

# 2차 통계량과 RNN을 이용한 OFDM 신호 검출

박영훈\*, 임창현<sup>o</sup>

## Detection of an OFDM Signal Using the Second Order Statistics and RNN

Yeonghun Park\*, Chang Heon Lim<sup>o</sup>

### 요약

기존 OFDM(orthogonal frequency division multiplexing) 신호 검출 연구에서는 CP(cyclic prefix)의 반복성을 활용하는 다양한 검정 통계량이 제안된 바가 있다. 하지만 이러한 OFDM 신호의 특성을 검정 통계량으로 변환하는 과정에서 그 특성을 충분히 반영하지 못하는 경우가 있다. 이에 본 논문에서는 OFDM 신호의 2차 통계 기반 통계량에 RNN(recurrent neural network)을 적용하여 검정 통계량을 개발하는 방식을 제안하고, 컴퓨터 실험을 통해 그 성능을 평가하고자 한다.

**Key Words** : cognitive radio, spectrum sensing, OFDM, CP, machine learning, RNN

### ABSTRACT

Some previous works on detection of an OFDM signal have presented a variety of test statistics exploiting the repetition of the cyclic prefix. However, development of the test statistics from the inherent characteristic may not fully reflect the property of an OFDM signal. Motivated by this, we present a new detection method which derives its test statistics by applying the RNN to the statistics of an OFDM signal based on the second order statistics and evaluate its performance by computer

simulation.

### I. 서론

OFDM 전송 방식은 LTE, WiFi 등 여러 가지 무선 통신 시스템이 채택하고 있다. 이는 OFDM 전송 방식을 사용하는 우선 사용자(primary user)가 많다는 것을 의미한다. 따라서 보다 많은 가용 주파수 대역을 찾아서 사용하려는 인지 무선 시스템 입장에서는 OFDM 신호를 검출하는 스펙트럼 센싱 기술이 매우 중요하다.

일반적인 신호에 대한 스펙트럼 센싱 기술<sup>1)</sup>은 크게 에너지 검파, 정합 필터, 특징 기반 검파 방식으로 구분할 수 있다. OFDM 신호에 대해서는 이 중에서 OFDM 신호 자체가 갖는 고유 특성을 활용하는 특징 기반 검파 방식에 대한 연구가 많은 비중을 차지한다. 대표적인 특징 기반 방식으로는 OFDM 심볼을 구성하는 CP와 그에 대응되는 데이터 블럭간의 상관성을 이용하는 방식과 파일럿 톤의 주기성을 이용한 방식 등이 있다<sup>2)</sup>.

CP의 반복성을 활용하는 방식 중에서 가장 일반적인 형태는 OFDM 신호의 2차 통계에 GLRT(generalized likelihood ratio test)를 적용한 방식<sup>3)</sup>이다. 이 방식은 2차 통계 특성으로부터 검정 통계량을 설계하는 과정에서 CP의 위치에 따른 관련 통계량 중에서 최대값을 검정 통계량으로 선택한 것인데, 관련 통계량의 전체 특성을 온전히 반영하지 못한다. 이에 본 논문에서는 RNN 기반 머신 러닝 알고리즘을 [3]의 CP 위치에 따른 관련 통계량에 적용하여 OFDM 신호를 검출하는 방안을 제시하고 컴퓨터 실험을 통해 그 성능을 평가하고자 한다.

### II. 수신 OFDM 신호 모델

임의의 OFDM 신호가 시간  $n$ 에서 갖는 샘플을  $s(n)$ 이라 하고 잡음 샘플을  $w(n)$ 이라 할 때, OFDM 신호 존재 여부에 따라 이차 사용자가 수신하는 신호  $r(n)$ 은 다음과 같이 표현할 수 있다.

\* 이 논문은 부경대학교 자율창의기술연구비(2019년)에 의하여 연구되었음

• First Author : (0000-0002-5324-6181)Pukyong National University, Department of Electronic Engineering, hun6024096@naver.com, 학생(학부과정), 학생회원

o Corresponding Author : (0000-0001-7022-8914)Pukyong National University, Department of Electronic Engineering, chlim@pknu.ac.kr, 정교수, 종신회원

논문번호 : 202009-225-A-LU, Received September 15, 2020; Revised September 17, 2020; Accepted September 18, 2020

$$r(n) = \begin{cases} w(n) & H_0 \\ h \cdot s(n) + w(n) & H_1 \end{cases} \quad (1)$$

위 식에서 가설  $H_0$ 와  $H_1$ 은 각각 OFDM 신호가 존재하지 않는 경우와 존재하는 경우를 가리킨다. 그리고  $h$ 는 페이딩 채널 이득을 나타내는데 센싱 구간 동안에 일정한 값을 갖는다고 가정하고,  $w(n)$ 은 AWGN(additive white gaussian noise)을 나타낸다고 한다. OFDM 신호  $s(n)$ 은  $N_d$ 개의 부반송파를 사용하고, OFDM 심볼 하나의 데이터 블럭 길이를  $N_d$  샘플, CP의 길이를  $N_c$  샘플이라고 가정한다. 그리고 센싱 구간 내에는  $K$ 개의 OFDM 심볼이 포함되며 센싱 데이터의 길이  $N$ 을  $K(N_c + N_d) + N_d$  라고 설정한다.

### III. OFDM 신호의 2차 통계 특성

참고 문헌 [4]에서 사용하는 2차 통계 데이터는  $\{R_i \mid i=0, \dots, N_c + N_d - 1\}$ 이며, 이에 대한 정의는 다음과 같다.

$$R_i = \frac{1}{K} \sum_{k=0}^{K-1} r^*(i + k(N_c + N_d))r(i + k(N_c + N_d) + N_d) \quad (1)$$

가설  $H_0$ 가 유효한 상황에서  $r(n)$ 은 잡음 성분만 갖고 있으므로  $R_i$ 는 동일한 통계적 분포를 갖는다. 반면에 가설  $H_1$ 가 유효한 상황에서는 OFDM 심볼 구간 중에서 CP가 존재하는 시간 구간과 나머지 구간에 대응되는  $R_i$  값의 분포가 다르므로, 이러한 차이를 활용하면 가설 검정을 할 수 있다. 기존의 연구<sup>[2-4]</sup>에서  $\{R_i\}$ 의 합 또는 CP 구간에 대응되는  $R_i$ 만의 합을 검정 통계량으로 설정하는 방식들이 대표적인 사례이다.

CP가 시작되는 지점을  $\theta$ 로 정의하고,  $S_\theta$ 는 CP에 속하는 수신 데이터 샘플 번호의 집합이라고 정의할 때, 참고 문헌 [3]에 따르면  $\theta$ 가 알려진 경우에  $\{R_i\}$ 에 대하여 GLRT를 적용하면 다음과 같은 통계량  $A_{GLRT}(\theta)$ 를 도출할 수 있다고 하였다.

$$A(\theta) = \frac{\sum_{i=0}^{N_c + N_d - 1} |R_i|^2}{\sum_{k \in S_\theta} \left| R_k - \frac{1}{N_c} \sum_{i \in S_\theta} \bar{R}_i \right|^2 + \sum_{j \notin S_\theta} |R_j|^2} \quad (2)$$

위 식에서  $\bar{R}_i$ 는  $R_i$ 의 실수부를 의미한다. 그리고 이를  $\theta$ 를 알 수 없는 경우로 확장하면 검정 통계량  $A_{GLRT}$ 을 다음과 같이 설계할 수 있다고 제안하였다.

$$A_{GLRT} = \max_{\theta} A(\theta) \quad (3)$$

그림 1은  $N_c = 16, N_d = 64$  이고,  $\theta = 0$ 인 상황에서 두 가지 가설  $H_0$ 와  $H_1$ 에 대하여  $\theta$ 의 추정값인  $\hat{\theta}$ 에 따라  $A(\hat{\theta})$ 가 어떻게 변하는 지에 대한 사례 중의 하나이다. 이때 가능한  $\hat{\theta}$ 의 범위는  $[0, 79]$ 이므로  $H_1$ 에 대한  $A(\hat{\theta})$ 가  $\hat{\theta} = 0$ 과 79 근처에서 최대값을 갖게 된다. 반면에  $H_0$ 에 대한  $A(\hat{\theta})$ 는 대부분 작은 값을 갖지만, 이 경우처럼  $H_0$ 에 대한  $A(\hat{\theta})$ 이 첨두 특성을 보이는 경우도 발생한다. 따라서 이때는  $H_0$ 의 경우에도  $A_{GLRT}$ 가 클 수 있음을 알 수 있다. 그러므로  $A_{GLRT}$  보다는  $\{A(\theta)\}$ 의 특성을 활용하여 가설 검정하는 것이 유리할 수 있음을 예상할 수 있다.




그림 1.  $\theta$ 에 따른  $A(\theta)$ 의 변화  
Fig. 1.  $A(\theta)$  as a function of  $\theta$

### IV. RNN 기반 OFDM 신호 검출 방식

$\{A(\theta)\}$ 는 일종의 수열로 OFDM 신호 존재 여부에 따라 다른 패턴을 보인다고 해석할 수 있다. 이에 본 논문에서는 시계열 데이터 학습에 적합한 RNN 기반 머신 러닝 방식을 이용하여 OFDM 신호의 존재 여부를 결정하는 방안을 제시하고자 한다.

논문에서 사용한 머신 러닝 모델의 자세한 모델 구조는 표 1에 나타난 것처럼 총 다섯 개의 층(layer)으로 구성되어 있는데, 처음 3개 층은 GRU(gated

표 1. 제안하는 머신 러닝 모델의 하이퍼 파라미터  
Table 1. Hyperparameters of the proposed machine learning model

input : $\{A(\theta), i = 0, \dots, N_c + N_d - 1\}$		
layers	memory cell	note
GRU	512	dropout=0.2, activation=ReLU
GRU	1024	dropout=0.2, activation=ReLU
GRU	256	dropout=0.2, activation=ReLU
dense	-	input=256, output=500 activation=ReLU
dense	-	input=500, output= 2 activation=softmax
output : 1 x 2 score vector		

recurrent unit) 셀을 이용하여 구현하였다. 이 중 처음 두 층은  $(N_c + N_d)$ 개의 순차적 입력에 대하여 각각 층  $(N_c + N_d)$ 번의 출력을 내고, 세 번째 층은 최종 출력만 그 다음에 연결된 밀집 층(dense layer)으로 전달하는 것으로 설계하였다. 그리고 과잉 적합(over fitting)을 방지하기 위해 20%의 드롭아웃(drop out)을 적용하였다. 네 번째 층은 밀집 층으로서 세 번째 층으로부터 넘겨받은 256개의 입력을 받아 500개의 값을 출력하고, 다섯 번째 밀집 층에서는 이를 입력으로 소프트맥스(softmax) 활성 함수를 적용하여 출력 벡터  $[O_1 \ O_2]$ 를 결정한다. 최종적으로 본 논문에서 제안하는 스펙트럼 센싱 방식의 검정 통계량  $A_{RNN}$ 은 다음과 같이 정의하며, 이때 사용하는 임계값은 목표로 하는 오경보 확률을 달성할 수 있도록 실험적으로 정하는 것으로 설계하였다.

$$A_{RNN} = \frac{O_1}{O_2} \quad (4)$$

### V. 모의 실험 및 결과

성능 분석을 위해 실험에서 사용한 OFDM 신호는 부반송파별로는 QPSK 변조 심볼을 사용했으며,  $N_c = 16$ ,  $N_d = 64$ 를 사용하는 것으로 설정하였다. 그리고 샘플링 속도는 20MHz,  $K = 99$ 으로 가정하였다. 또한 수신 채널로는 도플러 주파수가 10Hz인 레일리 페이딩 환경을 고려하였다.

머신 러닝 학습에 사용하는 수신 OFDM 신호로는 OFDM 신호가 존재하는 경우와 그렇지 않은 경우를 확률적으로 1/2씩 생성하고, OFDM 신호가 존재하는 경우에 SNR(signal to noise ratio)이 -15dB ~ 0dB 사이의 임의값을 갖도록 설정하여 총 8000개 신호를




그림 2. 여러 가지 SNR에서 OFDM 신호 검출 성능  
Fig. 2. Performance of OFDM signal detection for several values of SNRs

만들고 이를 사용해 학습을 진행하였다. 그리고 임계값 설정 및 검파 성능 측정에 사용한 신호는 각각 1000개이고, 실험에서 설정한 목표 오경보 확률( $P_{FA}$ )로는 0.01, 0.05, 0.1을 고려하였다.

그림 2는 기존의 방식(GLRT)<sup>[3]</sup>과 본 논문에서 제안한 방식(ML)의 검출 성능을 비교하였다. 그림에서 보는 바와 같이 제안한 방식의 성능이 기존의 방식보다 향상된다는 것을 확인할 수 있으며, SNR이 낮을수록 개선 폭이 크다는 것을 알 수 있다. 이는 머신 러닝에 기반한 검정 통계량  $A_{RNN}$ 이  $A_{GLRT}$ 에 비해 우선 사용자 신호의 2차 통계 특성을 더 잘 반영함으로써 우월한 가설 검정 능력을 갖기 때문이다.

### References

- [1] T. Yucek, et al., "A survey of spectrum sensing algorithms for cognitive radio applications," *IEEE Commun. Surv. Tuts.*, vol. 11, no. 1, pp. 116-130, Mar. 2009.
- [2] C. H. Lim, "Spectrum sensing techniques for OFDM signals in cognitive radio," *J. KICS*, vol. 42, no. 9, pp. 1726-1732, Sep. 2017.
- [3] E. Axell, et al., "Optimal and sub-optimal spectrum sensing of OFDM signals in known and unknown noise variance," *IEEE J. Sel. Areas Commun.*, vol. 29, no. 2, pp. 290-304, Jan. 2011.
- [4] J. Tian, et al., "A machine learning-enabled spectrum sensing method for OFDM systems," *IEEE Trans. Veh. Technol.*, vol. 68, no. 11, pp. 11374-11378, Sep. 2019.