

시간 영역에서 이웃한 관측 창 신호 사이의 상관성에 심층 학습을 적용한 레이더 신호 검출

임창헌*, 박종부*

Radar Signal Detection Applying Deep Learning to the Correlation Between Adjacent Windows in Time Domain

Chang Heon Lim*, Jongbu Park*

요약

펄스 레이더 신호는 시간 영역에서 동일한 펄스가 반복된다는 특성을 갖는다. 이전 연구^[4]에서 이에 근거하여 시간 영역에서 이웃한 관측 창 신호 사이에 원형 컨벌루션을 구하고, 그 결과의 최대 절대값을 검정 통계량으로 사용하는 레이더 신호를 검출하는 방안을 제시한 바가 있다. 본 논문에서는 좀 더 향상된 성능을 확보하기 위한 방안으로 이웃한 관측 창 신호 사이의 원형 컨벌루션에 심층 학습(deep learning)을 적용한 방식과 컨벌루션의 푸리에 변환 절대값에 심층 학습을 적용한 검출 방식을 제시하고 그 성능을 비교하고자 한다.

Key Words : cognitive radio, spectrum sensing, pulse radar, circular convolution, deep learning

ABSTRACT

For a pulse radar signal, the radar pulses tend to occur periodically in time domain. Based on this, a previous work^[4] presented a radar detection scheme which performs circular convolution between two signal sets in two adjacent observation windows in

time domain and employs its maximum absolute value as a test statistic. In this Letter, in order to further improve its performance, we present two improved versions of it which apply deep learning to the circular convolution between signals over two adjacent observation windows and the absolute values of Fourier transforms of the convolution and compares their performances.

I. 서론

빠르게 늘어나는 주파수 수요를 감당하기 위해 과거 독립적으로 사용하던 대역을 여러 사용자가 공동 사용함으로써 주파수 이용 효율을 높이는 시도에 대한 관심이 고조되고 있다. 대표적인 사례로 5GHz 레이더 대역에 무선랜 서비스를 도입하거나 3.5GHz 대역에 무선 통신 서비스 CBRS(citizens broadband radio service)를 도입하는 것을 들 수 있다^[1].

구체적인 주파수 공유 방식으로는 여러 가지 형태가 있을 수 형태가 있을 수 있는데, 그 중의 하나가 우선 사용자(primary user)가 일시적으로 사용하지 않는 대역을 이차 사용자(secondary user)가 사용하는 방식이며, 이때 가장 핵심적인 기능은 우선 사용자 신호를 검출하는 스펙트럼 센싱 기술^[2]이다. 최근 레이더 대역이 주파수 공유 후보 대역으로 많은 관심을 모으고 있다. 이 대역에서는 레이더 신호가 우선 사용자 신호가 된다. 지금까지 발표된 레이더 신호 검출 방식^[3]으로는 정합 필터를 사용하거나 전력 수준이나 전력 변화를 기반으로 하는 펄스 검출 방식이 대부분이다. 펄스 레이더 신호의 존재 유무를 효과적으로 파악하기 위해서는 레이더 신호의 특성을 최대한 활용할 필요가 있다. 기본적으로 펄스 레이더 신호는 펄스가 시간 영역에서 일정한 규칙에 따라 반복적으로 나타나는 특징이 있다. 이를 활용하여 레이더 신호를 검출하는 방법으로 이전 연구^[4]에서 시간 영역에서 이웃한 2개의 관측 창 내에 포함된 신호간의 원형 컨벌루션을 계산하고 그 중의 최대값을 검정 통계량(test statistic)으로 하는 방안을 제시한 적이 있다. 하지만 레이더 신호 존재 여부가 컨벌루션의 최대값에만 영향을 미치는 것은 아니기 때문에 컨벌루션 결과 전체를 활용한

※ 이 논문은 부경대학교 자율창의기술연구비(2021년)에 의하여 연구되었음

* First and Corresponding Author : (ORCID:0000-0001-7022-8914:)Pukyong National University, Department of Electronic Engineering, chlim@pknu.ac.kr, 정교수, 중신회원

* (ORCID:0000-0002-0890-6919)Pukyong National University, Department of Electronic Engineering, 학생(학부생)
논문번호 : 202103-068-A-LU, Received March 24, 2021; Revised April 13, 2021; Accepted April 16, 2021

다면 레이더 신호 검출 성능의 향상을 기대할 수 있다. 본 논문에서는 기계 학습의 일종인 심층 학습을 컨벌루션 기반 데이터에 적용하여 레이더 신호 존재 여부를 판단하는 방식을 제안하고자 한다.

II. 제안하는 스펙트럼 센싱 방식

수신된 펄스 레이더 신호가 시간 n 에서 갖는 샘플을 $s(n)$ 이라 하고 잡음 샘플을 $w(n)$ 이라 할 때, 레이더 신호 유무에 따라 이차 사용자(secondary user)가 수신하는 레이더 신호 $r(n)$ 을 다음과 같이 표현할 수 있다.

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

위 식에서 가설 H_0 와 가설 H_1 은 각각 레이더 신호가 존재하지 않는 경우와 존재하는 경우를 가리키며, $w(n)$ 은 평균이 0이고 분산이 σ^2 인 AWGN(additive white Gaussian noise)을 나타낸다.

본 논문에서 제안하는 검출 방식에서는 길이가 N 인 관측 창마다 우선 사용자의 존재 유무를 판단한다고 가정한다. 현재 관측 창과 직전 관측 창에 포함된 신호를 각각 $X = \{r(n), n=0, \dots, N-1\}$, $Y = \{r(n), n=-N, \dots, -1\}$ 이라고 설정한다. 만약 레이더 신호가 존재한다면, X 와 Y 가 각각 주기적인 펄스를 포함하고 있으므로 그에 대한 원형 컨벌루션 결과에 침투 특성이 나타날 것으로 예상할 수 있다. 반면에 레이더 신호가 없다면 X 와 Y 는 서로 통계적으로 독립적인 잡음 성분만을 갖고 있으므로 그런 현상이 나타나지 않을 것이다. 이렇게 레이더 신호 존재 여부에 따라 원형 컨벌루션 결과가 다른 특성을 갖는다는 점을 활용하여 이전 연구^[4]에서는 원형 컨벌루션의 최대 절대값을 검정 통계량으로 하는 방식을 제안한 바가 있다.

레이더 신호가 존재하는 경우에 X 와 Y 가 각각 주기적인 펄스를 포함하고 있으므로 원형 컨벌루션의 결과에 여러 개의 침투값이 나타날 수 있다. 따라서 이를 활용한다면 컨벌루션 최대값만을 사용하는 방식 보다는 레이더 신호 검출 성능의 개선을 기대할 수 있다. 그러나 이때 레이더 신호 존재 여부에 따른 컨벌루션 결과의 통계적 분포를 도출하는 것은 매우 어려워 최대 우도 검출(maximum likelihood detection) 방식을 적용하기는 어렵다. 차선책으로 본 논문에서는

기계 학습 방법 중의 하나인 심층 학습 기법을 컨벌루션 결과에 적용하여 레이더 신호 존재 여부를 판단하는 방법을 제시하고자 한다.

제안한 검출 방식에서는 X 와 Y 의 원형 컨벌루션 결과를 Z 라고 하고 이것이 심층 학습의 입력 데이터가 된다. 본 논문에서 사용한 기계 학습 모델의 구조를 정리하면 표 1에 나타난 바와 같다. 먼저 입력 Z 를 입력한 후, 50%의 드롭아웃(drop out)을 적용한다. 그리고 그 결과를 밀집층(dense layer)으로 전달한다. 이때 밀집층에서는 배치 정규화와 leaky RELU(rectified linear unit) 형태의 활성화 함수(activation function)를 사용하는 것으로 한다. 첫번째 밀집층의 출력 길이는 10이며, 첫번째 밀집층의 출력은 출력 크기가 5인 두번째 밀집층에 전달되고, 두번째 밀집층의 출력은 출력 크기가 2인 세번째 밀집층에 전달된다. 두번째 밀집층은 첫번째 밀집층과 마찬가지로 배치 정규화와 leaky RELU 활성화 함수를 사용하고, 세번째 밀집층은 소프트맥스(softmax) 활성화 함수를 사용하는 것으로 설계하였다. 세번째 밀집층의 출력을 벡터 $[O_1 \ O_2]$ 로 할 때, 이 두 개의 값은 가설 H_0 와 가설 H_1 의 발생 가능성을 나타낸다. 이때 목표로 하는 오경보 확률을 달성하기 위해서 O_2/O_1 비율이 특정 임계값 이상이면 신호가 존재하는 것으로 판단하되, 이때 사용하는 임계값은 목표로 하는 오경보 확률을 달성할 수 있도록 실험적으로 정하였다.

한편, 레이더 신호와 잡음은 주파수 영역에서 다른 스펙트럼 특성을 갖는다. 잡음의 전력 스펙트럼은 광대역이며 주파수 영역에서 고른 특성을 갖는 반면에 레이더 신호는 그렇지 않기 때문이다. 따라서 레이더 신호의 존재 여부를 시간 영역보다 주파수 영역에서 판단하기가 더 용이할 수 있다. 이에 근거하여 두 개의 관측창에 포함된 신호의 FFT 결과를 곱한 결과의 절대값에 심층 학습을 적용한 방식을 추가로 제안하

표 1. 제안하는 방식에서 사용한 심층 학습 모델
Table 1. Deep learning model adopted in the proposed schemes

Layers	Note
Input	input size
Dropout	dropout=0.5
Dense layer	output size=10, batch normalization, activation=leaky RELU
Dense layer	output size=5, batch normalization, activation=leaky RELU
Dense layer	output size=2, activation=softmax

고자 한다. 즉 X 와 Y 에 대하여 FFT를 적용한 결과를 곱한 후, 이의 절대값만을 선택한 결과를 W 라고 하고, 앞서 Z 에 대하여 심층 학습 방식을 적용하듯이 W 에 대하여 심층 학습 방식을 적용하는 방식을 제안한다. 여기에서 W 는 Z 를 푸리에 변환한 후 절대값을 선택한 것이라고 볼 수 있다.

III. 성능 평가 결과

성능 평가를 위해 사용하는 레이더 신호로 펄스 폭은 $10 \mu s$, 레이더 펄스 반복 주기는 $1 ms$ 인 신호를 사용하였으며, 연속한 2개 관측창의 길이는 각각 $10 ms$ 로 설정하고 샘플링 속도는 $10 MHz$ 로 설정하였다. 그리고 펄스 압축(pulse compression) 방식으로는 $100kHz$ 의 주파수 변화율을 사용하는 LFM(linear frequency modulation) 방식을 사용하였다. 검출 임계값은 목표 오경보 확률이 $0.01, 0.05, 0.1$ 인 세 가지 경우에 대하여 실험적으로 결정하였으며, 배경 잡음 전력의 불확실성은 $0 dB, 1 dB, 2 dB$ 라는 세 가지 경우를 고려하였고, 펄스 레이더 신호는 도플러 주파수가 $10 Hz$ 인 이중 경로 레이더 페이딩 채널을 거쳐 수신되는 것으로 가정하였다. 이때 이중 경로의 평균 경로 이득은 1로 동일하고, 경로 시간차는 $0.1 \mu s$ 로 설정하였다.

그림 1은 SNR(signal to noise ratio)=-10dB일 때 여러 가지 검출 방식의 오경보 확률 대비 검파 확률 성능을 보여준다. 그림의 범례에서 NU는 잡음 전력 불확실성(noise power uncertainty)을 나타내고, ED는 에너지 검출 방식, ConvMax는 [4]의 방식을 가리킨

다. 그리고 ConvDNN과 FFTDNN은 본 논문에서 제안한 2가지 방식으로, 전자는 이웃한 관측창 신호간의 원형 컨볼루션 결과에 심층 학습을 적용한 방식이고, 후자는 원형 컨볼루션 결과의 푸리에 변환후 절대값에 심층 학습을 적용한 방식이다. 그림에서 보는 바와 같이 본 논문에서 제안한 두 가지 방식인 ConvDNN과 FFTDNN은 모두 ConvMax나 ED 방식보다 우수한 스펙트럼 센싱 성능을 보여준다는 것을 알 수 있다. $NU=0dB$ 이고 오경보 확률이 0.1 일 때를 비교하면 ConvDNN과 FFTDNN 방식은 ConvMax 방식에 비해 검파확률이 각각 $0.23, 0.31$ 만큼 높다는 것을 알 수 있다. 특히, FFTDNN 방식이 ConvDNN 방식보다 우수한 센싱 성능을 보여주고 있는데, 이는 주파수 영역 관점에서 우선 사용자 신호 존재 여부를 판단하는 것이 더 유리하다는 것을 의미한다.

References

[1] A. M. Voicu, et al., "Survey of spectrum sharing for inter-technology coexistence," *IEEE Commun. Surv. Tuts.*, vol. 21, no. 2, pp. 1112-1144, 2019.

[2] 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, 2009.

[3] C. H. Lim, et al., "Spectrum sensing techniques for detection of radar signals in radar bands," *J. KICS*, vol. 43, no. 12, pp. 2048-2056, Dec. 2018.

[4] C. H. Lim, "Spectrum sensing for radar bands using correlation between signals in consecutive observation windows," *J. KICS*, vol. 43, no. 8, pp. 1243-1245, Aug. 2018.




그림 1. SNR=-10dB일 때 오경보 확률 대비 검파 확률
Fig. 1. Detection probability versus false alarm probability for SNR=-10dB