디지털산업정보학회 논문지 제16권 제2호-2020년 6월
http://dx.doi.org/10.17662/ksdim.2020.16.2.027

CNN 기반의 IEEE 802.11 WLAN 프레임 포맷 검출

김 민 재*·안 흥 섭**·최 승 원***

CNN based IEEE 802.11 WLAN frame format detection

Kim Minjae·Ahn Heungseop·Choi Seungwon

〈Abstract〉

Backward compatibility is one of the key issues for radio equipment supporting IEEE 802.11, the typical wireless local area networks (WLANs) communication protocol. For a successful packet decoding with the backward compatibility, the frame format detection is a core precondition. This paper presents a novel frame format detection method based on a deep learning procedure for WLANs affiliated with IEEE 802.11. Considering that the detection performance of conventional methods is degraded mainly due to the poor performances in the symbol synchronization and/or channel estimation in low signal-to-noise-ratio environments, we propose a novel detection method based on convolutional neural network (CNN) that replaces the entire conventional detection procedures. The proposed deep learning network provides a robust detection directly from the receive data. Through extensive computer simulations performed in the multipath fading channel environments (modeled by Project IEEE 802.11 Task Group ac), the proposed method exhibits superb improvement in the frame format detection compared to the conventional method.

Key Words : IEEE 802.11, Format Detection, Deep Learning, CNN

Ⅰ. 서론

WLAN (Wireless Local Area Network) 영역에서 해마다 늘어나는 데이터 트래픽에 대응하기 위해 새로운 IEEE 802.11 표준들이 출시되고 있으며, 새로운 표준을 지원하는 기기들 또한 출시되고 있다[1]. 최신 IEEE 802.11 표준을 지원하는 기기들은 기존에 존재하던 표준을 지원하는 기기들과의 공존을 위해 역 호환성이 보장되어야 한다[2]. 예를 들어, IEEE 802.11 ac 표준을 준수하는 기기의 경우 프레임 포맷으로 VHT (Very Hight Throughput)을 사용하며 기존에 존재하던 IEEE 802.11 a에서 사용하는 프레임 포맷인 non-HT (non-High Throughput), IEEE 802.11 n에서 사용하는 프레임 포맷인 HT-MF (High Throughput-Mixed Format)와의 호환성을 지원해야 하며, 각 프레임 포맷마다 구성이 다르다[3]. 그렇기에 역 호환성 (Backward compatibility)을 지원하기 위한 첫 번째 단계는 프레임 포맷 검출하는 과정이다. 성공적인 패킷 디코딩을 위해선 낮은 SNR (Signal-to-noise-ratio)

* 한양대학교 전자컴퓨터통신공학과 석사과정(제1저자)
** 한양대학교 전자컴퓨터통신공학과 박사과정(참여저자)
*** 한양대학교 전자컴퓨터통신공학과 교수(교신저자)

의 환경과 멀티패스 채널 환경에서도 프레임 포맷을 성공적으로 검출하는 방법이 필요하다.

딥러닝은 컴퓨터 비전 및 자연어 처리 등의 다양한 분야에서 성공적으로 적용되어 왔으며 [4, 5], 이런 흐름에 따라 딥러닝을 이동 통신 네트워크 및 WLAN 영역에도 적용하기 위한 연구가 활발하다[6]. 딥러닝을 네트워크 분야에 적용하는 초기 연구는 라우팅, 스케줄링, 자원 할당과 같은 통신 프로토콜의 상위 계층 관련 연구가 주였지만, 최근에는 신호 감지, 변조 분류, 채널 코딩 등과 같은 물리 계층의 신호처리 분야에 딥러닝을 적용하려는 연구 또한 활발하다[7, 8].

기존 방식의 경우 채널이 심한 페이딩을 겪고 낮은 SNR 상황일 때 프레임 포맷을 올바르게 검출할 수 없었다[9]. 이러한 문제를 해결하기 위해 본 논문에서는 신경망 (Neural Network) 중 하나인 CNN (Convolution Neural Network) 기반의 IEEE 802.11 프레임 포맷 검출 방법을 제안한다.

CNN의 경우 일반적인 DNN (Deep Neural Network)과 다르게 여러 차원의 데이터 형태를 이용할 수 있다. 그로 인해 데이터 형태를 그대로 사용할 수 있어 데이터의 특징을 추출하는데 강력하다. 또한 CNN의 경우 이미지 프로세싱 분야에 많이 사용되고 있으며, 이미지 분류문제에서 강한 성능을 보여주고 있다. 최근에는 통신 분야에서 낮은 SNR에서 변조 방식을 분류하는데 강한 성능을 보였다[10]. 마찬가지로 본 논문에서 해결하고자 하는 문제인 프레임 포맷 검출의 경우도 분류문제에 가깝기에 CNN을 사용하는 것이 적합하다고 판단을 하였다. 결과적으로 CNN을 사용한 프레임 포맷 검출의 성능은 기존 방법보다 10dB 이상의 성능 향상을 보였다. 이로 인해 낮은 SNR와 멀티패스의 환경에서 딥러닝을 적용하였을 때 프레임 포맷 검출 성능이 좋다는 것을 확인하였다.

본 논문의 구성은 다음과 같다. Section 2에서 기존 방법과 딥러닝 방법에 대한 설명을 하고 section 3에서는 시뮬레이션의 결과를 보이며, section 4에서는 시뮬레이션 결과에 대한 결론을 맺으며 향후 연구과제에 대해 설명을 한다.

II. 검출 방법

이 장에서는 IEEE 802.11 수신 데이터의 프레임 형식을 검출하는 일반적인 방법에 대해 간략하게 설명을 하며, 기존 방법의 한계점을 고려하여, 7개 계층으로 구성된 딥러닝 네트워크를 기반으로 프레임 포맷을 검출하는 새로운 방법을 제안한다. 목표는 IEEE 802.11a/n/ac 의 3가지 프레임 형식, Non-HT, HT-MF, VHT의 형식을 파악하는 것이다.

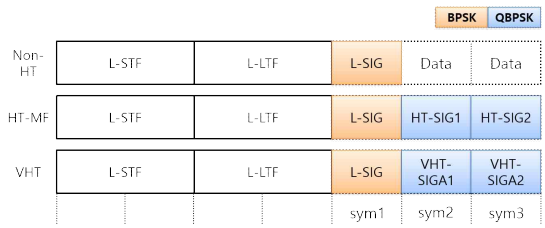

<그림 1> IEEE 802.11 a/n/ac 프레임 포맷

<그림 2>는 <그림 1>에 명시된 BPSK와 QBPSK의 성상도를 나타낸다.

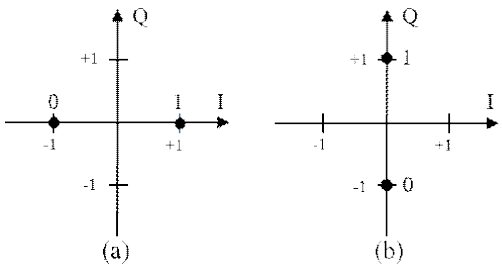

<그림 2> (a) BPSK (b) QBPSK

2.1 기존 방법

<그림 1> IEEE 802.11a/n/ac에서 사용하는 세 가지 포맷 Non-HT, HT-MF, VHT 를 나타낸다. L-LTF (Legacy-Long Training Field) 이후 의 세 개의 심볼들을 BPSK (Binary Phase Shift Keying), QBPSK (Quadrature Binary Phase Shift Keying)를 이용한 조합들로 구성되어 Non-HT, HT-MF, VHT 포맷을 분류가 가능하다[9].

수신 데이터의 프레임 포맷을 검출하는 기존의 방식은 대부분 채널 추정에 근거 한다. <그림 3>은 802.11a/n/ac 의 프레임 포맷을 검출하는 절차를 보인다. <그림 3>과 같이 프레임 검출 절차를 수행하기 전에 동기화, L-LTF 추출, L-LTF 복조, 채널 추정/보상 등의 절차를 걸쳐 수신 데이터를 처리해야 한다. 그런 다음에 위에서 언급한 L-LTF 이후의 3개의 심볼을 프레임 포맷 검출에 사용한다. 첫째로, Non-HT의 경우 첫 번째 심볼이 BPSK이며 코딩 레이트가 1/2 또는 3/4 일 수 있는 반면에 HT-MF와 VHT의 경우는 BPSK 코딩 레이트는 1/2의 경우만 있기 때문에 첫 번째 심볼의 변조 방식과 코딩 레이트를 확인하여 Non-HT를 구분하며 그다음으로, 두 번째 심볼이 QBPSK이면 HT-MF 아닐 경우 세 번째 심볼이 QPBSK인 경우 VHT로 분류하며, 아닐 경우에는 Non-HT로 구분을 한다.

2.2 딥러닝 기반 방법

본 논문에서 제안하는 딥러닝 기반의 프레임 포맷 검출 방법은 <그림 3>과 같은 절차적인 기존 방법을 <그림 4>와 같은 신경망으로 대체하였다. 기존 방법은 동기화, 채널 추정, 채널 보상의 과정이 단계적으로 이루어 져야 한다. 그렇기에 채널 보상은 채널 추정에 영향을 받고, 채널 추정은 동기화에 영향을 받게 된다. 이러한 절차적인 방법과는 다르게 제안하는

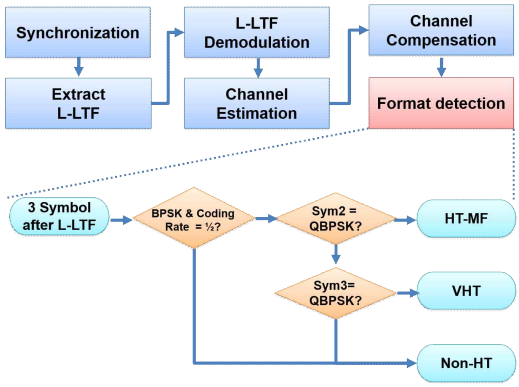

<그림 3> 기존방법의 플로우 차트

딥러닝 방법은 데이터의 전체를 활용한다. 즉, 어느 부분의 데이터가 잘못되었다고 해도 다른 부분의 데이터를 활용하여 판단을 할 수 있기에 기존 방법보다 검출 성능이 좋다.

본 논문에서 사용한 신경망은 <표1>과 같이 구성하였으며 2차원 Convolution layer와 Maxpooling layer, 완전 연결인 Dense layer를 사용하였다. Input layer의 경우 <그림 1>에 표현된 7개의 심볼과 그 뒤의 1개의 심볼 총 8개의 심볼 길이를 사용하였다. 심볼마다 80개의 샘플로 구성되어 있기에 640개의 샘플의 길이를 사용하며, 샘플은 complex value로 구성되어 있기에 Real part와 Image part를 나누어 (640,2)의 형태의 데이터가 Input layer로 들어간다. Hidden layer의 경우 2차원 데이터를 처리를 할 수 있는 Convolution layer를 사용하고 추출된 특징의 개수를 줄이고자 Maxpooling layer를 사용하였다. 활성화 함수로는 음의 값이 일부 표현이 가능한 SELU (Scaled Exponential Linear Unit)를 사용하였다[11]. Output layer의 활성화 함수로는 Output의 총합이 1이 되어 확률 같이 표현할 수 있는 Softmax를 사용하였다. Loss function으로는 다중 분류에 능한 Categorical cross entropy를 사용하였고 Optimizer로는 학습속도가 빠르고 Step size를 이전 Gradient 값을 이용하여

정하는 Adam (Adaptive moment estimation)을 사용하였다[12].

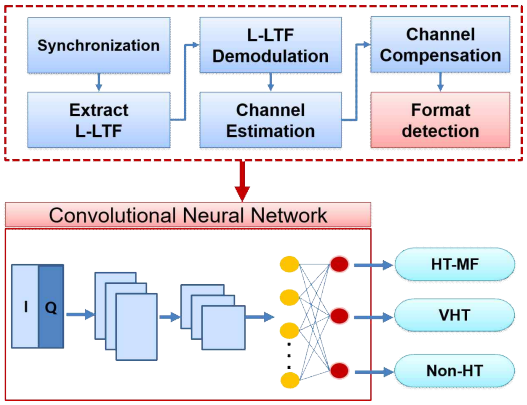

<그림 4> CNN 기반의 프레임 포맷 검출 블록 다이어그램

<표 1> Network 구성

Input	640 Complex value
Conv2D(SELU)	Filters:128, Kernel size: (2,2)
MaxPooling2D	Pool size: (2,2), Strides = 2
Conv2D(SELU)	Filters: 64, Kernel size: (2,2)
MaxPooling2D	Pool size: (2,2), Strides = 2
Dense(SELU)	64
Dense(SELU)	128
Output	3
Loss Function	Categorical Cross Entropy
Optimizer	Adam
Learning Rate	0.001
Batch size	64

Ⅲ. 실험 및 분석결과

이 장에서는 실험에 사용될 TX 데이터의 생성방법과 RX 데이터의 매개변수(채널, 노이즈) 설정에 대한 설명을 한다. 그런 다음, <그림 4>에서 나타낸 제안된 딥러닝 절차에서 얻은 시뮬레이션 결과를 <그림 3>에 나타낸 기존의 방법과 비교한다.

시뮬레이션에서 사용된 데이터는 MATLAB WLAN 툴박스를 사용하며, <표 2>의 파라미터를 이용하여 <그림 5>와 같은 절차로 생성하였다.

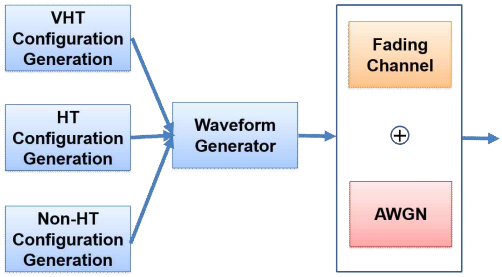

<그림 5> 데이터 생성 과정

중심 주파수로 IEEE 802.11a는 5GHz, IEEE 802.11n은 2.4GHz와 5GHz를 사용하며, IEEE 802.11ac의 경우 5GHz를 사용한다. 사용하는 대역폭으로는 Non-HT의 경우 5, 10, 20MHz를 사용하며, HT의 경우 20, 40MHz를 사용한다. VHT의 경우 20, 40, 80, 160 MHz를 사용한다. 실험에서 사용한 데이터는 3개의 포맷이 가장 구분을 어렵게 하기 위해 중심 주파수로는 5GHz, 대역폭으로는 20MHz로 하였다. 그리고 데이터 필드의 변조를 BPSK를 사용하였다.

<표 2> 데이터 파라미터

Class	Non-HT, HT-MF, VHT
Carrier frequency	5GHz
Bandwidth	20MHz
Channel	IEEE 802.11ac multipath fading channel (Model-A ~ F)
Noise	AWGN
SNR	-10 ~ 20 dB
Data Field Modulation scheme	BPSK

사용한 채널은 <표 3>에 표시된 IEEE 802.11 Task

Group ac에서 정한 6개의 fading 채널 모델을 사용하였다[13, 14]. 그리고 SNR을 −10dB에서부터 20dB까지 변경하면서 데이터를 생성 하였다. 즉, 훈련 데이터 셋은 각 채널 마다 Non-HT, HT, VHT 3개의 포맷을 8개의 심볼의 길이로 (640 샘플), 500개씩 SNR을 1dB단위로 변경해가며 총 6(채널모델) x 3(포맷) x 640(샘플 수) x 500 x 31(SNR[-10, 20]))를 이용한다.

<표 3> IEEE 802.11 TGac multipath fading channel

Parameter	Model					
	A	B	C	D	E	F
Breakpoint distance(m)	5	5	5	10	20	30
RSM delay spread(ns)	0	15	30	50	100	150
Maximum delay(ns)	0	80	200	390	730	1050
Rician K-factor(dB)	0	0	0	3	6	6
Number of taps	1	9	14	18	18	18
Number of clusters	1	2	2	3	4	6

<표3>에 표시된 채널들은 Model-A에서 Model-F로 이동함에 따라 복잡해짐을 알 수 있다. 예를 들어 Model-A는 주거 환경에 해당하고 Model-F는 도시환경에 해당한다.

<그림 6>에서는 기존방식과 딥러닝 방식을 이용하여 프레임 포맷 검출을 했을 때의 결과를 나타낸다. 기존 방식의 경우 15dB에서 100%에 가까운 성능을 보이고, 딥러닝 방식의 경우 5dB에서 100%에 가까운 성능을 보인다. <그림 7>에서는 가장 복잡한 채널인 Model-F에서 SNR −10, -7, -4, 0dB에서의 혼동행렬(confusion matrix)을 보인다.

결과적으로 기존 방식보다 딥러닝 방식이 10dB가량 성능의 향상을 보였다. 이로 인해 낮은 SNR과 멀티패스 환경에서도 프레임 포맷 검출을 정확히 할 수 있기에 패킷 디코딩의 성능향상을 기대할 수 있다. 또한 기존 방법의 경우 동기화, 채널 추정, 채널 보상과 같은 과정이 단계적으로 이루어져야 한다. 그렇기에 채널 보상은 채널 추정에 영향을 받고, 채널 추정은 동기화의 영향을 받게 된다. 이 같은 경우는 어느 한 부분의 과정이 잘못되었을 경우 정상적인 검출을 할 수 없다. 그러나 제안된 딥러닝 방법의 경우 절차적이지 않고 데이터의 전체적인 부분을 사용한다. 즉, 어느 부분이 잘못되었더라도 다른 부분도 활용하여 판단을 하므로 성능이 좋다.

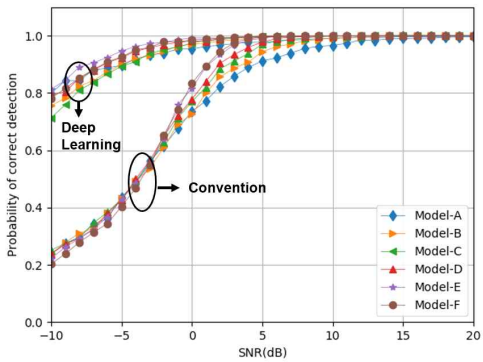

<그림 6> 기존 방식과 딥러닝 방식의 프레임 포맷 검출 확률

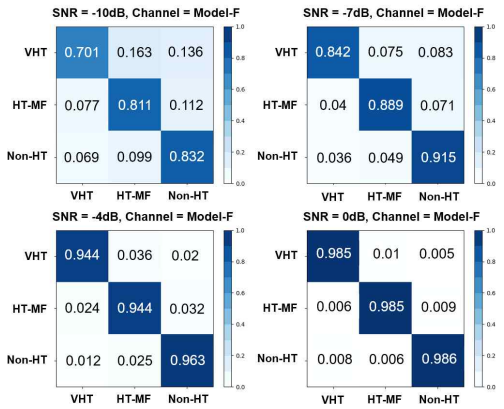

<그림 7> Model-F에서 SNR(−10, −7, −4, 0)일 때의 혼동행렬

Ⅳ. 결론

본 논문에서는 802.11 WLAN 프레임 포맷 검출에

딥러닝을 적용해보았고, 시뮬레이션 결과 기존방식보다 10dB가량 좋은 성능을 보였다. 이처럼 낮은 SNR과 멀티패스 채널 환경에서 딥러닝의 성능이 좋음을 확인하였다. 이처럼 딥러닝은 복잡하고 다양한 신호처리 분야에 적용하기에 매력적인 기술이다. 그러나 현재 딥러닝의 실제 통신 기기에 적용되기에는 경우 하드웨어의 제약 상 문제로 어렵다고 생각을 한다. 현재 대부분의 딥러닝은 GPU를 활용하고 있으며, GPU의 경우 병렬연산에 좋은 성능을 보이지만 비용적 측면에서 비효율적이다. 최근 GPU의 대안으로 FPGA를 활용하여 비용을 줄이고, 병렬연산을 하는 연구들이 이루어지고 있다. 그렇기에 실제 필드에 적용하기 위해서는 하드웨어의 성능 발전이 더 필요하다고 생각을 하며, 현재의 딥러닝은 딥러닝을 적용해봄으로써 발전 가능성을 확인하는 단계라고 생각을 한다. 향후 연구로는 최근에 IEEE 802.11ax가 상용화되기 시작하였고, 이에 따라 IEEE 802.11ax 프레임 포맷을 포함하여 검출하는 것을 해볼 것이며, 패킷 디코딩 과정에도 딥러닝을 적용해볼 것이다.

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] IEEE 802.11 WLANs, Working Group for WLAN Standards, 2015.

[2] E. Lopez-Aguilera, E. Garcia-Villegas, and J. Casademont, “Evaluation of IEEE 802.11 Coexistence in WLAN Deployments,” in Wireless Networks. Springer, 2017, pp. 1-18.

[3] E. Perahia and R.Stacey, Next Generation Wireless LANs: 802.11n and 802.11ac, Cambridge Univ. Press, 2013.

[4] 김창식·김남규·곽기영, “머신러닝 및 딥러닝 연구 동향 분석: 토픽모델링을 중심으로,” 디지털산업정보학회 논문지, 제15권, 2호, 2019, pp.19-28.

[5] 임상헌·이명숙, “딥 러닝 기반의 악성흑색종 분류를 위한 컴퓨터 보조진단 알고리즘,” 디지털산업정보학회 논문지, 제14권, 4호, 2018, pp.69-77.

[6] C. Zhang, P. Patras, and H. Haddadi, “Deep Learning in Mobile and Wireless Networking: A Survey,” IEEE Commun. Surveys & Tutorials, Mar. 2019.

[7] T. O’Shea and J. Hoydis, “An introduction to deep learning for the physical layer,” IEEE Trans. Cogn. Commun. Netw., vol. 3, no. 4, Dec. 2017, pp.563–575.

[8] H. Ye, G. Y. Li, and B.-H. F. Juang, “Power of deep learning for channel estimation and signal detection in OFDM systems,” IEEE Wireless Commun. Lett., vol. 7, no. 1, Feb. 2018, pp.114–117.

[9] N.K. Chanvali, “Maximum likelihood detection of a frame format in HT and VHT wireless LANs,” Int. Conf. on Elec. Comput. and Comm Tech(IEEE CONECCT), 2013.

[10] P. Triantaris, E. Tsimbalo, W. H. Chin, and D. Gündüz, “Automatic modulation classification in the presence of interference,” in Proc. Eur. Conf. Netw. Commun., Jun. 2019, pp.549–553.

[11] G. Zhang and H. Li, “Effectiveness of scaled exponentially-regularized linear units (SERLUs),” Jul. 2018, arXiv:1807.10117.

[12] KINGMA, D., AND BA, J. “Adam: A method for stochastic optimization,” arXiv preprint arXiv:1412.6980 (2014).
[13] TGn Channel Models, IEEE Std. 802.11 - 03/940r4, May 2004.
[14] TGac Channel Model Addendum Supporting Material, IEEE Std. 802.11-09/0569r0, May 2009.

■ 저자소개 ■

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

안 흥 섭
Ahn, Heung Seop

2016년 3월~현재 한양대학교 전자컴퓨터통신공학과 박사과정
2016년 2월 한양대학교 전자컴퓨터통신공학과 (공학석사)
2013년 2월 한양대학교 융합전자공학부 (공학학사)

관심분야 : vehicular comm, 5G, LTE, Cell planning, SDR etc.
E-mail : ahs90@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

논문접수일 : 2020년 5월 7일
수정일 1차 : 2020년 6월 3일
수정일 2차 : 2020년 6월 8일
게재확정일 : 2020년 6월 8일