

## 인지 무선 통신을 위한 순환 신경망 기반 스펙트럼 센싱 기법

정태윤<sup>1</sup> · 정의림<sup>2\*</sup>

### Recurrent Neural Network Based Spectrum Sensing Technique for Cognitive Radio Communications

Tae-Yun Jung<sup>1</sup> · Eui-Rim Jeong<sup>2\*</sup>

<sup>1</sup>Graduate Student, Department of Mobile Convergence and Engineering, Hanbat National University, Daejeon, 34158 Korea

<sup>2\*</sup>Professor, Department of Information and Communication Engineering, Hanbat National University, Daejeon, 34158 Korea

#### 요 약

본 논문에서는 인지 무선 통신을 위한 새로운 순환 신경망 기반 스펙트럼 센싱 기법을 제안한다. 제안하는 기법은 주사용자에 대한 정보가 전혀 없는 상황에서 에너지 검출을 통해 신호 존재 유무를 판단한다. 제안 기법은 센싱하고자 하는 전체 대역을 고려하여 수신신호를 고속으로 샘플링 후 이 신호의 FFT (fast Fourier transform)를 통해 주파수 스펙트럼으로 변환한다. 이 스펙트럼 신호는 채널 대역폭 단위로 자른 후 순환 신경망에 입력하여 해당 채널이 사용 중인지 비어있는지 판정한다. 제안하는 기법의 성능은 컴퓨터 모의실험을 통해 확인하는데 그 결과에 따르면 기존 문턱값 기반 기법보다 2 [dB] 이상 우수하며 합성곱 신경망 기법과 유사한 성능을 보인다. 또한, 실제 실내환경에서 실험도 수행하는데 이 결과에 따르면 제안하는 기법이 기존 문턱값 기반 방식 및 합성곱 신경망 방식보다 4 [dB] 이상 우수한 성능을 보인다.

#### ABSTRACT

This paper proposes a new Recurrent neural network (RNN) based spectrum sensing technique for cognitive radio communications. The proposed technique determines the existence of primary user's signal without any prior information of the primary users. The method performs high-speed sampling by considering the whole sensing bandwidth and then converts the signal into frequency spectrum via fast Fourier transform (FFT). This spectrum signal is cut in sensing channel bandwidth and entered into the RNN to determine the channel vacancy. The performance of the proposed technique is verified through computer simulations. According to the results, the proposed one is superior to more than 2 [dB] than the existing threshold-based technique and has similar performance to that of the existing Convolutional neural network (CNN) based method. In addition, experiments are carried out in indoor environments and the results show that the proposed technique performs more than 4 [dB] better than both the conventional threshold-based and the CNN based methods.

**키워드** : 인지 통신, 순환 신경망, 스펙트럼 센싱, 에너지검출, 이진 분류

**Keywords** : Cognitive radio, Recurrent neural network, Spectrum sensing, Energy detection, Binary classification

Received 5 March 2020, Revised 19 March 2020, Accepted 6 April 2020

\* Corresponding Author Eui-Rim Jeong(E-mail:erjeong@hanbat.ac.kr, Tel:+82-42-821-1752)

Professor, Department of Information and Communication Engineering, Hanbat National University, Daejeon, 34158 Korea

Open Access <http://doi.org/10.6109/jkiice.2020.24.6.759>

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

무선 통신 시스템에서 주사용자 (Primary user, PU)에게 할당된 스펙트럼은 항상 사용되고 있는 것은 아니며 긴 시간동안 사용되지 않는 경우도 있다. 부족한 스펙트럼 문제를 해결하고 스펙트럼 사용 효율을 높이기 위해 부사용자 (Secondary user, SU)가 이렇게 일시적으로 사용하지 않는 스펙트럼을 활용하여 통신할 수 있도록 인지 무선 (Cognitive radio) 통신 기술이 제안되었다 [1]. 인지 무선 통신에서는 SU가 간섭 신호를 발생하지 않도록 정확한 PU 신호 존재 유무를 판단하는 것이 매우 중요하며 이를 스펙트럼 센싱이라 한다. 스펙트럼 센싱 방식은 크게 세 가지 범주로 분류되는데 PU 신호에 대한 사전 정보를 알고 있는 경우[2-3], PU에 대한 정보가 전혀 없는 경우[3], 다수의 SU가 협력하여 판정하는 방법[4]이 있다. PU 신호에 대한 정보가 없는 상황에서 가장 널리 사용되는 방식은 문턱값 기반의 에너지 검출 기법이다[5-6]. 이 기법은 먼저 잡음의 전력을 추정하고 이를 기반으로 문턱값을 설정한다. 이후 수신 신호의 전력이 문턱값을 넘으면 PU 신호가 존재한다고, 넘지 않으면 비어있다고 판단한다. 에너지 검출 방식은 잡음의 전력을 정확하게 추정할 수 있는 경우 우수한 성능을 보이지만 정확하지 않으면 성능 열화가 심하다고 알려져 있다[6-7]. 최근에는 낮은 SNR에서도 PU 신호 존재 유무를 정확하게 판단하기 위해 머신러닝 기반의 연구도 활발히 진행되고 있다. 인공신경망 (Artificial neural network, ANN) 기반의 스펙트럼 센싱[8-9]은 기존의 에너지 검출보다 개선된 성능을 보이지만, 스펙트럼 관찰 시간에 따라 존재 유무를 판정한다고 하면 메모리 셀이 없는 인공 신경망은 분류 문제에 적합하지 않아 주로 순환 신경망 (Recurrent neural network, RNN) 기반 스펙트럼 센싱 기법이 연구되었다[10]. 순환신경망 중에서도 장기 의존성 문제를 해결한 LSTM (long short term memory) 셀을 이용한다[10-11].

본 논문에서는 에너지 검출을 기반으로 한 새로운 스펙트럼 센싱 기법을 제안한다. 본 논문은 이전에 연구되었던 합성곱 신경망 (Convolutional neural network, CNN) 기반 스펙트럼 센싱 기술[12]을 변형하여 순환 신경망을 이용한 새로운 스펙트럼 센싱 기법을 제안한다. 제안하는 기법은 잡음전력의 추정 과정 없이 수신신호의 크기 제곱을 순환 신경망에 입력하고 순환 신경망이 PU의 신호 존




Fig. 1 Example of received signal's spectrum

재 유무를 판단한다. 제안 기법은 한 가지 가정 하에 동작한다. 즉, PU가 할당할 수 있는 전체 주파수 채널의 수가 A개라고 하면 실제로 A-1개만 할당 하고 1개의 채널은 비워둔다는 가정이다. 에너지 검출에 기반하는 스펙트럼 기법은 제안하는 기법을 포함해서 잡음의 전력을 정확하게 추정하는 것이 중요한데, PU들이 하나의 채널을 항상 비워둔다면 이 채널을 이용하여 잡음의 전력을 정확하게 추정할 수 있을 것이다. 제안하는 기법은 잡음전력을 추정하는 과정은 필요 없지만 이렇게 할당하지 않은 채널의 신호를 딥러닝에 활용하여 스펙트럼 센싱을 수행한다. 구체적으로, 제안 기법은 센싱하고자 하는 전체 대역을 고려하여 고속으로 샘플링하고, 샘플링 한 신호는 그림 1과 같이 여러 채널의 PU 신호가 관찰될 수 있다. 스펙트럼 센싱을 위해 이 신호에 대해 FFT (fast Fourier transform)를 수행한다. 이렇게 수신신호를 주파수 스펙트럼으로 변환하고 연속적인 수신신호에 대해 구한 스펙트럼을 쌓아서 2차원 신호로 만든다. 이렇게 만든 2차원 신호는 채널 대역폭 단위로 쪼개어지고 비워둔 채널 신호를 붙여 최종 신호, 즉 순환신경망 입력신호를 생성한다. 이렇게 만든 2차원 행렬 신호를 열벡터 단위로 순차적으로 제안하는 순환신경망에 입력한다. 순환신경망의 출력은 두 개의 클래스, 즉, PU 신호 존재유무이다. 따라서 제안 기법은 이진 분류 순환 신경망으로 볼 수 있다. 제안하는 순환 신경망은 LSTM (long short term memory) 셀을 이용한다[11]. 제안하는 기법의 성능은 컴퓨터 모의실험과 실제 실내환경에서의 필드실험을 통해 검증한다. 필드 실험의 경우 모의 실험에서 학습한 신경망 모델을 그대로 사용하여 검출 성능을 검증한다. 모의실험 결과에 따르면 제안하는 기법은 기존 문턱값 기반 기법보다 2 [dB] 이상 우수한 성능을 보이고 합성곱 신경망 기법과의 유사한 성능을 보인다. 반면 필드 실험 결과에 따르면 제안하는 기법이 기존의 문턱값 기반 기법보다 8 [dB] 이상, 합성곱 신경망 기법보다 3 [dB] 이상 우수한 성능을 보인다.




Fig. 2 Overall system model

## II. 수신 신호 모델

본 논문에서 고려하는 스펙트럼 센싱 시스템 모델은 그림 2와 같다. 안테나를 통해 수신된 신호는 RF (radio frequency) 하향 변환기, ADC (Analog to digital converter) 에 의해 기저대역 디지털 신호로 변환되며 이 신호를  $r(n)$  이라 한다. 수신 신호는 FFT 크기인  $N_{FFT}$  단위로 읽는데 인접한  $N_{FFT}$  개의 신호를 읽을 때  $N_0$  만큼 중첩하며 샘플을 수집한다.  $r(n)$  을 중첩하며 신호를 취하는 과정은 그림 3과 같다. 중첩하여 신호를 취하는 이유는 전체 신호수집 시간을 단축하기 위함이다. 여기에서  $B$  는 FFT 신호 블록의 개수이다.  $i+1$  번째 수집 신호 블록은 다음과 같이 나타낼 수 있다.

$$\mathbf{r}_i = [r(iN_0), \dots, r(iN_0 + K - 1)]$$

for  $i = 0, \dots, B - 1$  (1)

스펙트럼 센싱은 주파수 영역에서 수행해야 하므로  $\mathbf{r}_i$  는 FFT를 통해 주파수 스펙트럼으로 변환한다.  $\mathbf{r}_i$  의 포인트 FFT 벡터를  $\mathbf{R}_i$  라고 정의하며 크기는  $K \times 1$  이다.

$$\mathbf{R}_i = FFT\{\mathbf{r}_i\} = [R_i(0), \dots, R_i(K - 1)]^T$$
 (2)

스펙트럼 센싱은 스펙트럼의 크기를 이용하여 판단해야 하므로  $K$ 개의 FFT 각 원소에 절대값을 취한다. 이 신호는 다음과 같이 정의한다.




Fig. 3 Process of collecting received signal block

$$|\mathbf{R}_i| \triangleq [|\mathbf{R}_i(0)|, |\mathbf{R}_i(1)|, \dots, |\mathbf{R}_i(K - 1)|]^T$$
 (3)

총  $B$  개의 신호 블록에 대해 FFT를 수행하고 절대값을 취해 얻은  $\{|\mathbf{R}_i|, i = 0, \dots, B - 1\}$  를 쌓아서 크기가  $K \times B$  인 2차원 신호를 만들고, 이 신호를  $\mathbf{R}$  이라고 정의하면 다음과 같이 쓸 수 있다.

$$\mathbf{R} = [|\mathbf{R}_0|, |\mathbf{R}_1|, \dots, |\mathbf{R}_{B-1}|] \quad (4)$$

$\mathbf{R}$  은 광대역 신호의 FFT를 통해 만든 신호이므로 여러개의 PU 채널들을 포함할 수 있다. 따라서 이를 센싱 채널별로 분리한다. 수신신호 전체 대역폭은  $K$  포인트로 표현되며 센싱채널의 폭은  $K_C (< K)$  포인트라고 하자. 전체 센싱채널의 개수는  $K/K_C$  가 되고, ADC의 샘플링 클럭을  $F_s$  (Hz)라고 할 때 각 센싱채널의 대역폭은  $K_C F_s / K$  (Hz)로 주어진다. 이때 마지막 센싱채널, 즉,  $K/K_C$  번째 채널은 PU가 할당하지 않고 항상 비워둔다고 가정한다. PU 신호 존재 유무에 대한 판단은 센싱채널의 전력과 잡음전력을 비교하여 판단하는 것이 일반적이다. 따라서, 이와 같이 잡음만 존재하는 채널이 존재하는 것은 스펙트럼 센싱에 매우 유리하다.

위에서 기술한 바와 같이  $\mathbf{R}$  을 센싱채널 별로 선택하고 잡음채널을 덧붙여 새로운 행렬을 만든다. 이 과정은 다음과 같이 쓸 수 있다.

$$\mathbf{R}_c = \begin{bmatrix} \tilde{\mathbf{R}}_c \\ \tilde{\mathbf{R}}_{K/K_C-1} \end{bmatrix} \text{ for } c = 0, \dots, K/K_C - 2 \quad (5)$$

$\tilde{\mathbf{R}}_c$  은 크기가  $K_C \times B$  인  $\mathbf{R}$  의 부분 행렬이며,  $\mathbf{R}$  에서  $cK_C + 1$  부터  $(c + 1)K_C$  까지의 행을 선택해서 만든 행렬이다.  $\tilde{\mathbf{R}}_{K/K_C-1}$  은 맨 마지막 센싱채널에 해당하는 부분 행렬이며 항상 잡음만 존재하는 채널이다. 결과적으로, 제안하는 순환 신경망 기반의 스펙트럼 센싱 기법은 센싱채널과 잡음채널을 결합하여 새롭게 만든 크기가  $2K_C \times B$  인 행렬  $\mathbf{R}_c$  를 이용하여 PU 신호 존재 유무를 판단한다. 구체적으로는  $\mathbf{R}_c$  를  $2K_C \times 1$  의 열 벡터 단위

로 순환 신경망에 입력한다. 합성곱 신경망을 이용하는 기존의 연구 [12]에서는  $R_c$ 가 곧바로 합성곱 신경망에 입력되었다.

### III. 스펙트럼 센싱 기법

본 절에서는  $R_c$ 를 이용한 기존 문턱값 기반 기법과 기존 합성곱 신경망 기반의 기법에 대해 설명하고 이어서 본 논문에서 제안하는 순환 신경망 기반 기법에 대해 설명한다.

#### 3.1. 기존의 문턱값 기반 스펙트럼 센싱

기존의 에너지 검출 방식은 먼저 잡음의 전력을 추정하고 이를 기반으로 문턱값을 설정한다. 이후 수신신호의 전력이 설정한 문턱값을 넘으면 신호가 존재하고 넘지 않으면 신호가 비어 있는 것으로 판단한다.  $(c+1)$  번째 센싱채널에 대한 판단은 다음과 같이 이루어진다.

$$\begin{cases} \text{Busy, } \hat{P}_c > \lambda \\ \text{Idle, } \text{otherwise} \end{cases} \quad (6)$$

여기에서  $\lambda$ 는 문턱값으로 다음과 같이 주어진다.

$$\lambda = \alpha \times \hat{P}_{noise} \quad (7)$$

$\hat{P}_{noise}$ 는 잡음전력의 추정값이며 PU가 할당하지 않은 잡음 채널을 이용하여 구할 수 있다.

$$\hat{P}_{noise} = \frac{1}{KCB} \sum_{n=0}^{B-1} \sum_{m=0}^{K-1} |\tilde{R}_{K/K_c-1}(m,n)|^2 \quad (8)$$

$\tilde{R}_c(m,n)$ 는 행렬  $\tilde{R}_c$ 의  $(m,n)$  번째 원소를 나타내며, 수식 (7)에서  $\alpha$ 는 양의 실수 값으로 SNR (signal to noise ratio)의 함수로 결정되는 변수이다.  $(c+1)$  번째 채널의 전력 추정값  $\hat{P}_c$ 는 다음과 같이 구해진다.

$$\hat{P}_c = \frac{1}{KCB} \sum_{n=0}^{B-1} \sum_{m=0}^{K-1} |\tilde{R}_c(m,n)|^2 \quad (9)$$

수식 (6)의 문턱값 기반의 에너지 검출 기법은 잡음의 전력을 정확하게 추정할 수 있으면 우수한 성능을 보이지만 그렇지 않은 경우에는 성능저하가 심각하게 발생하는 것으로 알려져 있다. 또한, 스펙트럼 센싱을 위해서는 SNR 값을 미리 알아야 한다는 부담이 있다.

#### 3.2. 합성곱 신경망 기반 스펙트럼 센싱

본 절에서는 기존에 연구되었던 합성곱 신경망 기반 스펙트럼 센싱 기법에 대해 간단히 설명한다. 그림 4의 왼쪽 그림은  $K=512, B=64$ 일 때 수식 (4)의  $R$ 의 한 예를 흑백 이미지로 나타내고 있으며 합성곱 신경망 입력 신호  $R_c$ 는 위에서부터 PU 신호가 있을 경우와 없을 경우를 나타낸다. 흰색은 큰 값, 검정색은 0에 가까운 값을 나타내며 그 사이 값은 회색으로 나타난다. 그림 4에서의 훈련 샘플의 예시는 SNR이 20 [dB]인 환경으로 SNR이 높은 상황이라서 센싱 채널 별로 PU 신호 존재 유무가 명확하게 구분이 된다. 합성곱 신경망 네트워크

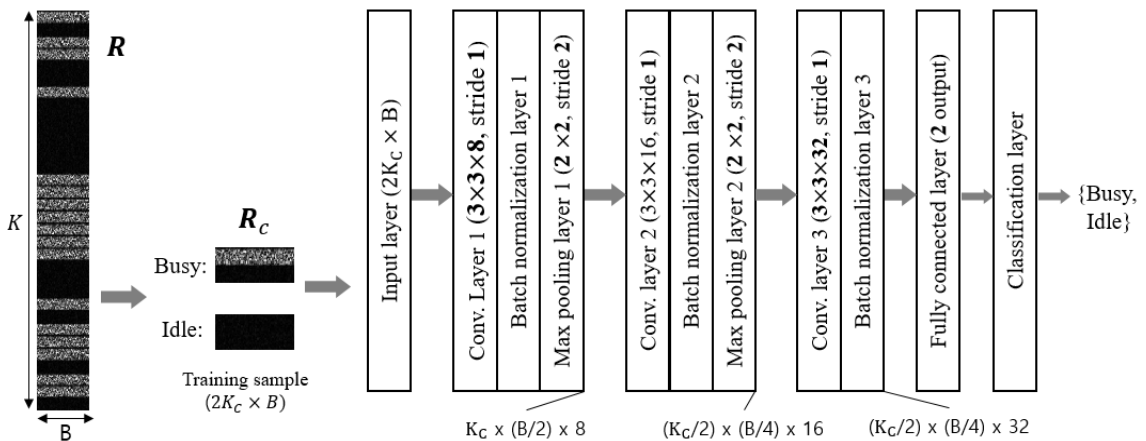


Fig. 4 Neural network of existing CNN based spectrum sensing technique

구조는 그림 4와 같이 크기  $2K_C \times B$ 인  $R_c$ 를 입력으로 하며 총 3개의 합성곱 계층으로 구성된다. 각 합성곱 계층에는 배치 정규화 계층, 풀링 계층을 포함하며 마지막 합성곱 계층에는 풀링 계층을 제외하여 같은 사이즈로 출력된다. 각 합성곱 계층의 필터 수는 8에서 32까지 2배씩 증가시키고, 필터 크기  $3 \times 3$ 과 스트라이드 1은 각 계층마다 동일하게 적용한다. 풀링 계층은  $2 \times 2$  맥스 풀링을 사용하며 스트라이드는 2이고 활성화 함수는 ReLU (Rectified Linear Unit)를 적용한다. 마지막 합성곱 계층의 출력은 완전 연결 계층으로 통하며 최종적으로 분류 계층에서 PU 신호의 존재 유무를 판정한다.

### 3.3. 제안하는 순환 신경망 기반 스펙트럼 센싱

제안하는 순환 신경망 기반 스펙트럼 센싱 기법에 대해 설명한다. 그림 5는 제안하는 기법의 전체 네트워크 구조를 보이고 있다. 그림 5의 왼쪽 구조를 시간에 따라 펼치면 오른쪽과 같다. 스펙트럼 센싱을 수행하는 순환 신경망의 입력에도  $R_c$ 를 사용하는데  $R_c$ 의 열 단위로 입력된다. 구체적으로, 2차원 행렬  $R_c$ 의 크기가  $2K_C \times B$ 이므로 순환 신경망의 입력은 크기가  $2K_C \times 1$ 인 총  $B$ 개의 열벡터이다. 그림 5에 보이고 있듯이 2차원 행렬  $R_c(m,n)$ 이 행렬  $R_c$ 의  $(m,n)$ 번째 값을 나타낸다고 하면, LSTM 셀의 첫 번째 입력은  $r_{c,0} = [R_c(0,0), \dots,$

$R_c(2K_C-1,0)]^T$ 이고 다음 입력은  $r_{c,1} = [R_c(0,1), \dots, R_c(2K_C-1,1)]^T$ 으로 총  $B$ 개의 열벡터가 입력된다. 이 벡터는 LSTM 셀과 전체 연결 계층, 최종적으로 이진 분류 계층을 통해 PU 신호 존재 유무를 판정한다. 본 논문에서 제안하는 순환 신경망은 64개의 LSTM 셀로 구성했으며, 맨 마지막 벡터가 입력된 후의 최종 출력이 PU 채널이 사용 중인지 비어있는지를 나타낸다.

## IV. 컴퓨터 모의실험

### 4.1. 학습 및 테스트 신호 모델

제안하는 방법의 성능을 확인하기 위해 먼저 컴퓨터 모의실험을 수행한다. 수신신호의 샘플링 주파수는 16 MHz이고 각 센싱채널의 대역폭은 0.5 MHz이다. PU 신호도 0.5 MHz의 대역폭을 가진다고 가정하면 광대역 샘플링을 통해 한 번에 관찰되는 전체 채널의 수는 32개이다. 제안하는 스펙트럼 센싱 기법에 사용된 주요 파라미터 값은 다음과 같다. FFT 포인트 수는  $K=512$ 이고, 신호 블록을 취할 때 중첩의 길이는  $N_0=256$ 이며, 센싱 채널의 길이는  $K_C = 16$ , 관찰 신호 블록의 길이  $B$ 는 64로 설정한다.

제안하는 순환신경망을 학습하기 위한 학습 신호 모

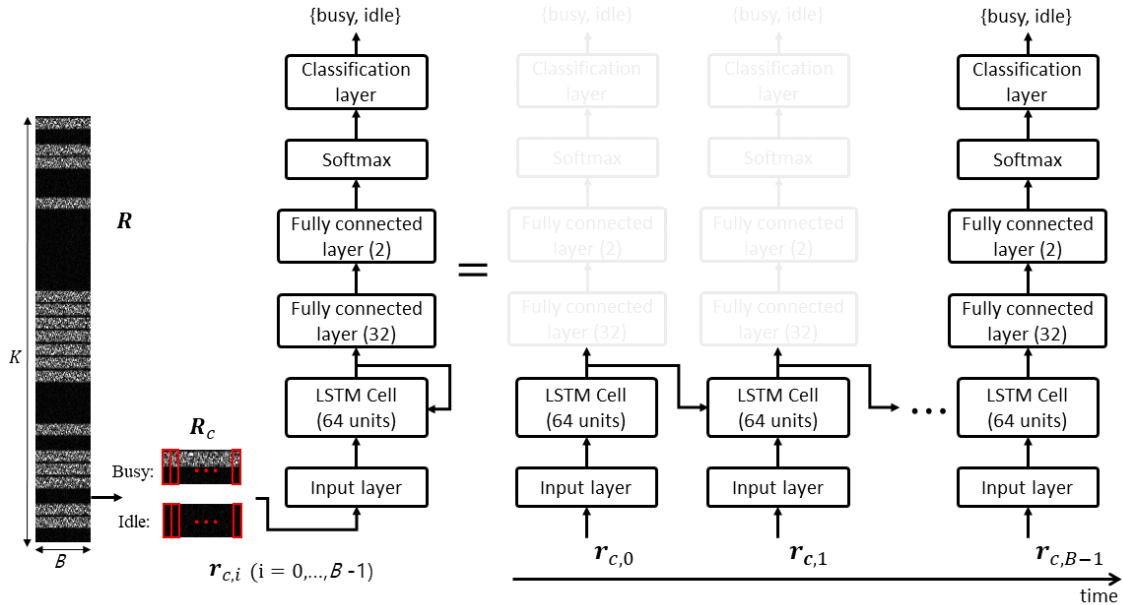


Fig. 5 Neural network of proposed RNN based spectrum sensing technique

델과 테스트 신호 모델은 다음과 같다. 학습에 사용되는 신호 모델은 총 20,000 세트의 광대역 PU 신호이다. 각 채널에서 PU 신호의 존재 확률은 50%이며 한 세트 신호로부터 마지막 채널을 제외한 총 31개의 센싱채널,  $R_c (c = 0, \dots, 30)$ 가 만들어진다. 또한, 학습 신호를 생성할 때 SNR은 -20 [dB]에서 50 [dB]의 범위에서 무작위로 선택한다. 이와 같은 범위는 실제 필드 환경을 고려하여 설정한 것이다. 따라서, 제안하는 순환 신경망의 입력에는 총  $20,000 \times 31 = 620,000$ 개의  $R_c$ 가 학습신호로 입력된다. 학습은 교차 엔트로피가 최소화되도록 수행하고 최적화 기법은 SGDM (Stochastic Gradient Descent with Momentum)을 사용한다. 학습률은 0.001이며 미니 배치 크기는 620로 설정한다. 그림 6은 순환 신경망 학습 시 손실함수의 학습 곡선을 나타낸다. 학습은 전체 학습 신호를 총 3번 반복 사용하면서 수행하고 (3 epochs), 그림 6에서 알 수 있듯이 약 300번 이내의 갱신 후에 충분히 수렴하는 것을 확인할 수 있다.

스펙트럼 센싱 성능을 확인하기 위한 테스트 신호 모델 역시 모의실험을 통해 생성한다. 생성하는 신호의 SNR은 -20 [dB]부터 6 [dB]의 범위에서 2 [dB] 간격으로 각각 4,000 세트의 신호를 생성한다. 따라서, 각 SNR 별로 순환신경망에 입력되는 테스트 신호는 총  $4,000 \times 31 = 124,000$ 개이며, 각 채널 별 PU 신호의 존재 확률은 역시 50%로 생성한다.

제안하는 스펙트럼 센싱 기법의 성능을 검증하기 위해 두 가지 오류 지표를 설정한다. 첫 번째로 PU 채널이 비어있는데 사용 중이라고 판정하는 경우를 놓친 검출 (miss detection)이라 하고, 두 번째로 PU 채널이 사용 중인데 비어있다고 판정하는 경우를 검출 오류(false detection)라고 한다. 그리고 오류 비율을 각각 MDR (miss detection ratio), FDR (false detectio ratio)이라고 나타낸다. 스펙트럼 센싱 관점에서 PU가 할당받은 주파




Fig. 6 Learning curve of the proposed RNN-based technique

수를 사용 중인데 비어있다고 판정하는 경우는 간섭 문제를 일으킬 수 있으므로 FDR을 최소화하는 것이 중요하다. 즉, PU 채널이 비어 있는 상황을 제대로 인지하지 못할 확률인 MDR보다는 FDR 성능이 더 중요하다고 볼 수 있다.

#### 4.2. 모의실험 결과

그림 7은 세 가지 기법의 MDR, FDR 성능을 비교한다. 이때 성능을 비교하기 위한 테스트 신호는 세 기법 모두 동일한 신호를 사용한다. 기존기법의 문턱값  $\lambda$ 은 수식 (7)에 의해 결정되며  $\alpha$ 는 최적의 성능을 나타내기 위해 표 1과 같이 SNR 구간별로 다르게 설정했다. 모의 실험 결과에 따르면 합성곱 신경망 기법과 제안 기법과의 성능은 거의 유사한 것을 알 수 있다. 합성곱 신경망과 순환신경망은 구조가 전혀 다름에도 불구하고 두 기법이 유사한 성능을 보인다. 하지만 기존 문턱값 기반 기법은 약 2 [dB] 이상의 성능 열화가 발생하는 것을 확인할 수 있다.

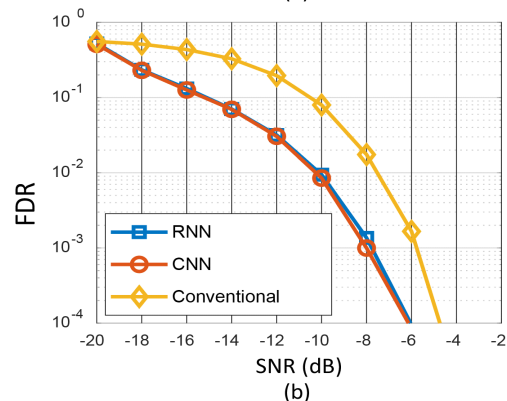
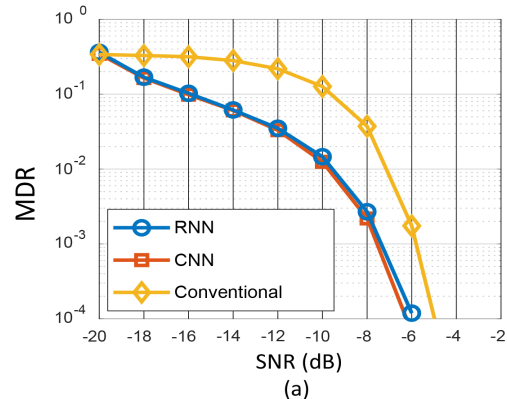



Fig. 7 Simulation results (a) MDR (b) FDR

**Table. 1**  $\alpha$  for each SNR range

SNR Range	$\alpha$
$SNR \leq -13 \text{ dB}$	1.01
$-8 \text{ dB} > SNR \geq -13 \text{ dB}$	1.04
$-2 \text{ dB} > SNR \geq -8 \text{ dB}$	1.20
$5 \text{ dB} > SNR \geq -2 \text{ dB}$	1.83
$SNR \geq 5 \text{ dB}$	2.60

### V. 필드실험

본 논문에서 제안하는 기법의 실제 필드 성능을 검증하고자 실내 환경에서 필드 실험을 수행한다. 그림 8은 실험장의 단면도를 나타낸다. 실험은 송수신기가 서로 보이지 않는 비가시선 (non line-of-sight) 환경에서 진행한다. 송신기와 수신기는 모서리로부터 각각 2 m 떨어진 위치에 고정한 후 송신기의 전력을 가변하면서 수신기에서 신호를 수집한다. 이렇게 수집된 신호에 기존 및 제안하는 스펙트럼 센싱 기법을 적용하여 성능을 평가한다.



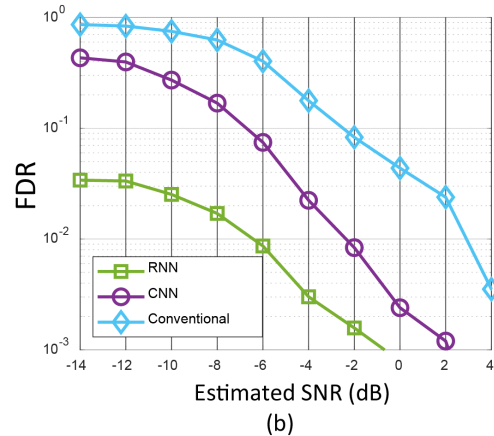

**Fig. 8** Sectional view of indoor experiment environment



**Fig. 9** Picture of experiment environment

그림 9는 실험장 사진을 보인다. 성능 검증을 위한 실험 데이터는 SNR= -14 [dB]에서 8 [dB]까지 2 [dB] 간격으로 각 55,000개씩 총 660,000개를 수집한다. 여기서 SNR은 정확한 값을 알 수 없으므로 스펙트럼 분석기를 통해 추정된 값이다. SNR 8 [dB]는 스펙트럼 분석기를 통해 비교적 쉽게 관측이 가능하다. 이 상황을 기준으로 송신기의 출력을 2 [dB] 씩 낮춰가며 SNR=-14 [dB]까지 신호를 수집하였다. 실험 시 반송파 주파수는 비면허 대역인 2.4 GHz를 사용하였다.

그림 10은 수집한 실험 데이터에 세 가지 기법을 적용하여 얻은 성능을 나타낸다. 이때 기존의 합성곱 신경망 기법 및 제안하는 순환신경망 기법은 3-2와 3-3에서 모의실험으로 학습한 신경망을 그대로 적용한다. 즉, 실험을 통해 얻은 데이터는 신경망 학습에 전혀 사용하지 않았다. 기존 문턱값 기반 기법은 SNR을 추정해야 하므로 PU 신호가 존재하는 임의의 채널 상태 하나를 알고



**Fig. 10** Experiment results (a) MDR (b) FDR

있다는 가정하에 SNR 추정을 수행한다. 그림 10-(a)의 결과에 따르면 MDR 성능은 제안 기법이 기존 문턱값 기반 기법보다 약 1 [dB] 정도의 우수하며 기존 합성곱 신경망 기법과는 유사한 성능을 나타낸다. 하지만 그림 10-(b)의 FDR 성능을 비교하면 제안하는 순환신경망 기법이 기존 문턱값 기법보다 약 8 [dB] 이상 우수하고 기존 합성곱 신경망 기법보다도 약 3 [dB] 이상 우수하다.

## VI. 결 론

본 논문에서는 인지 무선 통신을 위한 새로운 순환 신경망 기반의 스펙트럼 센싱 기법을 제안하였다. 제안하는 기법은 PU가 한 채널을 할당하지 않는다는 가정하에 각 센싱 채널별로 시간에 따른 스펙트럼을 순환신경망에 입력하여 PU 신호 존재 유무를 판단한다. 본 논문에서는 성능 분석을 위해 기존 방식과 제안 방식을 비교, 분석하였다. 모의실험을 통한 성능 비교에서는 제안 기법이 기존 합성곱 신경망 방식과는 성능 차이가 거의 없었으나 필드 실험 결과에 따르면 기존 합성곱 신경망 기반의 기법보다도 약 4 [dB] 이상 우수한 것을 확인할 수 있었다. 제안하는 기법은 SNR, 잡음전력 등 사전정보를 필요로 하지 않지만 PU가 한 채널을 비워야 하기 때문에 이에 따른 스펙트럼 손실은 발생한다. 하지만 이전 연구보다 FDR의 성능이 우수하여, 인지통신에 제안하는 스펙트럼 센싱이 적용된다면 PU에 미치는 간섭을 줄이면서도 스펙트럼 사용 효율을 높일 수 있을 것으로 기대한다.

## REFERENCES

[ 1 ] J. Mitola and G. Q. Maguire, "Cognitive radio: making software radios more personal," *IEEE personal communications*, vol. 6, no. 4, pp. 13-18, Aug. 1999.

[ 2 ] S. Kapoor, S. Rao, and C. Singh, "Opportunistic spectrum sensing by employing matched filter in cognitive radio network," in *IEEE Proceeding of International Conference on Communication Systems and Network Technologies*, Katra, Jammu, India, pp. 580-583, Jun. 2011.

[ 3 ] U. Salama, P. L. Sarker, and A. Chakrabarty, "Enhanced energy detection using matched filter for spectrum sensing

in cognitive radio networks," in *IEEE Proceeding of the 7th International Conference on Informatics, Electronics & Vision and 2nd International Conference on Imaging, Vision & Pattern Recognition*, Kitakyushu, Japan, pp. 185-190, Feb. 2018.

[ 4 ] X. Liu, F. Li, and Z. Na, "Optimal resource allocation in simultaneous cooperative spectrum sensing and energy harvesting for multichannel cognitive radio," *IEEE Access*, vol. 5, pp. 3801-3812, Mar. 2017.

[ 5 ] M. Lopez-Benitez and F. Casadevall, "Improved energy detection spectrum sensing for cognitive radio," *IET Communications*, vol. 6, no. 8, pp. 785-796, May 2012.

[ 6 ] B. Gajera, D. K. Patel, B. Soni, and M. Lopez-Benitez, "Performance evaluation of improved energy detection under signal and noise uncertainties in cognitive radio networks," in *IEEE Proceeding of International Conference on Signals and Systems*, Bandung, Indonesia, pp. 131-137, July 2019.

[ 7 ] R. R. Jaglan, S. Sarowa, R. Mustafa, S. Agrawal, and N. Kumar, "Comparative study of single-user spectrum sensing techniques in cognitive radio networks," *Procedia Computer Science*, vol. 58, no. 1, pp. 121-128, Aug. 2015.

[ 8 ] Y.-J. Tang, Q.-Y. Zhang, and W. Lin, "Artificial neural network based spectrum sensing method for cognitive radio," in *IEEE Proceeding of the 6th International Conference on Wireless Communications Networking and Mobile Computing*, Chengdu, China, pp. 1-4, Sep. 2010.

[ 9 ] M. R. Vyas, D. K. Patel, and M. Lopez-Benitez, "Artificial neural network based hybrid spectrum sensing scheme for cognitive radio," in *IEEE Proceeding of the 28th Annual International Symposium on Personal, Indoor, and Mobile Radio Communications*, Montreal, Canada, pp. 1-7, Oct. 2017.

[ 10 ] N. Balwani, D. K. Patel, B. Soni, and M. Lopez-Benitez, "Long short-term memory based spectrum sensing scheme for cognitive radio," in *IEEE Proceeding of the 30th Annual International Symposium on Personal, Indoor and Mobile Radio Communications*, Istanbul, Turkey, pp. 1-6, Sep. 2019.

[ 11 ] K. Greff, R. K. Srivastava, J. Koutnik, B. R. Steunebrink, and J. Schmidhuber, "LSTM: A search space odyssey," *IEEE transactions on neural networks and learning systems*, vol. 28, no. 10, pp. 2222-2232, Oct. 2017.

[ 12 ] T.-Y. Jung, E.-S. Lee, D.-K. Kim, J.-M. Oh, W.-Y. Noh, and E.-R. Jeong, "CNN based spectrum sensing technique for cognitive radio communications," *Journal of the Korea Institute of Information and Communication Engineering*, vol. 24, no. 2, pp. 276-284, Feb. 2020.





**정태윤(Tae-Yun Jung)**

한밭대학교 정보통신공학과 학사 (2019)  
한밭대학교 모바일융합공학과 석사과정 (현재)  
※관심분야: 디지털 신호처리, 딥러닝



**정의림(Eui-Rim Jeong)**

한국과학기술원 전기 및 전자 공학과 학사 (1995)  
한국과학기술원 전기 및 전자 공학과 석사 (1997)  
한국과학기술원 전자 전산학과 박사 (2001)  
한밭대학교 정보통신공학과 교수 (현재)  
※관심분야: 모델 설계, 통신신호처리, 딥러닝