

Rayleigh 페이딩에서 CNN을 이용한 주파수 도약 신호 탐지 방법 연구

이 경 규*, 오 성 준^o

Study on CNN-Based Frequency-Hopping Signals Detection Scheme in Rayleigh Fading

Kyung-Gyu Lee*, Seong-Jun Oh^o

요 약

군 통신에 주로 사용되는 주파수 도약 신호는 탐지 확률이 낮다. 스펙트로그램과 같은 기존의 탐지기들은 암맹 환경에서 주파수 도약 신호를 탐지하는 데 어려움이 있다. 주파수 도약 신호의 길이가 짧아서 에너지 누수가 생기고, SNR이 낮아지기 때문이다. 이 문제를 완화하기 위해 우리는 암맹 환경에서 CNN 기반의 주파수 도약 신호 탐지 방법을 제안한다. CNN은 주파수 도약 신호에서 공간적 특징 맵을 학습하여 신호를 탐지한다. CNN 기반 탐지 방법이 현실적인 환경에도 적용할 수 있는지 보기 위해 Rayleigh 페이딩 환경에서 실험했다. 시뮬레이션 결과, CNN 기반 탐지 방법은 페이딩을 학습하지 않아도 페이딩이 있는 신호를 탐지할 수 있었다. 그리고 기존의 탐지 방법들보다 성능이 좋은 것을 확인했다.

Key Words : Frequency-hopping, Detection, Deep learning, CNN, Rayleigh fading

ABSTRACT

The frequency-hopping (FH) system widely used in military communications has low probability of detection. The conventional detection scheme such as the spectrogram-based detection scheme has difficulty on detecting FH signals under the blind condition. Because of the short length of FH signals, energy leaks and results in a low signal-to-noise ratio issue. To alleviate the issue, we propose the CNN-based FH signals detection scheme. The CNN extracts spatial feature maps from FH signals and utilizes them for detection. To observe if the CNN-based detection scheme can be applied to realistic environment, experiments with Rayleigh fading is conducted. In simulation results, the CNN-based detection scheme detects FH signals under Rayleigh fading without learning the fading. Furthermore, the CNN-based detection scheme outperforms the conventional detection schemes.

I. 서 론

확산대역통신 (Spread Spectrum Communication) 은 군사용으로 개발된 보안 통신 시스템으로 특정한 암호가 없으면 복조할 수 없다. 확산대역통신 중의 하

나인 주파수 도약 시스템 (Frequency-Hopping System)은 PN 수열에 따라서 주파수를 랜덤하게 바꿈으로써 신호가 전파방해에 방해되지 않고, 잘 탐지되지 않게 하는 효과가 있다. 심볼 주기 동안 주파수를 여러 번 바꾸는 것을 빠른 주파수 도약 (Fast

* 이 연구는 방위사업청 및 국방과학연구소의 재원에 의해 설립된 신호정보 특화연구센터 사업의 지원을 받아 수행되었음.

• First Author : Korea University Graduate School of Computer and Information Technology, dgmstt@korea.ac.kr, 학생회원

o Corresponding Author : Korea University Graduate School of Information Security, seongjun@korea.ac.kr, 종신회원

논문번호 : 201911-272-0-SE, Received October 28, 2019; Revised January 2, 2020; Accepted January 3, 2020

Frequency-Hopping)이라고 하고, 주파수 도약 주기 동안 여러 심볼이 포함되는 것은 느린 주파수 도약 (Slow Frequency-Hopping)이라고 한다. 빠르고 느린 주파수 도약 시스템은 도약 주기를 정확히 알지 못하면 신호를 받을 때 감쇠 현상이 일어나서 탐지하기 어렵다.

주파수 도약 신호를 탐색하는 방법은 꾸준히 연구되었다. Energy^[1], Cyclostationary^[2], 스펙트로그램 (Spectrogram)^[3], Wavelet^[4] 등의 탐색 방법들이 연구되었다. 이 중에서 Wavlet과 스펙트로그램은 short time Fourier transform (STFT)을 통해서 1차원 신호를 2차원으로 바꿔서 탐지하게 만든다. 스펙트로그램은 주파수와 시간의 해상도가 서로 trade-off 관계다. 그래서 신호에 따라 적절한 window를 사용해야 좋은 성능을 낼 수 있다. 그리고 주파수 도약 신호의 심볼이 다수의 도약으로 나뉘기 때문에 주파수 응답의 진폭이 낮고 신호의 길이가 짧아서 Signal-to-noise ratio (SNR)이 낮게 나온다. 스펙트로그램과 다르게 Wavelet은 낮은 주파수에서는 긴 window를 사용하고, 높은 주파수에서는 짧은 window를 사용해서, 해상도의 trade-off를 보완하였다. 이 접근은 주파수 성분이 낮은 주파수에서는 긴 주기를 가지고, 높은 주파수에서는 짧은 주기를 가질 때 효과적이다. 그러나 주파수 도약 신호와 같이 높은 주파수와 낮은 주파수를 가리지 않고 사용하는 경우에는 효과가 반감된다.

스펙트로그램의 단점을 보완하기 위해서 우리는 딥러닝 (Deep Learning)에 주목했다. 딥러닝은 최근 활발히 발전하는 분야로서, 결과를 입력받아 변환하고 추상화하는 과정을 여러 수준에 걸쳐 반복 작업하는 학습모델이다. 딥러닝은 음성인식, 패턴검색, 이미지 인식 분류뿐만 아니라 통신 분야에서도 활발히 적용되고 있다^{[5][8]}. 딥러닝은 이미지 인식에 특화되어있는 Convolutional neural network (CNN)과 순환 구조로 되어있는 Recurrent neural network (RNN) 모델들이 주목받고 있다. CNN은 이미지 인식을 위한 신경망 구조이다. 이미지를 따라 각 필터가 내적을 계산하여 특징 맵 (feature map)을 학습한다. CNN에서는 Alexnet, GoogleNet, VGG^[9] 등이 좋은 성과를 거두었다. RNN은 네트워크에 피드백 연결이 포함 되어 있어서 순차적인 학습이 가능하다. 주로 글자추론, 캡션 추정 등 시간적인 인풋이 있는 경우 적용이 된다. RNN과 CNN은 모두 탐지 분야에서 적용이 되고 있다^[8]. [8]에서 사용된 CNN은 1개의 3×3 합성곱 층과 20개의 필터를 가지고 있고, 3.5 GHz 대역에서 레이더를 탐지했다. 이 CNN은 레이더를 탐지하는 용도로

는 적절하지만, 암맹 조건에서 주파수 도약 신호를 탐지하는 데는 부족하다.

그래서 본 논문에서는 층수를 늘린 형태로 새로운 CNN 기반 탐지 방법을 설계한다. 새롭게 제시한 CNN 기반 탐지 방법이 현실적인 환경에서 좋은 성능을 낼 수 있을지 보기 위해 Rayleigh 페이딩 (Fading) 환경에서 실험을 설계한다. 페이딩 환경은 지형과 상황에 따라서 변할 수 있어서 하나로 정의하기 힘들다. 파라미터를 최적화시키는 학습 (training) 과정에서 다양한 페이딩을 학습시키는 것은 불가능에 가깝다. 그래서 우리는 세 가지 조건에서 CNN을 실험하여, CNN이 페이딩과 관계없이 신호를 탐지할 수 있는지 보고자 한다. 첫 번째는 학습 과정과 검증 (testing) 과정에서 모두 페이딩이 없는 실험이다. 두 번째는 학습 과정과 검증 과정에서 모두 페이딩이 있는 실험이다. 세 번째는 학습 과정에서는 페이딩이 없지만, 검증 과정에서는 페이딩이 있는 실험이다. 세 가지 조건에서 진행한 실험을 바탕으로 제시한 CNN 기반 탐지 방법이 현실적인 환경에 적용할 수 있음을 보인다. 또한, 기존의 주파수 도약 탐지 방법과 성능을 비교한다.

본 논문의 구성은 다음과 같다. II장에서는 주파수 도약 시스템의 가정과 채널 모델을 설명한다. III장에서는 제시한 CNN 기반 탐지 방법의 구조에 관해서 설명한다. IV장에서 시뮬레이션 결과와 분석을 기술했으며, 마지막으로 V장에서 결론을 내린다.

II. 시스템 모델

주파수 도약 신호의 주파수는 미리 약속된 PN 수열에 따라서 변화된다. 그러나 암맹 조건에서 수신자로서는 PN 수열을 알 수 없으므로 도약 주파수는 무작위로 바뀌는 것으로 보인다. 이산 시간 지수 n 의 i 번째 주파수 도약 신호 x 는 다음과 같이 표현할 수 있다.

$$x(n) = \sqrt{E_s} \sum_{i=-\infty}^{\infty} \cos(2\pi f_i n T_s + \phi_i) \cdot p(n - i T_h) \tag{1}$$

E_s 는 주파수 도약 신호의 에너지이고, f_i 는 i 번째 도약 주파수이다. T_s 와 T_h 는 각각 샘플링 (sampling) 주기와 주파수 도약 주기다. ϕ_i 는 페이즈 (phase)이며 0부터 2π 까지 균등분포를 가지고 있다. $p(\cdot)$ 는 직사각형 펄스로 주파수 도약 주기마다 신호가 불연속적

인 것을 보여준다.

페이딩 환경이 아니라면 x 를 그대로 스펙트로그램으로 변환하면 된다. 페이딩이 있다고 가정하면 Rayleigh 페이딩을 가정한다. Rayleigh 페이딩은 건물이나 지형에 의해 반사 또는 산란된 다중경로의 신호들을 중심극한정리를 통해 통계적으로 유도한 채널 모델이다. 송수신기간의 직선 경로가 없는 경우에 적합하다. 수신된 신호에 주파수 도약 신호가 있는 경우를 H_1 이라고 하고, 없는 경우는 H_0 라고 한다면, Rayleigh 페이딩을 거쳐서 수신된 신호 r 은 다음과 같다¹⁰⁾.

$$r(n) = \begin{cases} H_1 : \sum_{\alpha=0}^{A-1} \beta_{\alpha} x_{\alpha}(n - \tau_{\alpha}) + \nu(n) \\ H_0 : \nu(n) \end{cases} \quad (2)$$

β_{α} 는 α 번째 다중경로의 Rayleigh 분포 랜덤변수이다. β_{α} 는 서로 독립적이고 동일한 분포 (independent and identically distributed)를 가지고 있다. A 는 다중경로의 개수이며, τ_{α} 는 지연 시간이다. $\nu(\cdot)$ 는 복소 가우시안 분포를 가진 잡음으로써 0의 평균과 1의 분산을 가진다. 사용된 Rayleigh 페이딩 모델은 주파수 비선택적 페이딩이다. 신호대역폭이 상관대역폭 (coherence bandwidth)보다 작고, 송수신기가 느리게 움직이는 것을 가정한다¹⁰⁾.

제안한 CNN 기반 탐지 방법은 스펙트로그램을 인풋으로 받아들인다. 수신된 신호 r 의 스펙트로그램 S_x 은 다음과 같이 나타낼 수 있다.

$$S_x(m, k) = \left| \sum_{n=0}^{N-1} r(n) w(n-m) e^{-\frac{2\pi kn}{N}} \right|^2 \quad (3)$$

m 과 k 는 각각 시간 축 인덱스와 주파수 축 인덱스다. $w(\cdot)$ 는 STFT에 사용되는 슬라이딩 윈도우 (sliding window) 함수이고, 본 논문에서 hamming 윈도우를 사용한다. N 은 푸리에 변환 크기다. 본 논문에서는 슬라이딩 윈도우의 길이와 N 의 크기가 모두 1024로 같다고 가정한다. 스펙트로그램은 STFT로 인해 생기는 스펙트럴 누수 (spectral leakage)를 완화하기 위해 슬라이딩 윈도우를 곱치게 한다. 다음번의 슬라이딩 윈도우가 현재 윈도우의 끝에서 시작하는 것이 아니라, 중간에서 시작하게 되는 것이다. 보통 50%의 겹침을 사용하므로 본 논문에서도 50%로 사용한다.

III. CNN 기반 탐지 방법

이번 장에서는 CNN을 기반으로 하는 주파수 도약 신호 탐지 방법을 설명할 것이다. 본 논문에서 제안하는 CNN 기반 방법은 지도 학습 (supervised learning)을 따르고 있으므로 정답이 있는 데이터가 필요하다. CNN을 통한 주파수 도약 탐지 방법은 신호의 여부를 미리 알고 있는 스펙트로그램을 인풋으로 넣어서, 학습 과정 동안 CNN의 weight를 최적화시키고, 검증 과정에서 성능을 계산한다. CNN 기반 탐지 방법의 4개 층과 3개 층 구조는 그림 1에 나와 있다. 2개, 1개 층의 구조는 각각 Conv3과 Conv2를 제거한 구조와 같다. 합성곱 계층에는 3×3 합성곱을 사용한다. 3×3을 사용한 이유는 한정된 파라미터 개수 내에서 3×3 4개 층이 5×5 3개 층보다 비선형적인 구간이 많아지면서 특징 맵을 더 잘 추출하기 때문이다⁹⁾. 각 층 끝에는 Rectified linear unit function이 활성화 함수로 배치된다. 비용 함수로는 Cross-entropy가 사용되었고, 최적화 함수에는 Adam이 사용되었다. 과적합을 방지하기 위해서는 He initialization¹¹⁾, L1

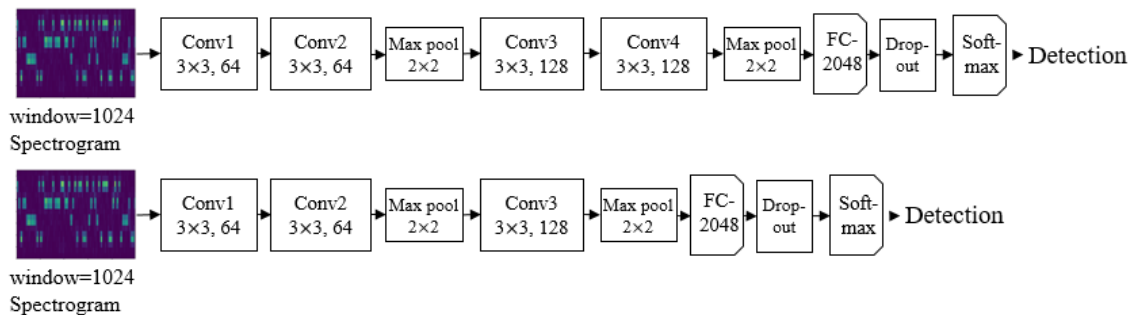


그림 1. 3개 층과 4개 층의 CNN 기반 탐지 방법 구조
Fig. 1. Structure of 3- and 4-layer CNN-based detection scheme

regularization, 50% dropout이 사용되었다. 특히 He initialization은 각 층의 평균과 표준편차를 일정하게 유지하면서 weight의 포화를 막고, 더 작은 오류를 나게 만든다. 사용하기 전에는 CNN의 층의 개수를 늘려도 오히려 성능이 감소하였지만, 사용 후에는 층수가 늘어날수록 성능이 향상되었다.

CNN을 기반으로 하는 주파수 도약 신호 탐지 방법은 그림 1에 나와 있는 구조를 통해서 최종적으로 두 개의 가설 H_1 과 H_0 의 확률을 구한다. 처음 스펙트로그램을 인풋값으로 넣으면 파라미터의 최적화가 이루어졌지 않기 때문에 H_1 과 H_0 의 확률이 0.5와 0.5로 나타난다. 이후에 학습 과정이 진행되면서 주파수 도약 신호가 있다면 H_1 의 값이 크게 나오고, 주파수 도약 신호가 없다면 H_0 의 값이 크게 나온다. 그림 1의 'Detection' 블록에서 H_1 이 크다면 주파수 도약 신호가 있다고 판정하고, H_0 가 크다면 없다고 판정을 내린다. 학습 과정이 끝나고 검증 과정에서는 성능 지표를 계산하는데, 본 논문에서는 정확도 (Accuracy)를 사용한다. 정확도는 신호가 있을 때 있다고 판정을 내리는 경우와 신호가 없을 때 없다고 판정을 내리는 경우를 합해서 모든 경우의 수로 나눈 비율이다.

CNN이 기존의 탐지 방법들과 다른 점은 신호에서 공간적인 특징 맵을 추출해서 탐지에 사용한다는 점이다. CNN은 적절하게 학습이 되면 낮은 SNR 영역에서도 특징 맵을 추출할 수 있다. 그래서 기존의 탐지 방법들보다 성능이 좋다. 그 이유는 두 가지가 있는데, 첫째는 CNN의 비선형성이고, 둘째는 검정 통계량 (test statistic)의 개수 때문이라고 생각된다. 먼저 직관적으로 비교 가능한 스펙트로그램 기반 탐지 방법과 비교해본다. 스펙트로그램 기반 탐지 방법은 스펙트로그램 값 중에서 최댓값을 구하는 선형 함수로 검정 통계량을 만든다. 이러한 선형 함수들은 대역폭이 커지거나 측정시간이 길어지면 상대적으로 잡음의 불확실성이 커져서 성능이 급격히 감소하는 성질을 가지고 있다. 반면에 CNN 기반 탐지 방법은 특징 맵 또는 활성화 함수와 같은 비선형 함수를 사용해서 잡음에 상대적으로 더 유동적으로 대처한다. 만약 탐지 구간에서 잡음의 크기가 신호보다 더 크다고 하더라도 학습을 통해 적절한 경계선을 찾는다. 그리고 CNN은 검정 통계량이 기존의 탐지 방법들보다 더 많다고 볼 수 있다. 기존의 탐지 방법들이 각 모델에 1개의 검정 통계량을 가지고 있다고 본다면, CNN은 필터 개수만큼 획득할 수 있다. 검정 통계량의 개수가 크게 차이 나기 때문에 복잡한 상황에서도 더 최적화를 잘

할 수 있다. CNN 기반 탐지 방법은 알고리즘을 통해 많은 검정 통계량을 더 유동적으로 최적화할 수 있다는 점에서 기존의 탐지 방법보다 더 낫다고 할 수 있다. 실제로 눈을 통해서 스펙트로그램의 신호 여부를 판단할 때 0 dB 아래로 내려가면 거의 구분되지 않는다. 하지만 CNN 기반 탐지 방법은 0 dB 밑에서도 충분히 잘 작동하는 것을 보면 사람의 눈보다 더 신호를 잘 포착하는 것을 알 수 있다.

IV. 성능 분석

4.1 주파수 도약 신호 생성

실험에 사용될 주파수 도약 신호의 파라미터들은 표 1에 나와 있다. Sampling frequency는 hopping band를 모두 포함할 수 있는 값으로 정했다. Hopping frequency separation은 도약 주파수 간의 간격이고, Hopping rate는 신호가 단위 시간 동안 도약하는 횟수다. Number of hops는 도약 주파수의 개수다. 그림 2로 예를 들면 Hopping frequency separation은 $f_2 - f_1$, Hopping rate는 $t_2 - t_1$ 그리고 Number of hops는 f 의 개수인 5이다. Modulation은 실험에서 디코딩하지 않기 때문에 간략화하기 위해 생략했다. 주파수 도약 신호들은 암맹 환경을 가정하고 있으므로 파라미터를 알 수 없다. 이 가정을 구현하기 위해 각 신호 표본의 파라미터는 표 1에 나와 있는 값 중에서 무작위로 정해진다. 무작위로 정해진 파라미터들은 식 (1)을 통해 계산되어 주파수 도약 신호로 생성된다. 1개의 주파수 도약 신호 데이터는 0.1초 동안 생성된 신호들을 포함한다. 생성된 신호의 스펙트로그램은 그림 2와 같은 구조를 가지고, CNN 기반 주파수 도약 신호 탐지 방법의 인풋으로 입력된다.

주파수 도약 신호는 학습 데이터와 검증 데이터로 나뉘는데, 페이딩 환경 실험을 위해 세 가지 경우에서 생성된다. Case A에서는 학습 데이터와 검증 데이터 모두 페이딩 없이 생성된다. Case B는 학습 데이터와

표 1. 주파수 도약 신호 표본의 파라미터
Table. 1. Parameters of FH signal samples

Parameter	Value
Sampling frequency (Hz)	37500
Hopping frequency separation (Hz)	500, 600, 700, 800, 1000, 2000, 3000
Hopping rate (hops/s)	100, 500, 1000, 1500, 3000, 6000
Number of hops	3, 4, 5

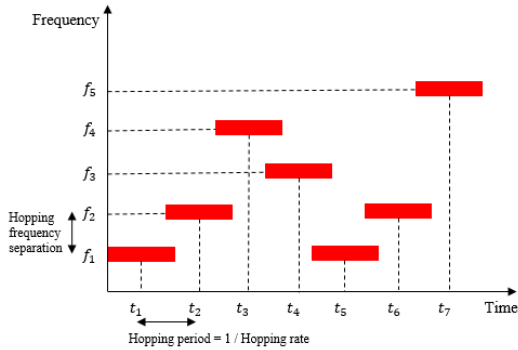


그림 2. 주파수 도약 신호의 스펙트로그램 구조
Fig. 2. Structure of frequency-hopped signal spectrogram

검증 데이터 모두 페이딩이 있게 생성된다. 마지막으로 Case C는 학습 데이터에는 페이딩이 없지만, 검증 데이터에는 페이딩이 있게 생성된다. 페이딩이 있는 경우 주파수 도약 신호는 식 (2)를 통해 계산된다. 각각의 경우마다 학습 데이터는 50,000개를 만들었고, 검증 데이터는 10,000개를 만들었다.

4.2 기존의 탐지 방법

시뮬레이션에서 CNN 기반 탐지 방법과 비교할 기존의 탐지 방법들은 Energy, Cyclostationary, 스펙트로그램 기반 탐지 방식이다. Energy 탐지 방법은 신호의 에너지를 계산해서 문턱 값과 비교하는 방법이다. Energy 탐지 방법의 검정 통계량은 다음과 같다^[1].

$$\frac{1}{N_s} \sum_{n=0}^{N_s-1} |R[n]|^2 \tag{4}$$

N_s 는 주파수 도약 신호 표본의 개수이고, $R[\cdot]$ 은 FFT로 변환된 신호 r 의 주파수 도메인 표현이다. Cyclostationary 탐지 방법은 신호의 평균이나 자기상관관계가 주기적인 것을 이용한 방법이다. Cyclostationary의 검정 통계량은 다음과 같이 나타낼 수 있다^[2].

$$\max \sum_{l=0}^{N_s-1} r(l)r^*(l-n) \tag{5}$$

스펙트로그램 탐지 방법은 식 (3)에서 가장 큰 값과 문턱 값을 비교하여 신호의 여부를 결정한다. 기존의 탐지 방법들에서 FFT가 사용되면 그 크기는 1024로 한다.

4.3 시뮬레이션 결과

시뮬레이션에서 CNN은 Tensorflow를 사용했고, 기존의 탐지 방법들은 Numpy를 사용했다. CPU는 Intel Core i7 6700을 사용했고, GPU는 GeForce GTX 970 4G를 사용했다. CNN 기반 탐지 방법의 하이퍼 파라미터는 학습속도 10^{-6} , Regulation rate 0.1을 사용한다. 시뮬레이션의 성능 지표는 정확도를 사용한다. 시뮬레이션의 학습 과정은 100개씩 500번 학습 데이터를 입력하여 1개의 epoch으로 이루어진다. 전체 epoch은 50번을 반복하였다. 검증 과정에서는 100개씩 100번 검증 데이터를 입력하고, 이 결과를 최종 결과로 사용한다.

그림 3에는 Case A에서 CNN 기반 탐지 방법의 층 개수를 바꿔가며 실험한 것이 나타나 있다. 1개 층에서 4개 층으로 갈수록 정확도가 증가하는 것을 볼 수 있다. 4개 층 CNN의 정확도가 가장 높지만, 3개 층 CNN과 차이는 크게 나지 않는다. 2개 층과 1개 층은 그 위의 층보다 낮다. 장비의 제약 때문에 4층 이상의 CNN에 대해 실험하지는 못했지만, 층 간 차이가 점점 감소하는 것으로 보아 정확도가 수렴한다고 예상된다. 적어도 3개 층의 CNN을 사용해야 의미 있는 성능을 기대할 수 있다고 보인다. 층이 증가해도 수렴되는 이유는 스펙트로그램에서 추출할 수 있는 특징의 개수가 제한되어있기 때문이라고 생각된다. 그래서 층을 더 쌓아도 중복되는 특징 맵만 늘어나고 실질적인 성능향상은 크지 않다.

그림 4는 4개 층 CNN 기반 탐지 방법에서 Case A, B, C를 비교한 것이다. 페이딩이 없는 Case A에서 정확도가 가장 크고, Case B와 C는 A보다 작다. Case B와 C의 정확도는 B가 높은 SNR에서 약간 크고, 그 이후에는 거의 같다. Case A와 Case B, C의 차이는




그림 3. Case A에서 CNN 기반 탐지 방법의 정확도
Fig. 3. Accuracy of CNN-based detection scheme in Case A

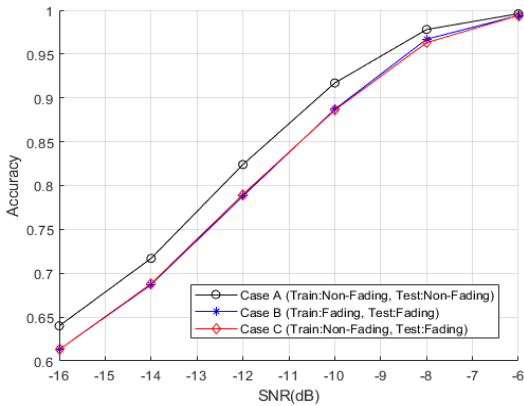


그림 4. 서로 다른 경우에서 4개 층 CNN 기반 탐지 방법의 정확도
 Fig. 4. Accuracy of CNN-based detection scheme in different cases

페이딩으로 인한 SNR 감소 차이이다. Case B와 Case C도 차이가 날 것으로 기대했지만, 차이가 거의 나지 않는 결과가 나왔다. 학습 과정에서 페이딩이 들어가지 않아도 검증 과정에서 결과가 비슷하게 나온 것은 의미 있는 결과라고 볼 수 있다. CNN이 특징 맵에서 페이딩의 여부와 관계없이 주파수 도약 신호의 특징을 잘 찾은 것으로 보인다.

그림 5는 Case C에서 4개 층 CNN 기반 탐지 방법과 기존의 탐지 방법을 비교한 것이다. 기존의 탐지 방법들은 Energy, Cyclostationary, 스펙트로그램 기반 방법들이고, 모두 페이딩이 있는 상태에서 정확도를 구했다. CNN 기반 탐지 방법의 정확도가 가장 높고, Cyclostationary, Energy 스펙트로그램 순으로 내려간다. CNN 기반 탐지 방법과 기존의 탐지 방법의




그림 5. CNN 기반 탐지 방법과 기존의 탐지 방법들의 정확도 비교
 Fig. 5. Comparison of CNN-based detection scheme and conventional detection schemes

정확도의 차이가 크게 난다. 특히 같은 스펙트로그램을 사용했음에도 불구하고, 스펙트로그램 기반 탐지 방법과 차이가 아주 크게 나는 것이 보인다.

V. 결론

본 논문에서 우리는 암맹 환경에서 CNN 기반 주파수 도약 신호 탐지 방법을 설계했다. CNN 기반 탐지 방법은 학습 과정에서 페이딩을 학습하지 않아도 학습한 것과 차이를 보이지 않았다. 그리고 페이딩 환경에서 기존의 탐지 방법보다 우수한 성능을 보였다.

References

- [1] Y. Arjoun and N. Kaabouch, "A comprehensive survey on spectrum sensing in cognitive radio networks: Recent advances, new challenges, and future research directions," *Sensors*, vol. 19, no. 1, p. 126, Jan. 2019.
- [2] H. Fan, Y. Guo, and Y. Xu, "A novel algorithm of blind detection of frequency hopping signal based on second-order cyclostationarity," in *Proc. 2008 Congr. Image and Signal Process.*, vol. 5, pp. 399-402, May 2008.
- [3] Daniel L. Stevens and Stephanie A. Schuckers, "Low probability of intercept frequency hopping signal characterization comparison using the spectrogram and the scalogram," *Global J. Reas. in Eng.*, 2016.
- [4] J. Lv and W. Qu, "Application of the wavelet rearrangement algorithm in the detection of noncooperative frequency hopping signals," in *Proc. 2012 IEEE 11th Int. Conf. Signal Process.*, vol. 1, pp. 263-266, Oct. 2012.
- [5] M. Baek, et al., "Implementation methodologies of deep learning-based signal detection for conventional MIMO transmitters," *IEEE Trans. on Broadcast.*, vol. 65, no. 3, pp. 636-642, Sep. 2019.
- [6] W. Lee, T. Ban, S. Kim, and J. Ryu, "Neighbor discovery for mobile systems based on deep learning," *J. KICS*, vol. 22, no. 3, pp. 527-533, Mar. 2018.
- [7] C. Ha and H. Song, "Signal detection scheme

based on adaptive ensemble deep learning model,” *IEEE Access*, vol. 6, pp. 21342-21349, Apr. 2018.

- [8] W. M. Lees, et al., “Deep learning classification of 3.5-GHz band spectrograms with applications to spectrum sensing,” *IEEE Trans. Cogn. Commun. Netw.*, vol. 5, no. 2, pp. 224-236, Jun. 2019.
- [9] K. Simonyan and A. Zisserman, “Very deep convolutional networks for large-scale image recognition,” in *arXiv:1409.1556*, Sep. 2014.
- [10] S. H. Kim and S. W. Kim, “Frequency-hopped multiple-access communications with multi-carrier on-off keying in rayleigh fading channels,” *IEEE Trans. Commun.*, vol. 48, no. 10, pp. 1692-1701, Oct. 2000.
- [11] K. He, X. Zhang, S. Ren, and J. Sun, “Delving deep into rectifiers: Surpassing human-level performance on imagenet classification,” in *Proc. 2015 IEEE Int. Conf. Comput. Vis. (ICCV)*, pp. 1026-1034, Dec. 2015.

오 성 준 (Seong-Jun Oh)



1991년 2월 : 한국과학기술원
전기 및 전자공학과 학사
1994년 2월 : 한국과학기술원
전기 및 전자공학과 석사
2000년 9월 : University of
Michigan, Ann Arbor,
EE:Systems PhD

2000년 9월~2007년 8월 : Ericsson Wireless
Communications, 와 Qualcomm CDMA
Technologies 근무

2007년 9월~현재 : 고려대학교 정보보호대학원 교수
<관심분야> 무선네트워크, 통신 표준화, 모델 구현
딥러닝

[ORCID:0000-0002-0235-9987]

이 경 규 (Kyung-Gyu Lee)



2015년 2월 : 고려대학교 정보
통신대학 컴퓨터·통신공학부
학사

2015년 3월~현재 : 고려대학교
일반대학원 컴퓨터·전파통신
공학과 석·박사통합과정

<관심분야> 채널 모델, 공유 연구, 물리계층보안,
신호 처리, 딥러닝

[ORCID:0000-0001-9917-9845]