

# 신경망 기반의 신호 천이 고속 분류 연구

장 연 수\*

## Study for Fast Classification of Signal Transient based on Neural Network

Yeon-Soo Jang\*

### 요 약

인지 무선 통신 시스템에서는 가변적인 스펙트럼 재사용을 위해 개별 통신 객체를 분류하는 능력이 요구된다. 송신되는 통신 신호의 초기 구간인 천이 신호의 특성을 분석하면 개별 송신기를 분류할 수 있으며, 실시간으로 운용되기 위해서는 낮은 계산 복잡도를 갖고 고속의 분류가 가능해야 한다. 본 논문에서는 신경망 기반의 통신 신호 천이 고속 분류 방법을 제안한다. 분류기의 복잡도를 낮추면서 처리 속도를 향상시키기 위해 전처리 없이 통신 신호 천이 구간의 샘플을 사용하고 단순한 형태의 신경망을 적용한다. 상승 코사인 및 제곱근 상승 코사인 천이 타입을 포함하여 12가지 종류의 천이 타입에 대한 분류를 수행한다. 컴퓨터 모의실험을 통해 제안하는 방법이 신호 대 잡음비 10 dB에서 99%의 분류 정확도를 나타내는 것을 확인하였다. 그리고 제안하는 방법은 매 클럭당 12번의 곱셈을 수행하는 구조이므로, 낮은 계산 복잡도를 갖는 것으로 분석되었다.

### Abstract

In cognitive radio communication systems, classification ability is required for an individual communication device for adaptive reuse of spectrum. If characteristics of a transient signal that is the initial duration of a transmitted communication signal can be analyzed, we can classify the individual transmitter. For a real-time operation, a fast classification with low complexity should be available. We propose a fast classification method of a communication signal transient based on a neural network. To improve the processing speed of the classifier with low complexity, we use transient samples of the communication signal without preprocessing and adopt a simple neural network structure. Classification is performed for twelve transient types including raised-cosine and square-root raised-cosine shapes. Through computer simulation, it was confirmed that the proposed method showed a classification accuracy of 99% at a signal-to-noise ratio of 10 dB. Furthermore, because the proposed method has a structure in which multiplication is performed 12 times per clock, it was analyzed as having low computational complexity.

### Keywords

communication signal transient, computational complexity, fast classification, machine learning, neural network

\* 국방과학연구소 레이더/전자전기술센터  
- ORCID: <https://orcid.org/0000-0002-5401-303X>

• Received: Mar. 24, 2022, Revised: Apr. 13, 2022, Accepted: Apr. 16, 2022  
• Corresponding Author: Yeon-Soo Jang  
Radar and Electronic Warfare Technology Center, Agency for Defense Development, Daejeon, Korea.  
Tel.: +82-42-821-0902, Email: [ysjang83@gmail.com](mailto:ysjang83@gmail.com)

## I. 서 론

현대의 이동통신 시스템에서는 수많은 객체가 동시에 통신을 수행하고 있다. 통신 신호의 밀집도가 높은 무선 환경에서 제한된 주파수 자원의 효율을 극대화하기 위한 인지 무선(Cognitive radio) 기술이 활발하게 연구되고 있다[1][2]. 인지 무선은 실시간으로 해당 영역에서 사용 중인 스펙트럼을 탐지하고 식별하여, 가변적으로 통신 링크를 운용함으로써 통신 효율성을 향상시킬 수 있는 기술이다. 이러한 인지 무선에서 요구되는 핵심능력은 실시간으로 신호를 수집하여 분류하는 것이다.

통신 신호를 분류하기 위해 수집된 데이터로부터 특성 인자를 추출하여 분석하는 접근 방법이 고려되었다. 통신 시스템에서는 효과적으로 정보를 전달하기 위해 다양한 변조 방식을 사용한다. 변조 방식은 위상 변조, 주파수 변조, 진폭 변조 등 매우 다양하며, 변조 방식을 분석하고 분류하는 여러 연구가 진행되었다[3]-[7]. 변조 특성을 분석하여 통신 신호를 분류하는 방법은 동일 변조 방식을 사용하는 통신 신호의 경우 구별이 어려울 수 있다. 또한 스펙트럼의 통계적 특성을 분석하여 통신 신호를 분류하는 연구가 진행되었다[7]-[9]. 스펙트럼의 통계적 특성 연구는 주로 신호의 Cyclostationary 성분을 다양하게 분석하여 수행되었다. 정확한 통계적 특성을 얻기 위해서는 추출하고자하는 특성 인자에 따라 특정 길이 이상의 수집 신호가 필요하며 통계적 특성 인자를 추출하기 위한 전처리 과정이 필요하다. 추가적인 연산이 소요되는 특성 인자 추출 과정을 생략하고 구현 복잡도가 낮은 분류 방법이 제시된다면 통신 신호 출현과 동시에 고속의 통신 신호 분류가 가능할 것이다.

특성 인자 추출 등 수신 신호에 대한 전처리를 하지 않고 샘플값을 그대로 사용할 경우, 통신 신호 분류 시간을 감소시킬 수 있다. 수신 신호의 샘플값을 심층 신경망(DNN, Deep Neural Network) 또는 컨볼루션 신경망(CNN, Convolutional Neural Network)에 적용하여 전자파 신호원을 분류하는 연구가 진행되었다[10]-[13]. 관련 기존 연구는 분류 시간 감소보다는 분류 정확도 향상에 초점을 두어 진행하였기 때문에 충분한 길이의 수신 데이터를 이용하

고 계층 및 노드의 수가 많은 모델을 적용하고 있다. CNN은 패턴 분류 분야에서 매우 우수한 성능을 나타내지만, 계층 사이에 컨볼루션 및 풀링 연산 등을 수행해야하므로 요구되는 연산량이 많고 소요 시간이 길다. DNN은 CNN과 같이 계층 사이에 추가적인 연산이 필요하지는 않지만, 다수의 계층과 노드를 적용하므로 DNN 역시 통신 신호에 대한 실시간 고속 분류에 적용하기에는 계산 복잡도 및 소요시간이 적지 않다. 본 논문에서 실시간은 통신 신호가 발생했을 때, 상승 구간(Rising time)이 끝나고 데이터 스트림이 시작되기 이전에 분류 결과를 출력하는 것으로 정의한다.

수신 통신 신호에 실시간 대응 가능한 분류 기술을 위해서는 전처리 과정 없이 수신 샘플을 있는 그대로 분류기에 입력하되 그 중에서도 통신 신호의 시작 천이 구간을 사용하고, 계층 수 및 노드 수를 최소화시킨 신경망 모델을 적용할 필요가 있다. 본 논문에서는 천이 구간을 이용하여 통신 신호를 고속으로 분류할 수 있는 신경망 모델을 연구한다. 그리고 제안하는 신경망 기반의 분류기 성능 및 계산 복잡도를 분석한다. 본 논문의 구성은 다음과 같다. 2장에서는 다양한 통신 신호 천이 모델을 설명하고 분류하고자 하는 클래스를 소개한다. 3장에서는 통신 신호 천이 고속 분류를 위한 신경망을 제안한다. 4장에서는 제안하는 신경망의 분류 성능 및 계산 복잡도를 분석한다. 그리고 5장에서 끝맺는다.

## II. 통신 신호 천이 모델

통신 신호 천이 구간은 그 형태 및 상승 시간에 따라 다양하게 나타날 수 있다. 천이 형태는 RC (Raised-Cosine) 펄스 형태, SRRC(Square-Root Raised-Cosine) 펄스 형태, Nyquist 펄스 형태, Linear 펄스 형태 등을 가질 수 있다. RC 펄스의 임펄스 응답은 아래와 같이 표현된다[14].

$$h_{RC}(t) = \frac{\sin(\frac{\pi t}{T}) \cos(\frac{\pi \alpha t}{T})}{\frac{\pi t}{T} \left(1 - \frac{4\alpha^2 t^2}{T^2}\right)} \quad (1)$$

여기서  $T$ 는 임펄스 응답이 0과 교차하는 시점이고,

$\alpha$ 는 Roll-off factor이다. 펄스 천이 부분에서  $T$ 가 작을수록 천이 구간은 가파르게 상승하게 된다. RC 펄스의 임펄스 응답을 그림 1에 나타내었다.

그림 1에는  $T=20$ , Roll-off factor가 0.5와 0.75인 경우를 나타내었으며, Roll-off factor가 클수록 시간 영역에서 퍼지는 정도가 작지만, 차지하는 주파수 영역이 증가하게 된다.

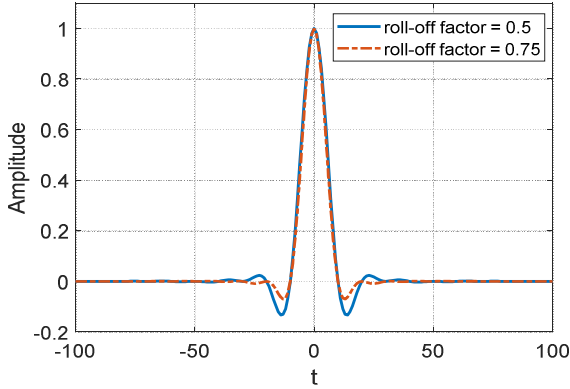


그림 1. RC 펄스의 임펄스 응답  
Fig. 1. Impulse response of RC pulse

SRRC 펄스의 임펄스 응답은 아래와 같이 표현된다[14].

$$h_{SRRC}(t) = \frac{\sin\left((1-\alpha)\frac{\pi t}{T}\right) + \frac{4\alpha t}{T} \cos\left((1+\alpha)\frac{\pi t}{T}\right)}{\sqrt{T} \left(1 - \left(\frac{4\alpha t}{T}\right)^2\right)} \quad (2)$$

SRRC 펄스의 임펄스 응답을 그림 2에 나타내었다.

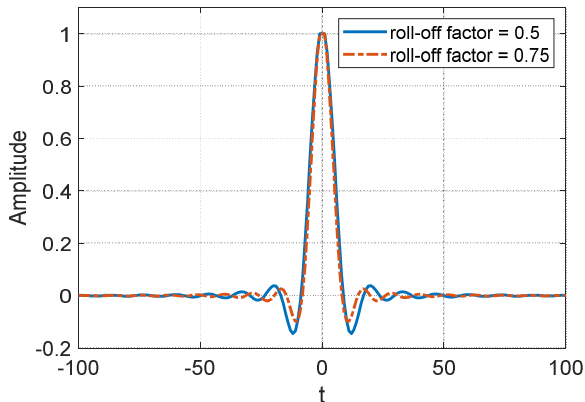


그림 2. SRRC 펄스의 임펄스 응답  
Fig. 2. Impulse response of SRRC pulse

그림 2에는  $T=20$ , Roll-off factor가 0.5와 0.75인 경우를 나타내었으며, SRRC의 임펄스 응답은 RC의 임펄스 응답과는 달리  $T$ 의 배수에서 그 값이 0이 되지 않는다.

Nyquist 펄스의 임펄스 응답은 아래와 같이 표현된다[14].

$$h_{Nyq}(t) = \frac{\sin\left(\frac{\pi t}{T}\right)}{\frac{\pi t}{T}} \quad (3)$$

Nyquist 펄스는 RC 펄스의 Roll-off factor가 0인 경우와 동일하다. Nyquist 펄스의 임펄스 응답을 그림 3에 나타내었다.




그림 3. 나이퀴스트 펄스의 임펄스 응답  
Fig. 3. Impulse response of Nyquist pulse

Linear 펄스의 임펄스 응답은 아래와 같이 표현된다.

$$h_{Lin}(t) = \begin{cases} 1 & \text{for } -T/2 \leq t \leq T/2 \\ 0 & \text{for } t > T/2, t < -T/2 \end{cases} \quad (4)$$

Linear 펄스의 임펄스 응답을 그림 4에 나타내었다. 본 논문에서는 천이 형태와 상승 시간을 조합하여 12개의 클래스를 생성하고 분류한다. 표 1에는 대상 클래스 목록을 나타내었다.

본 논문에서 수신 시스템은 500kHz의 기저대역 샘플율을 갖는 것으로 가정하였고 각 통신 신호 천이에 대한 수집 시간 및 길이는 200us와 100샘플로 설정하였다.




그림 4. 선형 펄스의 임펄스 응답  
Fig. 4. Impulse response of linear pulse

표 1. 대상 클래스 목록  
Table 1. Target class list

Class number	Transient type	Rising time(us)	Roll-off factor
Class 1	Linear	20	-
Class 2	Linear	40	-
Class 3	Nyquist	20	-
Class 4	Nyquist	40	-
Class 5	RC	20	0.5
Class 6	RC	40	0.5
Class 7	RC	20	0.75
Class 8	RC	40	0.75
Class 9	SRRC	20	0.5
Class 10	SRRC	40	0.5
Class 11	SRRC	20	0.75
Class 12	SRRC	40	0.75

천이 구간은 짧은 시간 동안 발생하므로 데이터 수집 타이밍이 일정하지 않을 수 있다. 그러므로 데이터는 수집 타이밍이 -10us에서 +10us로 랜덤하게 변하는 것을 가정하였다.

### III. 신경망 기반의 천이 분류기

통신 신호 천이 구간에 대한 고속 분류를 위한 신경망을 구성하고 그에 대한 학습 결과를 소개한다. 소요 시간 및 연산량이 최소화된 분류기 구현을 위해 천이구간 샘플값을 신경망 입력으로 사용하기 때문에 입력 노드 개수는 100개이며, 출력 노드 개수는 클래스 개수와 동일한 12개이다. 활성화 함수는 Sigmoid 함수를 적용하였다. 제안하는 신경망 구조는 그림 5와 같다.

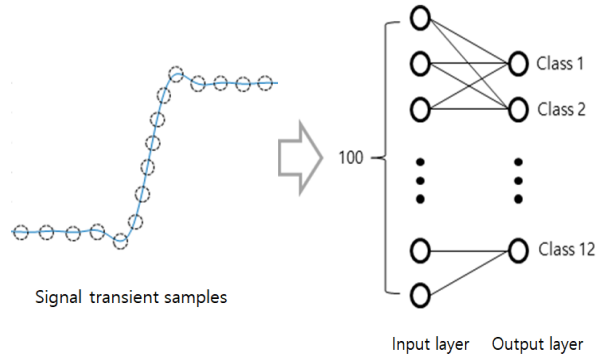


그림 5. 제안하는 신경망 구조  
Fig. 5. Proposed neural network structure

각 입력 노드에는 해당 샘플값이 순차적으로 입력된다. 학습 데이터는 잡음을 신호 대 잡음비(SNR, Signal-to-Noise Ratio)에 따라 랜덤하게 생성하여 원 신호에 더한 데이터를 사용하였고, 총 1200개의 데이터를 이용하여 학습 및 검증하였다. 구성된 데이터 중 10%를 검증 데이터로 설정하였다. 그림 6에는 class 5를 위한 학습데이터를 예로 나타내었다.




그림 6. 5번째 클래스를 위한 학습데이터 예  
Fig. 6. Learning data example for class 5

그림 6에 나타난 데이터는 SNR 15dB를 설정하여 적용한 학습 데이터이다. 구성된 신경망의 분류 성능은 학습 데이터의 SNR에 따라 성능이 달라질 수 있다. 4장에서는 학습 데이터의 SNR에 따른 분류기 성능을 나타낸다.

학습을 통해 각 노드 간 가중치와 바이어스에 대한 계수값을 얻을 수 있고 이 계수값을 적용하여, 분류기를 운용할 수 있다. 입력 노드 개수가 100개이고 출력 노드 개수가 12개이므로 각 노드를 연결하는 총 가중치는 1,200개가 필요하다. 펄스의 천이

신호는 시간 순차적으로 입력된다. 그러므로 입력되는 신호에 대한 가중치 연산을 순차적으로 수행하면, FPGA(Field Programmable Gate Array) 등과 같은 하드웨어에서 구현 가능한 수준으로 실시간 연산이 가능하다.

그림 7에는 순차적인 입력신호에 대한 분류기 연산 과정을 예시로 나타내었다. 설명의 편의를 위해 입력 노드의 개수가 5개이고 대상 클래스가 3개인 신경망을 가정하였다.  $h$ 번째 입력 노드에 대한  $k$ 번째 출력 노드 사이의 가중치를  $w_{h,k}$ 라고 가정한다. 1번째 입력 신호가 수신되었을 때, 해당 클럭에서는 입력신호와  $w_{1,1}, w_{1,2}, w_{1,3}$ 의 곱셈이 이루어지고 출력 노드 변수에 그 값을 저장한다. 2번째 입력 신호가 수신되었을 때, 해당 클럭에서는 입력신호와  $w_{2,1}, w_{2,2}, w_{2,3}$ 의 곱셈이 이루어지고 출력 노드 변수에 누적한다. 이와 같은 연산 방법을 제안하는 신경망에 적용할 경우, 매 클럭 당 12번의 곱셈을 수행하여 그 값을 누적하고 마지막 곱셈이 끝나면, 바이어스 값 12개를 합하여, 가장 큰 값을 갖는 출력을 선택한다.




그림 7. 분류기 연산 과정  
Fig. 7. Operation process of classifier

#### IV. 성능 및 계산 복잡도 분석

본 장에서는 제안하는 천이 분류기의 성능과 계산 복잡도를 분석한다.

##### 4.1 분류 성능 분석

분류기의 성능은 Confusion matrix로 나타낼 수 있다. 12개 클래스에 대한 분류 성능을 SNR 별로 나타내었다. 우선, SNR이 0dB 학습 데이터로 학습시킨 분류기를 대상으로 테스트 데이터의 수신

SNR이 각각 10dB, 15dB일 때, 성능을 구한다. 그림 8에는 테스트 데이터의 SNR이 10dB일 때, 그림 9에는 테스트 데이터의 SNR이 15dB일 때, Confusion matrix 결과를 각각 나타내었다. 테스트 데이터는 각 클래스 별로 110개를 할당하였다. 그림 8과 그림 9의 결과에서 알 수 있듯이, 제안하는 분류기가 테스트 데이터를 SNR 10dB 이상에서 95%이상으로 분류하는 것을 확인할 수 있다.

구성된 신경망의 분류 성능은 학습 데이터의 SNR에 따라 성능이 달라질 수 있다. 그림 10에는 학습 데이터의 SNR을 -20dB에서 10dB까지 변화시키며 학습시킨 분류기에 테스트 데이터의 SNR 범위 0 ~ 30dB에 대한 분류 정확도를 나타내었다.

	#1	#2	#3	#4	#5	#6	#7	#8	#9	#10	#11	#12
#1	108	0	0	0	0	0	0	1	0	0	1	0
#2	0	109	0	0	0	0	1	0	0	0	0	0
#3	0	1	109	0	0	0	0	0	0	0	0	0
#4	0	1	0	106	0	0	1	1	0	0	0	1
#5	0	0	0	0	110	0	0	0	0	0	0	0
#6	0	0	0	0	0	110	0	0	0	0	0	0
#7	0	0	0	1	0	0	109	0	0	0	0	0
#8	0	0	0	0	0	0	0	110	0	0	0	0
#9	0	1	0	0	0	0	1	0	107	0	0	1
#10	0	0	0	0	0	0	0	0	0	110	0	0
#11	0	0	0	0	1	0	0	0	1	0	108	0
#12	0	1	0	0	0	0	0	0	0	0	0	109

그림 8. 오차 행렬 (SNR = 10dB)  
Fig. 8. Confusion matrix (SNR = 10dB)

	#1	#2	#3	#4	#5	#6	#7	#8	#9	#10	#11	#12
#1	110	0	0	0	0	0	0	0	0	0	0	0
#2	0	110	0	0	0	0	0	0	0	0	0	0
#3	0	0	110	0	0	0	0	0	0	0	0	0
#4	0	0	0	110	0	0	0	0	0	0	0	0
#5	0	0	0	0	110	0	0	0	0	0	0	0
#6	0	0	0	0	0	110	0	0	0	0	0	0
#7	0	0	0	0	0	0	110	0	0	0	0	0
#8	0	0	0	0	0	0	0	110	0	0	0	0
#9	0	0	0	0	0	0	0	0	110	0	0	0
#10	0	0	0	0	0	0	0	0	0	110	0	0
#11	0	0	0	0	0	0	0	0	0	0	110	0
#12	0	0	0	0	0	0	0	0	0	0	0	110

그림 9. 오차 행렬 (SNR = 15dB)  
Fig. 9. Confusion matrix (SNR = 15dB)

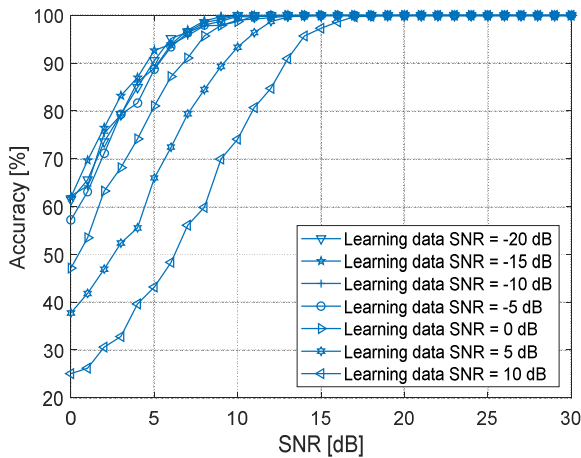


그림 10. 신호 대 잡음비에 따른 분류 정확도  
Fig. 10. Accuracy of classification for SNR

신경망을 학습시킬 때, 잡음을 첨가하는 Denosing 기법이 잡음 환경에서 분류 성능을 향상시키는 것으로 알려져 있다. 본 논문의 시뮬레이션 결과에서도 학습 데이터의 SNR을 약 -15dB 정도로 설정하였을 때, 높은 분류 성능이 나타나는 것을 확인할 수 있다. 그림 10에서 확인할 수 있듯이, 학습 데이터의 SNR이 약 -15dB일 때, 분류 성능은 테스트 데이터의 SNR이 5dB일 때, 90% 이상, 테스트 데이터의 SNR이 10dB일 때, 99% 이상으로 나타난다. 이를 통해 제안하는 분류 방법이 잡음이 존재하는 상황에서도 대상을 분류하는 것을 검증하였다.

[12]에서 제안된 DNN기반의 분류기는 서로 다른 I/Q 불균형 특성을 이용하여 8종의 송신 신호에 대해 약 95%의 분류 정확도를 나타내었다. [13]에서는 6종의 ZigBee 송신 신호를 모의하여 DNN을 이용한 분류기로 약 96%의 분류 정확도를 나타내었다. 본 논문에서 제안하는 방법은 12종의 신호 천이 형태에 대해 SNR 7dB 이상에서 95% 이상의 분류 정확도를 보이므로, 분류 성능 측면에서는 기존 연구 결과와 유사한 수준을 보인다.

#### 4.2 계산 복잡도 분석

3장에서 설명된 바와 같이 펄스열이 수신되면 순차적으로, 해당 노드 간 가중치와 곱해진다. 즉, 매 입력 샘플마다 12번의 곱셈이 이루어지고, 12개의 저장 공간에 저장된다. 100샘플이 모두 입력되면

1,200번의 곱셈연산이 이루어진다. 각 출력 노드의 바이어스 값 12개가 더해져서 최종 출력 노드의 값들이 정해진다. 제안하는 신경망 기반의 분류기는 한 번의 분류를 위해 총 곱셈 1,200번, 덧셈 12번이 필요하며, 곱셈 연산은 입력 샘플에 따라 순차적으로 12번씩 100회에 걸쳐 분산하여 처리할 수 있다. 이러한 분류기의 연산량을 보았을 때, 학습된 분류기는 상용 FPGA 등에서 구현 가능할 것으로 기대된다.

[12]에서 제안된 DNN 분류기 모델은 2048개의 입력, 2개의 은닉층, 8개의 출력을 갖는다. 은닉층은 각각 1024개 및 512개의 노드를 갖고 드롭아웃 (Dropout) 비율은 0.5이다. 따라서 한 번의 분류를 수행하기 위해서는 약  $2 \times 10^9$ 번의 곱셈이 요구된다. [13]에서 제안된 DNN 분류기 모델은 32개의 입력, 3개의 은닉층, 6개의 출력을 갖고 은닉층은 각각 256개, 256개, 128개의 노드를 갖는다. 따라서 한 번의 분류를 수행하기 위해서는 약  $1.5 \times 10^9$ 번의 곱셈이 요구된다. 본 논문에서 제안하는 방법은 한 번의 분류를 위해  $10^3$ 단위의 곱셈이 필요하므로, 계산 복잡도 측면에서 매우 효율적이라고 판단되어진다.

## V. 결 론

본 논문에서는 천이 구간을 이용하여 통신 신호를 고속으로 식별하기 위해 계산 복잡도가 낮은 신경망 모델을 제안하였다. 제안하는 신경망 모델은 수집된 샘플값을 전처리 없이 입력하고, 순차적으로 수신되는 신호의 입력 샘플마다 신경망 연산을 수행하여 누적하는 방식으로 마지막 샘플값이 입력되는 동시에 분류 결과가 얻어질 수 있다. 그리고 제안하는 신경망 기반의 분류기 성능을 12개의 클래스에 대해 SNR에 따라 분석하여, 제안하는 분류기가 잡음이 존재하는 환경에서도 높은 분류 정확도를 나타내는 것을 확인하였다.

특히, 제안하는 신경망은 학습 데이터의 SNR이 -15dB일 때, 테스트 데이터의 SNR이 10dB에서 99% 이상의 분류 성능을 보이는 것을 시뮬레이션을 통해 확인하였다. 또한, 곱셈 및 덧셈 연산량을 바탕으로 구현 복잡도를 분석하였다. 제안하는 방법은

무선 인지 통신 시스템 및 광대역 스펙트럼 감시 시스템 등에서 초기에 빠르게 신호를 탐지하고 식별하는 과정에 활용도가 높을 것으로 기대된다. 또한, 추후 본 논문에서 발전된 연구로써, 잡음이 심한 환경에서 수집 타이밍의 변화가 클 때, 성능을 확보할 수 있는 고도화된 알고리즘에 대한 연구를 고려할 수 있을 것이다.

## References

- [1] Y. Liang, K. Chen, G. Y. Li, and P. Mahonen, "Cognitive radio networking and communications: an overview", *IEEE Transactions on Vehicular Technology*, Vol. 60, No. 7, pp. 3386-3407, Sep. 2011. <https://doi.org/10.1109/TVT.2011.2158673>.
- [2] P. Pawelczak, K. Nolan, L. Doyle, S. W. Oh, and D. Cabric, "Cognitive radio: Ten years of experimentation and development", *IEEE Communications Magazine*, Vol. 49, No. 3, pp. 90-100, Mar. 2011. <https://doi.org/10.1109/MCOM.2011.5723805>.
- [3] M. V. Subbarao and P. Samundiswary, "Automatic modulation recognition in cognitive radio receivers using multi-order cumulants and decision trees", *International Journal of Recent Technology and Engineering*, Vol. 7, No. 4, pp. 61-69, Nov. 2018.
- [4] B. Ramkumar, "Automatic modulation classification for cognitive radios using cyclic feature detection", *IEEE Circuits and Systems Magazine*, Vol. 9, No. 2, pp. 27-45, Jun. 2009. <https://doi.org/10.1109/MCAS.2008.931739>.
- [5] O. A. Dobre, M. Oner, S. Rajan, and R. Inkol, "Cyclostationarity-based robust algorithms for QAM signal identification", *IEEE Communication Letters*, Vol. 16, No. 1, pp. 12-15, Jan. 2012. <https://doi.org/10.1109/LCOMM.2011.112311.112006>.
- [6] T. E. Bogale and L. Vandendorpe, "Multi-cycle cyclostationary based spectrum sensing algorithm for OFDM signals with noise uncertainty in cognitive radio networks", in *Proc. IEEE Military Communications Conference (MILCOM)*, pp. 1-6, Oct. 2012. <https://doi.org/10.1109/MILCOM.2012.64157046>.
- [7] J. Lee, J. Kim, B. Kim, D. Yoon, and J. Choi, "High performance automatic modulation recognition technique for fading channels based on deep learning", *Journal of Korean Institute of Information Technology (JKIIT)*, Vol. 16, No. 1, pp. 1-10, Jan. 2018. <https://doi.org/10.14801/jkiit.2018.16.1.1>.
- [8] A. Tani, R. Fantacci, and D. Marabissi, "A low-complexity cyclostationary spectrum sensing for interference avoidance in femtocell LTE-A-based networks", *IEEE Transactions on Vehicular Technology*, Vol. 65, No. 4, pp. 2747-2753, Apr. 2016. <https://doi.org/10.1109/TVT.2015.2419877>.
- [9] O. A. Y. Ojeda, and J. Grajal, "Sensitivity analysis of cyclostationarity-based and radiometric detectors for single-sensor receivers", *IEEE Transactions on Aerospace Electronic Systems*, Vol. 48, No. 1, pp. 27-43, Jan. 2012. <https://doi.org/10.1109/TAES.2012.6129619>.
- [10] 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. <https://doi.org/10.1109/JSTSP.2018.2796446>.
- [11] K. Youssef, L. Bouchard, K. Haigh, J. Silovsky, B. Thapa, and C. V. Valk, "Machine learning approach to RF transmitter identification", *IEEE Journal of Radio Frequency Identification*, Vol. 2, No. 4, pp. 197-205, Dec. 2018. <https://doi.org/10.1109/JRFID.2018.2880457>.
- [12] D. Roy, T. Mukherjee, M. Chatterjee, E. Blasch, and E. Pasilio, "RFAL: Adversarial learning for RF transmitter identification and classification", *IEEE Transactions of Cognitive communications and Networking*, Vol. 6, No. 2, pp. 783-801, Jun.

2020. <https://doi.org/10.1109/TCCN.2019.2948919>.

- [13] H. Jafari, O. Omotere, D. Adesina, H. Wu, and L. Qian, "IoT devices fingerprinting using deep learning", 2018 IEEE Military Communications Conference, pp. 901-906, Oct. 2018. <https://doi.org/10.1109/MILCOM.2018.8599826>.
- [14] I. Hadkhale, "Faster than Nyquist signaling and analysis of its performance under uncoded/coded transmission systems", Master Thesis, University of Oulu, Finland, Mar. 2015.

### 저자소개

장 연 수 (Yeon-Soo Jang)



2009년 2월 : 한양대학교  
전자통신컴퓨터공학부(공학사)  
2015년 2월 : 한양대학교  
전자통신컴퓨터공학과(공학박사)  
2015년 3월 ~ 현재 : 국방과학  
연구소 선임연구원  
관심분야 : 통신이론,  
무선통신시스템, 전자전