SIG-A에 속한다. MU-MIMO(Multi-User MIMO)의 경우에는 VHT-SIG-B 필드에도 여러 사용자에게 대한 추가적인 MCS index 정보가 포함된다.



<그림 1> Preamble 필드 중 MCS index의 위치

MCS index 정보가 포함된 VHT 필드는 BPSK로 변조되어있다. 그러므로 MCS index의 detection rate 은 BPSK signal을 맞게 디코딩할 확률과 같다.

2.2 관련 연구

많은 무선통신에서 사용되는 데이터 변조 방식으로는 BPSK(Binary Phase Shift Keying), QPSK(Quadrature Phase Shift Keying), QAM(Quadrature Qamplitude Modulation) 등이 있다. 데이터의 수신을 위해서는 변조 방식을 알아야하기 때문에 LTE, 5G, IEEE 802.11 등 무선통신 표준의 컨트롤 필드에는 데이터 변조 방식을 알리기 위한 MCS 필드가 포함된다. 만약 데이터 자체만 보고 변조 방식을 알아낼 수 있다면 MCS 필드는 필요없게 되는 것이고 데이터의 오버헤드를 줄일 수 있다. 그리고 데이터 자

체만 보고 어떤 변조 방식인지 맞추기에 적합한 알고리즘이 딥러닝이다. 분류하기 위한 방법으로는 수신된 데이터의 constellation 그래프를 보고 맞추는 방법 [8], 데이터 자체만 보고 맞추는 방법 [9] 등이 제시되었다. 이 방법들로 높은 SNR 상황에서의 성능 개선과 동시에 데이터의 오버헤드를 줄일 수 있게 되었다. 그러나 낮은 SNR 상황에서의 성능은 여전히 아쉬운 점으로 남아있었다. 본 연구는 IEEE 802.11ac 표준에 특화된 딥러닝 기반 변조방식 분류이다. 데이터 자체만 보고 변조 방식을 맞추는 것은 한계가 있으므로, IEEE 802.11ac의 프리앰블 필드까지 활용하여 낮은 SNR 상황에서도 강인한 딥러닝 기반 분류 방식을 제시하려고 한다.

III. 딥러닝 모델

이 논문에서는 프리앰블 필드를 디코딩해서 MCS index를 알아내는 기존의 방식과 딥러닝을 이용해서 변조 방식을 맞추는 방식의 성능을 비교한다. 딥러닝은 신경망(Neural Network) 내부의 가중치(weight)들을 학습을 통해 최적화해서 정답을 맞추는 방법이다. 따라서 딥러닝으로 최적의 성능을 내기 위해서는 적절한 신경망과 옵티마이저(optimizer)를 선택해야 한다.


신경망의 경우는 CNN(Convolutional Neural Network)를 적용하였고, 옵티마이저는 ADAM 옵티마이저를 사용하였다.

3.1 CNN(Convolutional Neural Network)

CNN은 convolution layer을 포함한 레이어들로 이루어진 신경망이다[10]. CNN은 다른 신경망에 비해 2차원 데이터의 전체적인 특성을 파악하는 성능이 뛰어나기 때문에 이미지 처리에 많이 사용된다. 통신

분야에서 사용되는 신호는 복소수 값으로 실수 부분과 허수 부분의 값을 가지며, 일종의 2차원 데이터라고 볼 수 있다. 이러한 부분에서 이미지 처리처럼 CNN 기반의 딥러닝 신경망이 유용할 것이라고 예측할 수 있다. 또한 실제로 통신 분야의 딥러닝 기반 분류에 CNN을 이용해 좋은 성능의 결과를 얻은 연구 결과가 존재한다[10]. 그렇기에 본 논문에서는 여러 신경망 중 CNN 신경망을 선택해 사용하였다.

<그림 2>는 CNN의 구조이다. Convolution 레이어는 실수부, 허수부로 이루어진 2차원 데이터와 필터를 convolution한다. Pooling 레이어는 convolution을 거친 데이터에서 선택적으로 특성을 뽑아내는 역할을 수행한다. 이 두 종류의 레이어가 CNN의 대표적인 구성 요소이며, 필요에 따라 다른 레이어들을 추가하여 신경망을 만들 수 있다.



<그림 2> CNN의 구조

3.2 Adam 옵티마이저

딥러닝은 학습을 통해서 가중치를 갱신해서 신경망을 최적화한다. 가중치를 갱신할 때는 loss function의 기울기인 gradient를 이용한다. Gradient를 어떤 값의 학습률(learning rate)을 통해 학습에 반영하는지에 따라서 옵티마이저의 종류가 나뉜다. Adam은 2014년에 제안된 옵티마이저이다[11]. Adagrad 방식과 모멘텀 방식의 장점을 융합한 방식으로 가장 일반적으로 사용되는 옵티마이저이다.

3.3 시뮬레이션 환경 설정

시뮬레이션을 위한 입력으로는 프리앰블 필드 전체와 데이터 필드의 일부분을 사용했다. VHT 필드 중 VHT-SIG-B 필드의 길이가 사용자 수에 따라서 달라지기 때문에 학습에 일정한 길이의 데이터를 제공하기 위해서 SU-MIMO 상황을 가정하였다. 이때의 프리앰블 필드의 길이는 800이다. 여기에 데이터 필드에서 100만개의 데이터를 추가적으로 이용하였으며 따라서 입력의 총 길이는 900이다. <표 2>는 입력과 딥러닝 신경망에 사용된 레이어들에 대해 정리해 놓은 표이다. 입력은 길이 900인 IQ 샘플, 즉 복소수 값이다. 이 데이터가 실수부, 허수부로 나뉘어서 (900,2)의 2차원 형태로 들어가게 된다. 이어서 2차원 데이터를 처리하기 위한 Convolution 2D 레이어가 두 개 들어간다. 이렇게 Convolution 레이어를 거친 2차원 데이터를 1차원으로 낮추기 위한 Flatten 레이어를 들어가고, 마지막으로 Dense 레이어 두 개 들어간다. Dense 레이어의 출력의 수는 각자 64, 16이다. Loss function으로는 Categorical cross entropy를 사용하였다. 배치 크기(Batch size)는 100, epochs는 1000으로 설정하였다.

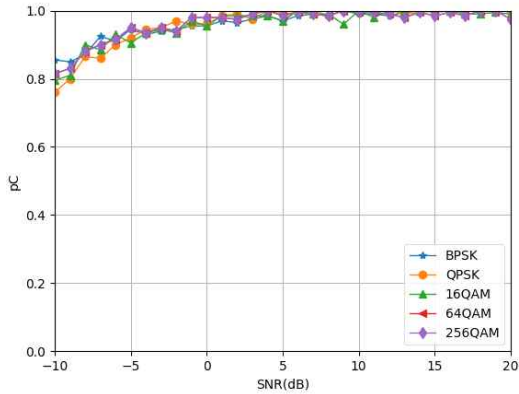
<표 2> 딥러닝에 사용된 신경망 모델과 데이터

Input	900 IQ samples
Convolution 2D	Filter=64, Kernel size=(2,4), RELU
Convolution 2D	Filter=16, Kernel size=(1,4), RELU
Flatten	2D -> 1D
Dense (RELU)	64
Dense (RELU)	16
Output	5
Loss function	Categorical Cross Entropy

프리앰블 필드를 포함하지 않은 딥러닝 방식과의 성능 비교를 위하여 데이터 필드를 이용한 학습도 진행했다. 이 때 사용한 데이터의 길이는 100이다. 신경망의 구조는 <표 2>와 동일하게 사용하였다.

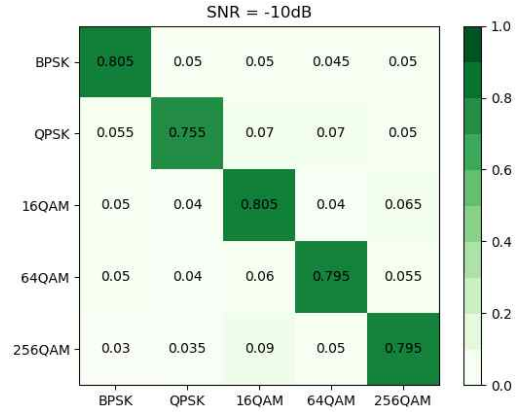
IV. 시뮬레이션 결과

본 시뮬레이션은 변조 방식에 대해서만 분류를 진행하였고 부호화율에 대해서는 분류하지 않았다. 따라서 MCS index는 다르지만 변조 방식이 같은 경우에는 부호화율이 가장 낮은 데이터를 이용하였다. 즉 MCS index가 0, 1, 3, 5, 8인 총 다섯 가지 경우에 대해서 분류한 것이다. 이때의 변조 방식은 BPSK, QPSK, 16QAM, 64QAM, 256QAM으로 총 5개이다. SNR을 -10dB부터 20dB까지 1dB 간격으로 변경해가며 detection rate을 구하는 시뮬레이션을 진행하였다. <그림 3>은 프리앰블 필드까지 이용한 딥러닝 방식으로 어떤 변조 방식을 사용하였는지 맞춘 확률에 대한 그래프이다. SNR이 -10dB라는 노이즈가 심한 환경에서도 모든 변조방식에 대해서 75%가 넘는 detection rate을 보였으며 0dB대역 이상부터는 90% 이상의 detection rate을 보였다.




<그림 3> 프리앰블 필드 이용 시 SNR 대비 detection rate

<그림 4>는 -10dB 대역에서의 confusion matrix이다. confusion matrix를 통해서 변조 방식을 잘못 분류한 경우 어떤 변조 방식으로 잘못 분류했는지 시각적으로 확인할 수 있다.



<그림 4> SNR = -10dB일때의 confusion matrix


프리앰블 필드를 포함해서 학습했을 때와 포함하지 않고 학습했을 때의 성능 비교를 위하여 800 point의 프리앰블 필드를 제외하고 100 point의 데이터 필드만 이용해서 학습을 하였다. <그림 5>는 이 경우의 SNR 대비 변조 방식 detection rate을 나타낸 그래프이다.



<그림 5> 데이터 필드만 이용 시 SNR 대비 detection rate

마지막으로 위 두 결과와 비교하기 위해 프리앰블 필드를 디코딩하여 MCS index를 올바르게 detection 할 확률을 MCS index별로 구하였다. 각 MCS index마다 SNR을 -10dB부터 20dB까지 1dB간격으로 4000

회색 시뮬레이션하였으며, <그림 6>이 그 결과이다.



<그림 6> 프리앰블 필드 디코딩 방식의 detection rate

V. 결론 및 향후 과제

기존에도 BPSK, QPSK, QAM 등의 신호들 중 어떤 변조 방식을 사용했는지 detect하는 연구는 있었다[10]. 이러한 연구들의 detection rate은 <그림 5>에 나타난 결과와 비슷한 확률을 보인다. 그러나 이러한 경우의 detection rate은 IEEE 802.11처럼 프리앰블 필드가 포함된 신호가 아니므로 <그림 4>의 프리앰블 필드가 포함된 detection rate에 비해서 상대적으로 성능이 떨어진다. 이 방식은 기존의 프리앰블 필드를 디코딩해서 MCS index를 구해내는 방법, 즉 <그림 6>에 나타나는 결과보다는 낮은 SNR 대역에서 성능이 좋다. 그러나 높은 SNR 대역에서 기존 방식이 100%에 가까운 detection rate을 보임을 감안했을 때 이 방법으로 완전히 대체하는 것은 어렵다. 따라서 낮은 SNR 대역에서 성능 보조 용도로 사용하고 높은 SNR 대역에서는 기존 방식을 이용하는 방식으로는 사용할 수는 있을 것으로 보인다.

본 시뮬레이션처럼 프리앰블 필드까지 포함해서 학습시킨 경우에는 기존 방식은 물론 프리앰블 필드

를 포함시키지 않은 딥러닝 방식과도 성능 면에서 큰 차이를 보인다. 특히 0dB 이하 대역, 즉 노이즈의 세기가 신호의 세기보다 강한 상황에서도 90%에 가까운 detection rate을 보이는 등 노이즈에 강인하다.

이렇게 높은 detection rate을 보이기 때문에 딥러닝 방식을 이용했을 때 얻을 수 있는 이득이 있다. 송신단 입장에서는 더 낮은 SNR 상황에서도 높은 변조 방식을 선택하여 송신할 수 있으며 그에 따라서 전송 속도가 증가한다. 무선통신은 한정된 자원을 최대한 활용해서 전송 속도를 증가시키기 위해서 많은 기법들을 사용한다는 점을 고려하면 이는 큰 이점이다.

또는 전력 소모를 줄일 수도 있다. 같은 상황에서 신호의 세기를 낮추면 상대적으로 노이즈의 비율이 증가한다. 즉 SNR 값이 작아지는 것이다. 따라서 노이즈의 세기가 같은 상황에서 더 높은 데이터 전송 속도 달성을 위해서는 신호 세기를 크게 해야 하는데, 딥러닝 방식을 이용한다면 같은 노이즈 세기인 상황에서 기존 방식보다 높은 변조 방식을 이용해 데이터 전송율을 높이는 것이 가능하므로 전력 소모에 민감한, 예를 들면 IoT 기기에 딥러닝 방식을 적용했을 때 전력 소모 문제를 일부 해소하는 효과를 기대할 수 있다.

추가적으로 기대할 수 있는 효과는 프리앰블 필드의 bit 절약이다. MCS index는 프리앰블 필드 중 총 4bit를 차지하고 있다. 그러나 딥러닝 방식으로 modulation index를 구해낼 수 있다면 프리앰블 필드에 이 정보를 실어서 보낼 필요가 없으므로 부호화율 정보만 전송하면 된다. 부호화율은 1/2, 2/3, 3/4, 5/6으로 4가지이므로 2bit만으로도 표현이 가능하므로 MCS index의 4bit 중 2bit를 절감할 수 있다. 따라서 프리앰블 필드 오버헤드를 줄이는 효과를 기대할 수 있다.

이렇게 기존 방법보다 좋은 성능을 내는 딥러닝 방법이지만 한계점이 존재한다. 바로 딥러닝 방식을 사용하기 위한 연산 오버헤드이다. 실제 시스템에 적용

하기 위해서는 아직 많은 연산량 최적화가 필요하며, 이는 앞으로 도전해보아야 할 과제이다. 따라서 현재 사용하고 있는 구성의 신경망이 아닌 다른 신경망들로 바뀌가면서 시뮬레이션을 해 보며 연산량과 성능의 최적의 타협점을 찾아보려고 한다. 그리고 지금의 시뮬레이션 결과는 실제 RF 데이터를 송수신해서 결과를 낸 것이 아니라 IEEE 802.11ac 표준에 맞게 데이터를 생성하고 채널을 적용하여 시뮬레이션을 한 것이므로 RF 데이터를 사용하였을 때도 이 시뮬레이션만큼 성능이 잘 나올지는 앞으로 확인을 해 보아야 한다. 따라서 실제 RF 데이터를 이용해서도 같은 성능이 나오는지 확인을 해 보려고 한다.

Acknowledgment

이 논문은 정부 (과학기술정보통신부)의 재원으로 정보통신기술진흥센터 (IITP) 의 지원을 받아 수행된 연구임. (No. 2017-0-00723, Reconfigurable Radio System 기술을 적용한 소프트웨어 기반 서비스 지향 통합 기지국 플랫폼 개발)

참고문헌

- [1] Ong, Eng Hwee, et al. "IEEE 802.11 ac: Enhancements for very high throughput WLANs," 2011 IEEE 22nd International Symposium on Personal, Indoor and Mobile Radio Communications, IEEE, 2011.
- [2] Korowajczuk, Leonhard, ed. LTE, WiMAX and WLAN network design, optimization and performance analysis, John Wiley & Sons, 2011.
- [3] 조은숙·민소연·김세훈·김봉길, "딥러닝을 통한 의미·주제 연관성 기반의 소셜 토픽 추출 시스템 개발," 디지털산업정보학회 논문지, 제14권, 4호, 2018, pp.35-45
- [4] 임상현·이명숙, "딥 러닝 기반의 악성흑색종 분류를 위한 컴퓨터 보조진단 알고리즘," 디지털산업정보학회 논문지, 제14권, 4호, 2018, pp.69-77
- [5] Wang, Tianqi, et al. "Deep learning for wireless physical layer: Opportunities and challenges," China Communications 14.11, 2017, pp.92-111.
- [6] Mendis, Gihan J., Jin Wei, and Arjuna Madanayake, "Deep learning-based automated modulation classification for cognitive radio," 2016 IEEE International Conference on Communication Systems (ICCS), IEEE, 2016.
- [7] Xiao, Yang, "IEEE 802.11 n: enhancements for higher throughput in wireless LANs," IEEE Wireless Communications 12.6, 2005, pp.82-91.
- [8] Mobasseri, Bijan G, "Digital modulation classification using constellation shape," Signal processing 80.2, 2000, pp.251-277.
- [9] Peng, Shengliang, et al. "Modulation classification using convolutional neural network based deep learning model," 2017 26th Wireless and Optical Communication Conference (WOCC), IEEE, 2017.
- [10] Lawrence, Steve, et al. "Face recognition: A convolutional neural-network approach," IEEE transactions on neural networks 8.1, 1997, pp.98-113.
- [11] Kingma, Diederik P. and Jimmy Ba, "Adam: A method for stochastic optimization," arXiv preprint arXiv:1412.6980, 2014.

■ 저자소개 ■

논문접수일 : 2020년 6월 1일
 수정일 1차 : 2020년 6월 13일
 수정일 2차 : 2020년 6월 17일
 게재확정일 : 2020년 6월 18일



강 석 원
Kang, Seok Won

2019년 9월~현재
 한양대학교 전자컴퓨터통신공학과
 석사과정
 2019년 8월 한양대학교 융합전자공학부
 (공학학사)
 관심분야 : FPGA, LTE, 5G, Deep learning
 E-mail : seekwon.kang@dsplab.hanyang.ac.kr



김 민 재
Kim, Min Jae

2018년 9월~현재
 한양대학교 전자컴퓨터통신공학과
 석사과정
 2018년 2월 가천대학교 전자공학과(공학학사)
 관심분야 : 5G, NB-IoT, LTE-M, DSP,
 FPGA, eCPRI etc.
 E-mail : minjae.kim@dsplab.hanyang.ac.kr



최 승 원
Choi, Seung Won

2012년 3월~현재
 HY-MC 연구센터 센터장
 2002년~2011년
 HY-SDR 연구센터 센터장
 1992년~현재
 한양대학교 융합전자공학부 교수
 1990년~1992년
 일본 우정성 통신연구소 선임
 연구원
 1989년~1990년
 ETRI 선임 연구원
 1988년~1989년
 미국 Syracuse대학 전지 및 전산과
 교수
 1988년 12월 미국 Syracuse대학 전기공학
 (공학박사)
 1985년 12월 미국 Syracuse대학 전기공학
 (공학석사)
 1982년 2월 서울대학교 전자공학 (공학석사)
 1982년 2월 한양대학교 전자공학 (공학학사)
 관심분야 : SDR, 이동통신, 신호처리
 E-mail : choi@dsplab.hanyang.ac.kr