

433 MHz 대역 송신기의 인증을 위한 RF 지문 기법

김영민¹ · 이웅섭² · 김성환^{3*}

RF Fingerprinting Scheme for Authenticating 433MHz Band Transmitters

Young Min Kim¹ · Woongsup Lee² · Seong Hwan Kim^{3*}

¹Chief, Computer Team, Kangrim Heavy industry, Changwon, 51744 Korea

²Associate Professor, Department of Information Engineering, Gyeongsang National University, Tongyeong, 53064 Korea

³Associate Professor, Major of Data Science, Korea National University of Transportation, Uiwang, 16106 Korea

요 약

사물인터넷에 사용되는 소형 통신 기기들은 적은 메모리 용량과 느린 연산 속도 때문에 고급 암호기법을 적용하지 못하기 때문에 각종 해킹에 취약하다. 본 논문은 433MHz 대역에서 동작하는 소형 송신기들의 인증 신뢰도를 높이기 위해 RF 지문을 도입하고 분류 알고리즘으로 CNN (convolutional neural network) 을 사용한다. 각 송신기가 전송하는 프리엠블 신호를 소프트웨어정의라디오를 사용하여 추출하고 수집하여 학습 데이터 집합으로 만들고, 이를 신경망을 학습시키는 데에 사용한다. 네 가지의 시나리오에서 20개의 송신기의 식별을 테스트한 결과 높은 식별 정확도를 얻을 수 있었다. 특히 학습 데이터 수집 시의 위치와 다른 위치에서 테스트를 수행한 시나리오에서, 그리고 송신기가 걷는 속도로 이동하는 시나리오에서 각각 95.8%, 92.6%의 정확도를 산출함을 알 수 있었다.

ABSTRACT

Small communication devices used in the Internet of Things are vulnerable to various hacking because they do not apply advanced encryption techniques due to their low memory capacity or slow computation speed. In order to increase the authentication reliability of small-sized transmitters operating in 433MHz band, we introduce an RF fingerprint and adopt a convolutional neural network (CNN) as a classification algorithm. The preamble signal transmitted by each transmitter are extracted and collected using software-defined-radio to constitute a training data set, which is used for training the CNN. We tested identification of 20 transmitters in four different scenarios and obtained high identification accuracy. In particular, the accuracy of 95.8% and 92.6% was obtained, respectively in the scenario where the test was performed at a location different from the transmitter's location at the time of collecting training data, and in the scenario where the transmitter moves at walking speed.

키워드 : 인증, 심층학습, RF 지문, 433MHz 대역

Keywords : Authentication, Deep learning, RF fingerprinting, 433MHz band

Received 26 November 2022, Revised 5 December 2022, Accepted 11 December 2022

* **Corresponding Author** Seong Hwan Kim (E-mail: seonghwan.kim@ut.ac.kr, Tel: +82-31-460-0582)

Associate Professor, Major of Data Science, Korea National University of Transportation, Uiwang, 16106 Korea

Open Access <http://doi.org/10.6109/jkiice.2023.27.1.69>

print ISSN: 2234-4772 online ISSN: 2288-4165

© This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.
Copyright © The Korea Institute of Information and Communication Engineering.

I. 서 론

최근 사물인터넷 기기들이 자동차, 의료, 건축, 금융 등 다양한 산업에서 활용되고 있다. 특히, 키팜, NFC 기기, 스마트 홈 기기, 스마트 헬스케어 기기와 같이 송신 기능을 갖춘 소형 기기들이 널리 사용되고 있다. 이는 RF 송수신 모듈, 센서, 마이크로컨트롤러 등의 전자 부품들이 소형화되고 제조 비용이 감소한 것에 기인한다. 이러한 소형 기기들은 일반적으로 메모리 용량 및 연산 능력이 낮아 정보보호를 위한 알고리즘이 단순하다. 따라서 다른 통신기기에 비해 보안 침해 사고가 발생할 가능성이 높다 [1]. 그러므로 소형 기기를 위해 메모리나 연산 능력이 적게 요구되면서도 신뢰도가 높은 보안 기법의 개발이 필요하다 [2].

그 방법 중 하나로 RF (radio frequency) 지문 기법이 있다. RF 지문은 통신 회로의 생산과정에서 발생한 랜덤한 왜곡으로부터 만들어지는 아날로그 신호의 고유한 특성을 지문으로 사용하여 무선 송신기들을 식별하는 기술이다 [3]. 본 논문에서는 송신기의 식별을 인증과 동일한 개념으로 간주한다. 무선 통신 기기의 인증에 RF 지문을 도입한 연구는 지난 15년간 활발히 진행되어 왔다 [3-9]. RF 지문 기반의 무선통신 기기 인증 연구 중에서 가장 이른 시기에 발표된 연구에서는 무선랜 송수신기들을 식별하였다 [3]. 기기 식별을 위해 RF 지문 신호를 획득-관심구간검출-지문추출-분류의 4가지 단계를 거쳤으며, 특히 마지막 단계인 분류에서는 확률신경망을 사용하였다. 논문 [4]에서는 RF 지문 기법을 이용하여 RFID 태그를 식별하였고, 논문 [5]에서는 블루투스 송신기를 식별하였다.

최근 분류 단계에 심층신경망 (deep neural network, DNN) 을 사용한 연구들이 다수 발표되었다. 논문 [6][7]에서는 IEEE 802.15.4의 표준을 따르는 Zigbee 기기들의 식별에 RF 지문을 사용하였고 합성곱 기반 신경망 (convolutional neural network, CNN)을 이용해 기기들을 분류하였다. 논문 [8]에서는 모바일폰의 식별에 RF 지문과 CNN을 사용하였다. 논문 [9]에서는 상용 WiFi 기기와 ADS-B (Automatic Dependent Surveillance-Broadcast) 기기 약 10,000개로부터 신호를 수집하고 CNN으로 분류를 하였다. 특히 채널, 기기의 수, 신호 세기, 학습 데이터의 양 등이 성능에 미치는 영향에 대해 연구하였다. 논문 [10]에서는 NFC (near field communications)

태그의 인증을 위해 태그의 RF 지문을 수집하였고, CNN, RNN (recurrent neural network), FNN (fully connected layer-based neural network) 을 분류 알고리즘으로 사용하였다. 그러나 저자들의 문헌 조사 결과 433MHz 대역을 사용하는 통신기기들을 RF 지문을 활용하여 식별한 연구는 없었다.

433MHz 대역은 UHF (ultra high frequency) 주파수 범위의 ISM (industry-science-medical) 대역으로서 최대 20km까지 통신이 가능하며, 차량용 키팜, 홈 시큐리티, 드론 통신 등 실생활에 다양하게 활용되고 있다. 일상에 널리 퍼져있는 만큼, 다양한 보안 침해 사례가 발생할 수 있으므로, 이 대역을 사용하는 소형 통신기기의 인증에 RF 지문을 도입한다면 보안성이 상당히 높아질 것으로 기대된다.

본 논문에서는 433MHz 대역을 사용하는 송신 모듈의 식별을 위해 기기의 RF 지문 신호를 수집하고, 이를 심층신경망 학습에 사용한다. 이를 위해 송신기 모듈을 아두이노 보드에 연결하여 송신기를 구성하고, 소프트웨어정의라디오 장비로 신호를 수집하는 테스트베드를 구성하였다. 송신된 신호를 관찰한 결과 모든 송신 모듈은 패킷의 초반부에 동일한 프리엠블 신호를 사용함을 알게 되었고, 각 송신기의 프리엠블 신호를 수집하여 특성 데이터 집합을 만들었다. 즉 프리엠블 신호에 존재하는 각 송신기의 고유한 왜곡 특성을 RF 지문으로 사용한다. 대부분의 기존 연구에서 학습용 신호 수집 시의 송신기 위치와 테스트 시의 송신기 위치를 동일하게 하였으나, 본 연구에서는 테스트 시 송신기의 위치가 학습 데이터 수집 시의 위치와 다른 상황을 고려하였으며, 더 나아가 송신기의 식별 테스트를 진행하는 동안 지속적으로 이동하는 상황까지 고려하였다. 20개의 송신기를 분류하는 실험을 진행한 결과 다양한 상황에서 높은 식별 정확도를 얻었다. 따라서 본 연구는 433MHz 대역의 송신기 인증에 RF 지문을 활용하는 기법이 높은 실용성을 가짐을 보인다. 본 논문은 학술대회에 발표된 논문 [11]을 기반으로 다양한 실험 시나리오를 추가하여 확장하였으며, 주저자의 석사학위논문 [12] 의 일부 내용을 기반으로 작성하였다.

II. 송신기의 RF 지문

본 연구의 실험에 사용하는 송신 모듈의 모델명은 MX-FS-03V이며 중심주파수로 433MHz를, 변조 방식으로 진폭변조방식을 사용하고, 최대 전송속도는 4kbps, 최대전송거리는 200m 이다. 송신기는 아두이노에 연결되어 제어되며 소프트웨어정의라디오 (software defined radio SDR)가 신호를 수신하여 양자화된 기저대역 신호를 출력하고 컴퓨터가 이 신호를 받아 프레임의 시작 시점 검출과 프레임블 추출의 전처리 과정을 수행한다. 전처리된 신호는 보조기억장치에 파일 형태로 저장된다. SDR은 Ettus사의 USRP X310을 사용하였으며 RF 도터보드는 UBX-160을 사용하며, 20M sample/sec (sps) 로 샘플링을 수행한다. 송신 모듈에 호환되는 수신 모듈은 MX-05V이며 역시 아두이노에 연결하여 수신 데이터를 관찰할 수 있다. 그러나 본 실험에서 수신기의 역할은 없다.

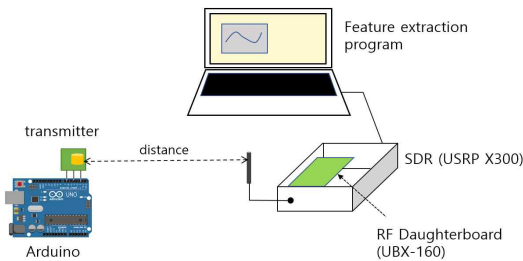


Fig. 1 Description of testbed

2.1. 송신 신호

실험에 사용되는 송신기의 프로토콜 문서를 찾을 수 없어 역공학으로 프로토콜을 파악하였다. 그림 2는 송신기가 전송하는 한 프레임의 시간에 따른 진폭변화를 보여준다. 한 프레임의 신호는 전반부의 프리엠블과 후반부의 데이터 부분으로 나뉜다. 프리엠블은 18개의 사각파 펄스로 이루어져 있으며 90 μ sec의 길이로 측정되었고, 이 규격은 모든 송신기에서 동일함을 확인하였다. 따라서 프리엠블 신호의 고유한 왜곡을 RF 지문으로 사




Fig. 2 Magnitude of one frame for varying time

용할 수 있다.

2.2. 특성 신호 추출

SDR는 수신 신호를 기저대역으로 천이시킨 후 표본화율 20Msps로 샘플링시켜 디지털 형태의 I/Q 심볼을 출력한다. 심볼들은 컴퓨터로 보내지고, GNURADIO 라이브러리를 이용한 프로그램을 통해 특성 신호가 추출된다. 추출 과정은 I/Q 심볼의 크기 (magnitude) 획득, 상관기를 이용한 프레임 시작점 검출, 프리엠블 부분 추출, 파일 저장의 단계를 거친다. 90 μ sec 길이의 프리엠블을 20Msps로 샘플링하므로 한 프리엠블을 표현하는 샘플의 수는 1800개이다. 그림 3(a)는 송신기 A가 SDR을 안테나로부터 10cm 거리에 있을 때 수신한 프리엠블의 사각파 펄스 신호를 관찰한 것이며, 그림 3(b)는 동일 거리에서 측정된 송신기 B의 신호이다. 사각파 펄스를 관찰해보면 파형의 리플이 존재하는 것을 볼 수 있으며, 하나의 송신기에서 동일한 리플 특성이 반복되는 것을 볼 수 있다. 반면 송신기 별로 리플 특성이 다른 것을 관찰할 수 있다. 본 실험에서는 20개의 송신기를 식별하며, 그들 중에 어떤 두 송신기는 육안으로는 구분하기 힘든 유사한 리플 특성을 갖는다. 따라서 심층신경망과 같은 분류 알고리즘을 도입하여 분류할 필요가 있으며 다음 절에서 이를 상세히 설명한다.

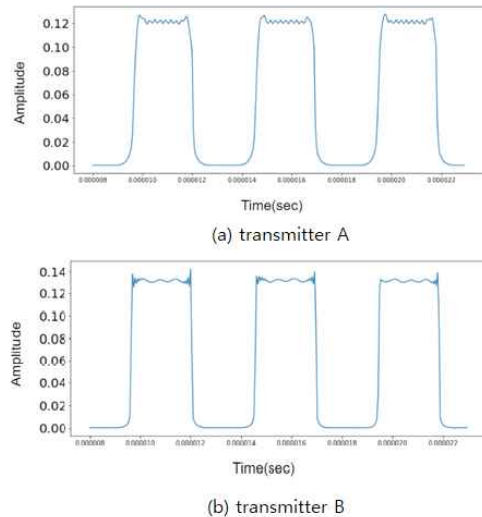


Fig. 3 Comparison between pulses of two transmitters when the transmitters are located 10 cm away from the antenna of SDR.

III. 신경망

본 연구에서 딥러닝에 사용한 신경망 모델은 영상 분류에 높은 정확도를 보이는 CNN을 사용하였으며 [13], 신경망의 구조를 나타내는 파라미터 값은 표 1에 나타나 있다. 한 프레임의 샘플 수가 1800개 이므로 입력층은 1800개의 뉴런으로 구성된다. 신경망에는 5개의 은닉층이 있고, 그 중 3개는 Convolution 1D와 Max-pooling을 사용하고 나머지 2개는 Fully connected으로 구성하였다. 은닉층의 활성화 함수는 ReLU함수를 사용하였고 마지막 층에는 소프트맥스 함수를 사용하였다. 신경망의 과적합 문제를 해결하기 위해 드롭아웃 기법을 도입하였고 드롭아웃의 비율은 0.7로 설정하였다. 최적화 알고리즘으로는 아담 최적화를 사용했으며, 미니 배치 사용으로 학습시간을 감소시켰다. 그리고 학습의 효율을 높이기 위해 배치 정규화를 활용한다.

Table. 1 Parameter describing the neural network used

layer	Size	Activation function
Input layer	1800 × 1	-
Convolution 1D	225 × 8	ReLU
Max Pooling	-	-
Convolution 1D	57 × 16	ReLU
Max Pooling	-	-
Convolution 1D	15 × 32	ReLU
Max Pooling	-	-
Fully connected	500	ReLU
Fully connected	100	Softmax

IV. 실험 환경

본 연구에서는 네 가지의 다른 시나리오에서 20개 송신기의 프리엠블 신호를 수집하였다. 본 실험에서 SDR의 위치는 고정하였으며, 송신기의 위치는 네 가지 실험에서 다르게 설정하였다. 아래에 실험 1~4에서 고려한 송신기의 위치를 설명한다.

4.1. 실험 1: 송신기를 한 지점에 고정

실험 1에서는 송신기의 위치를 한 지점에 고정한 상

황에서 RF 지문을 수집하고 테스트 한다. 이 시나리오는 가장 기본적인 것으로 식별 정확도가 가장 높을 것으로 예상되어 다른 시나리오 성능을 비교 분석하는 데 사용된다. 정확도를 높이기 위해 SDR과 송신기 사이의 거리를 근거리인 10cm로 고정하여 RF 지문을 수집하였다. 수집한 데이터 중 90%는 학습 데이터로 나머지 데이터는 테스트 데이터로 사용하였다.

4.2. 실험 2: 송신기를 세 지점에 번갈아 가며 위치

두 번째 실험은 SDR로부터 1m, 2m, 3m 떨어진 지점을 설정하고 송신기를 세 지점에 번갈아 위치시켜가면서 RF 지문을 수집하였다. 이렇게 수집된 데이터 중 90%를 학습 데이터로 나머지는 테스트 데이터로 사용하였다. 실험 2는 송신기가 거리를 달리하는 다양한 지점에서 식별이 가능한지 알아보기 위한 것이다. 그림 4는 송신기가 SDR로부터 1m, 2m, 3m의 거리에 위치하였을 때, 신호의 진폭 변화를 보여준다. 거리가 멀어질수록 신호들의 진폭이 낮아지며 진폭 중 리플의 비중이 높아진 것을 관찰할 수 있다.

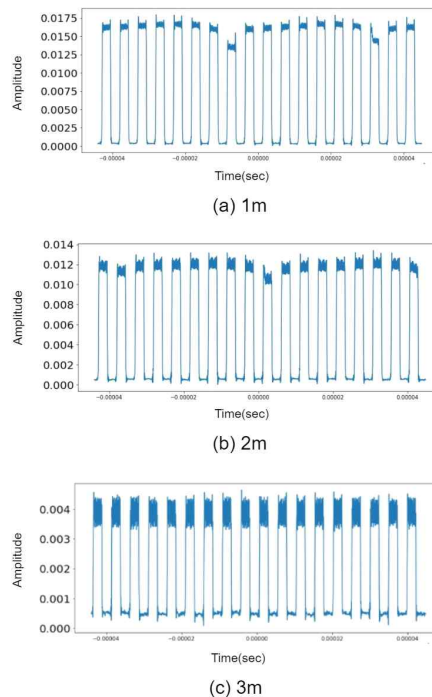


Fig. 4 Comparison of signal strength of a transmitter for different distance from the SDR.

4.3. 실험 3: 송신기를 랜덤한 위치에서 테스트

세 번째 실험은 실험 1과 2에서 측정된 데이터를 학습 데이터 집합으로 하여 신경망을 학습하고, 테스트 할 때는 SDR로부터 1~3m 범위에 떨어진 지점들을 무작위로 선택하여 송신기를 위치시키고 측정된 신호를 테스트 집합으로 사용하였다. 이는 학습용 데이터를 수집할 때는 몇 개의 특정한 지점에서만 RF지문을 수집할 수밖에 없는 반면, 실제 식별 시 송신기가 위치할 수 있는 지점은 무수히 많은 현실적인 상황을 반영하기 위함이다.

4.4. 실험 4: 송신기가 이동하는 상황에서 테스트

마지막 네 번째 실험은 세 번째 실험에서 사용한 것과 동일한 학습 데이터로 학습한 신경망을 테스트에 사용한다. 그러나 테스트 신호 수집 시, 송신기는 SDR로부터 1~3m 거리에 있는 직선 위를 시속 2.16km/h의 속력으로 이동한다. 이는 송신기가 사람이 걷는 속도로 이동할 때에도 정확히 식별되는지 확인하기 위함이다. 송신기의 이동은 채널의 시간에 따른 변화를 야기하나 속력이 낮아 변화의 정도가 심한 환경은 아니다. 그림 5는 본 연구에서 일정한 이동속도를 구현하기 위해 사용한 라인트레이서이다.




Fig. 5 Line Tracer RC Car

V. 실험 결과

수집한 RF지문 데이터를 통해 학습을 거친 신경망이 각 사니라이오 별로 어떠한 식별 정확도를 산출하는지 알아본다.

5.1. 실험 1

송신기별로 각 1만개의 특성 신호를 수집하여 총 20

만 개의 신호 얻었으며 이 중 18만 개는 학습용 집합으로 하고 나머지 2만 개는 테스트 집합으로 하여 신경망을 학습하였다. 20회 반복학습 후 테스트 집합에 대해 송신기들을 성공적으로 구별하는 확률인 식별 정확도가 약 99.9%가 나왔다. 이로써 딥러닝 기반 RF 지문 방식이 한 지점에 고정시킨 송신기들을 매우 정확하게 식별할 수 있음을 알 수 있다.

5.2. 실험 2

SDR과 송신기의 거리 1m, 2m, 3m로 하고, 거리별로 송신기 당 1만 개의 신호 수집을 통해 총 60만 개의 프리엠블 신호를 확보하였고, 그중 54만 개는 학습용 데이터로 사용하였으며 나머지 6만 개는 테스트에 사용하였다. 20회의 반복학습 후 기기들의 식별 정확도는 약 99.8% 이었다. 실험 2로부터 송신기가 SDR로부터 다양한 거리에서 있더라도, 높은 식별 정확도를 얻는 것을 알 수 있다.

5.3. 실험 3

실험 3은 실험 1, 2에서 수집한 RF지문 데이터를 합쳐서 학습 데이터로 사용한다. 이 실험에서는, 실험 1,2에서 데이터 수집 시 송신기가 위치한 지점과 다른 지점에 송신기를 위치시키고 테스트 데이터를 수집하였다. 역시 20회 반복 학습 후에 식별 정확도는 약 95.8%로서 실험 1,2에 비해 다소 감소하였으나, 여전히 높은 정확도를 보여준다. 따라서 433MHz 송신기에 적용한 RF지문 기법이 실제와 유사한 환경에서도 정확히 동작함을 알 수 있다.

5.4. 실험 4

실험 4에서는 학습 데이터를 실험 2와 같이 하지만 테스트 데이터는 송신기를 라인트레이서 부착하여 이동하는 상황에서 RF 지문을 수집하였다. 20회 반복 학습 후 식별 정확도는 약 92.6%가 나왔다. 네 가지의 실험 중 가장 낮은 정확도이지만, 여전히 높은 정확도를 보여준다. 추후 더욱 높은 정확도를 얻기 위하여, 주파수 영역의 신호 추출 등 다양한 기법을 도입할 필요가 있다.

Table. 2 Experiment results

Experiment No.	Position of transmitters		Accuracy [%]
	Collecting training data	Collecting test data	
1	fixed at 10cm from SDR	fixed at 10cm from SDR	99.85
2	fixed at 1m, 2m, and 3m from SDR	fixed at 1m, 2m, and 3m from SDR	99.81
3	fixed at 10cm, 1m, 2m, and 3m	fixed at random positions between 1 and 3m from SDR	95.77
4	fixed at 10cm, 1m, 2m, and 3m	moving between 1 to 3m from SDR at 0.6 m/s speed	92.56

VI. 결 론

본 논문은 433MHz 대역에서 동작하면서 메모리 용량이 적거나 연산 속도가 느린 소형 송신 기기들의 인증 신뢰도를 높이기 위해 RF 지문 기법을 도입하였으며, 분류 알고리즘으로 CNN을 사용하였다. 제안하는 기법은 수집된 프리여블 신호를 학습 집합으로 하여 신경망을 학습시킨 후 테스트 하고자 하는 송신기의 프리여블 신호를 신경망에 입력시켜 송신기를 식별하였다. 네 가지의 서로 다른 시나리오에서 실험한 결과 높은 식별 정확도를 얻을 수 있었으며, 특히 송신기가 학습 신호 측정 위치와 무관한 위치에 있는 경우와, 송신기가 걷는 속도로 이동하는 경우에도 각각 95.8%, 92.6% 의 높은 정확도를 산출함을 알 수 있었다.

ACKNOWLEDGEMENT

This was supported by Korea National University of Transportation in 2021.

REFERENCES

- [1] H. Han and D. Park, "Cybersecurity of The Defense Information System network connected IoT Sensors," *Journal of the Korea Institute of Information and Communication Engineering*, vol. 24, no. 6, pp. 802-808, Jun. 2020. DOI: 10.6109/jkiice.2020.24.6.802.
- [2] F. D. Garcia, D. Oswald, T. Kasper, and P. Pavlides, "Lock it and still lose it – on the (in)security of automotive remote keyless entry systems," in *Proceeding of 25th USENIX security symposium*, Austin: TX, USA, pp. 929-944, 2016.
- [3] O. Ureten and N. Serinken. "Wireless security through RF fingerprinting," *Canadian Journal of Electrical and Computer Engineering*, vol. 32, no. 1, pp. 27-33, 2007. DOI: 10.1109/CJECE.2007.364330.
- [4] B. Danev, T. S. Heydt-Benjamin, and S. Capkun, "Physical-layer identification of RFID devices," in *Proceeding of USENIX security symposium*, Montreal: QC, Canada, Aug. 2009.
- [5] A. M. Ali, E. Uzundurukan, and A. Kara, "Assessment of Features and Classifiers for Bluetooth RF Fingerprinting," *IEEE Access*, vol. 7, pp. 50524 - 50535, Apr. 2019. DOI: 10.1109/ACCESS.2019.2911452.
- [6] K. Merchant, S. Revay, G. Stantchev, and B. Nousain "Deep Learning for RF Device Fingerprinting in Cognitive Communication Networks," *IEEE Journal of Selected Topics in Signal Processing*, vol. 12, no. 1, pp. 160-167, Feb. 2018. DOI: 10.1109/JSTSP.2018.2796446.
- [7] J. Yu, A. Hu, G. Li, and L. Peng, "A Robust RF Fingerprinting Approach Using Multisampling Convolutional Neural Network," *IEEE Internet of Things Journal*, vol. 6, no. 4, pp. 6486 - 6799, Aug. 2019. DOI: 10.1109/JIOT.2019.2911347.
- [8] S. Wang, L. Peng, H. Fu, A. Hu, and X. Zhou, "A Convolutional Neural Network-Based RF Fingerprinting Identification Scheme for Mobile Phones," in *Proceeding of the IEEE International Conference on Computer Communications*, Toronto: ON, Canada, Jul. 2020. DOI: 10.1109/INFOCOMWKSHP50562.2020.9163058.
- [9] T. Jian, B. C. Rendon, E. Ojuba, N. Wang, K. Sankhe, A. Gritsenko, J. Dy, K. Chowdhury, and S. Ioannidis, "Deep Learning for RF Fingerprinting: A Massive Experimental Study," *IEEE Internet of Things Magazine*, vol. 3, no. 1, pp. 50-57, Mar. 2020. DOI: 10.1109/IOTM.0001.1900065.
- [10] W. Lee, S. Y. Baek, and S. H. Kim, "Deep-Learning-Aided RF Fingerprinting for NFC Security," *IEEE Communications Magazine*, vol. 59, no. 5, pp. 96-101, May 2021. DOI: 10.1109/MCOM.001.2000912.
- [11] Y. M. Kim, Y. M. Bak, W. Lee, and S. H. Kim, "Authentication Mechanism for 433MHz band Transceiver Module using Deep learning based RF Fingerprinting," in *Proceedings of the 2019 Fall Conference of the Korea Information and Communications*, Busan, Korea, pp. 397-399, 2019.

- [12] Y. M. Kim, "Physical-layer schemes to enhance the reliability of authentication for IoT devices," M. S. thesis, Gyeongsang National University, Korea, 2020.
- [13] I. J. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*, MIT Press, MA: USA, 2016.



김영민(Young Min Kim)

2018년 2월 경상대학교 정보통신공학과 학사
2020년 2월 경상대학교 정보통신공학과 석사
2020년 3월 ~ 2021년 9월 라도포스 연구원
2022년 7월 ~ 현재 강림중공업 전산팀 계장
※관심분야: 사물인터넷, 인공지능, ERP 개발



이용섭(Woongsup Lee)

2006년 한국과학기술원 전기및전자공학과 학사
2011년 한국과학기술원 전기및전자공학과 박사
2012년 2월~2013년 2월 한국과학기술원 박사후 연구원
2013년 2월~2014년 2월 독일 FAU 박사후 연구원
2014년 3월~2018년 2월 경상대학교 정보통신공학과 조교수
2018년 3월~현재 경상국립대학교 정보통신공학과 부교수
※관심분야: 차세대 이동통신 시스템, 인지 라디오 시스템, 스마트 그리드, 빅 데이터 분석, 딥러닝



김성환(Seong Hwan Kim)

2006년 8월 고려대학교 전기전자전파공학부 학사
2008년 8월 KAIST 전자전산학과 석사
2013년 2월 KAIST 전기전자공학과 박사
2013년 8월~2016년 2월 맥길대학교 박사후 연구원
2016년 3월~2020년 2월 경상대학교 정보통신공학과 조교수
2020년 3월~한국교통대학교 데이터사이언스전공 부교수
※관심분야: 차세대 이동통신 시스템, 사물인터넷 보안, 인공지능