

시간-주파수 분석 기법과 딥러닝을 사용한 저피탐 레이다 식별 기술의 정확도와 시간의 Trade-Off

Time and Accuracy Trade-Off of LPI Radar Classification Technology Based on Time-Frequency Analysis and Deep Learning

유준상 · 조윤석 · 김창주* · 최희열 · 김영식

Junsang Yoo · Yun Suk Cho · Chang-Joo Kim* · Heeyul Choi · Youngsik Kim

요 약

저피탐(LPI, low probability of intercept) 레이다 신호를 빠르고 정확하게 식별하는 기술은 인지통신 연구에 중요한 기술이다. 본 논문에서는 시간-주파수 분석(TFA, time-frequency analysis)과 딥러닝을 사용해 12가지 전형적인 레이다 신호를 식별하는 기술을 연구하였다. 기존 CWD(Choi-Williams distribution)를 사용하는 방식은 spectrogram에 비해 500배 이상 긴 TFA 생성 시간이 필요하다. 본 논문에서는 spectrogram, WVD(Wigner-Ville distribution), CWD를 딥러닝 학습 데이터로 사용하여 저피탐 신호의 식별 정확도와 검출 시간의 trade-off를 제시한다. 결과적으로, CWD 모델이 spectrogram 모델보다 정확도는 높고, 예측 시간 약 200배 이상 길었다. 두 모델이 -2 dB 이상의 SNR에서는 1 %p 미만의 정확도 차이를 보였지만, -10 dB에서 7.5 %p의 차이를 보였다. 즉, 낮은 SNR에서 TFA 모델에 따른 예측 시간과 정확도의 확연한 trade-off 관계를 확인하였다.

Abstract

Technology for classifying low probability of intercept (LPI) radar signals with speed and accuracy is critical for cognitive communication research. We used time-frequency analysis (TFA) and deep learning to classify 12 typical LPI radar signals. Traditional methods use the Choi-Williams distribution (CWD), which requires more than 500 times longer TFA generation time than the spectrogram method. In this paper, we show the trade-off relationship between classification accuracy and detection time using a spectrogram, Wigner-Ville distribution (WVD), and CWD as the training datasets. As a result, the CWD model showed higher accuracy than the spectrogram model, but the prediction time was more than 200 times longer. The accuracy difference was only 1 %p for an SNR over -2 dB, but it reached 7.5%p for an SNR of -10 dB. Therefore, a lower SNR shows a distinct trade-off between prediction time and accuracy, depending on the type of TFA.

Key words: Cognitive Radio, Low Probability of Intercept, Autonomous Classification, Deep Learning, Time-Frequency Analysis

「과제번호: 2019-0-00964, 과제명: 스펙트럼 챌린지를 통한 기존 무선국 보호 및 주파수공유 기술개발.」

한동대학교 전산전자공학부(Department of Computer Science and Electronic Engineering, Handong Global University)

*㈜휴라(HURA Co., Ltd)

· Manuscript received November 21, 2022 ; Revised December 28, 2022 ; Accepted January 11, 2023. (ID No. 20221121-017S)

· Corresponding Author: Youngsik Kim (e-mail: young@handong.edu)

I. 연구 배경

현재 사용되는 대역의 주파수 자원이 부족하고, 아직 상용화하지 않은 대역의 주파수 자원의 효율적인 활용 기술을 개발해야 한다. 주파수 자원의 효율적인 분배를 위해서 주파수 공동 사용과 그 정책 및 표준화에 관한 연구를 활발히 진행하고 있다^{[1][2]}. 또한 군 통신망으로 운용되는 대역을 공동 사용하려는 노력이 이루어지고 있다. 군 위성 통신이나 레이더로 사용되는 대역을 1차 사용자인 군 당사자가 보호받는 선에서 공동 사용하려는 것이다^[3]. 원활한 주파수 공동 사용을 위해서 빠르고 정확하게 주변의 전파 환경을 파악하는 인지통신 기술이 필요로 하다. 따라서 주로 군용 장비에서 사용되는 다양한 변조 방식의 저피탐 레이더를 식별하는 기술은 인지통신에 있어서 중요한 기술이다.

기존에 저피탐 레이더 신호 식별을 위해 시간-주파수 분석(TFA, time-frequency analysis)과 딥러닝을 사용하는 모델은 cross-term이 적고, 시간-주파수 해상도가 높은 CWD(Choi-Williams distribution)를 선호하였다^{[4][5]}. 하지만, 연산량이 많은 CWD는 빠르게 주파수 환경을 파악해야 할 때 속도 감소의 요인이 될 수 있다. WVD(Wigner-Ville distribution)는 CWD에 비해 연산량이 적고 시간-주파수 해상도가 우수하지만 cross-term으로 인한 간섭이 존재한다. Spectrogram은 연산량이 적고 cross-term이 없지만 시간-주파수 해상도가 CWD와 WVD에 비해 낮다.

본 논문에서는 spectrogram, WVD, CWD 세 가지 TFA와 CNN(convolutional neural network) 기반의 딥러닝을 사용하여 저피탐 레이더를 식별하는 기술을 구현하고 각각의 TFA를 사용하는 모델 간의 정확도와 연산 속도를 비교 분석하였다.

II. 훈련 데이터 생성

2-1 신호 생성

주로 군사용으로 사용하는 전형적인 12가지 저피탐 레이더 신호를 사용하였다. 이 신호들은 주파수 연속 변조 방식(FMCW, frequency modulation continuous wave), 주파수 도약, 위상 변조 방식을 사용한다. 훈련 데이터를 위해 생성한 신호에 대해 먼저 기술하였다^{[4],[6]}.

FMCW 방식 중에서 선형 주파수 변조(LFM, linear frequency modulation) 신호를 사용하였다. 표 1에서 LFM 신호의 주파수 계산을 위한 식을 기술하였다. 여기서 T 는 생성한 신호의 전체 길이, t 는 순간 시간, f_1 과 f_2 는 각각 시작 주파수와 끝 주파수를 의미한다.

주파수 도약 방식은 길이가 4~6인 Costas 신호를 사용하였다^[7]. 이는 Costas 코드에 따라 주파수를 도약한다. 표 1에서 Costas 신호의 주파수를 계산하였다. 여기서 C 는 Costas 코드, i 는 코드의 인덱스, N 은 코드의 길이, f_1 , f_2 는 각각 최소 주파수와 최대 주파수를 의미한다.

위상 변조 신호는 Barker 신호, Polyphase 신호, Polytime 신호를 사용하였다. Polyphase 신호는 Frank, P1, P2, P3, P4 신호를 사용하였고, Polytime 신호는 T1, T2, T3, T4 신호를 사용하였다.

Barker 신호는 알려진 길이 13 이하의 Barker 코드 중 임의로 선택하여 사용하였다. Barker 신호는 이진 위상 편이 변조 방식(BPSK, binary phase shift keying)을 사용한다. 알려진 Barker 코드는 표 2에 표시되어 있다^[8].

표 1에 polyphase 신호의 위상을 계산하는 식이 포함되어 있다^{[8]~[10]}. 표 1에 포함된 polyphase 신호들은 Frank,

표 1. 저피탐 레이더 신호의 주파수 및 위상
Table 1. Frequency and phase of LPI radar signal.

Modulation type	Frequency	Phase
LFM	$f_1 + \frac{f_2 - f_1}{T} \cdot t$	-
Barker	Constant	Table 2
Costas	$f_1 + \frac{(f_2 - f_1)}{N-1}(c_i - 1)$	-
Frank	Constant	$\frac{2\pi}{N}(i-1)(j-1)$
P1	Constant	$-\frac{\pi}{N}(N-(2j-1))(N(j-1)+(i-1))$
P2	Constant	$\left(\frac{\pi}{2} \cdot \frac{N-1}{N} - \frac{\pi}{N}(i-1)\right)(N+1-2j)$
P3	Constant	$\frac{\pi(i-1)^2}{\rho}$
P4	Constant	$\frac{\pi(i-1)^2}{\rho} - \pi(i-1)$
T1	Constant	$MOD\left[\frac{2\pi}{N} \cdot \int \left[(kt - jT) \frac{2N}{T}, 2\pi \right]$
T2	Constant	$MOD\left[\frac{2\pi}{N} \cdot \int \left[(kt - jT) \frac{2j-k+1}{T} \cdot \frac{N}{2}, 2\pi \right]$
T3	Constant	$MOD\left[\frac{2\pi}{N} \cdot \int \left[\frac{N\Delta F^2}{2T}, 2\pi \right]$
T4	Constant	$MOD\left[\frac{2\pi}{N} \cdot \int \left[\frac{N\Delta F^2}{2T} - \frac{N\Delta F_1}{2}, 2\pi \right]$

표 2. 알려진 Barker 코드
Table 2. Known Barker code.

Code length	Barker code
2	1,-1
3	1,1,-1
4	1,1,-1,1
5	1,1,1,-1,1
7	1,1,1,-1,1,1,-1
11	1,1,1,-1,-1,-1,1,-1,1,-1,1,-1
13	1,1,1,1,1,-1,-1,1,1,-1,1,-1,1,-1,1

P1, P2, P3, P4가 있다. 여기서 ϕ 는 생성한 신호의 위상, N 은 위상 분할의 개수, i 와 j 는 1에서 N 까지 서로 다른 인덱스를 뜻한다. P3, P4에서 ρ 는 펄스 압축비를 의미하며 이전 polyphase 신호의 N^2 과 같다. P3와 P4 신호의 인덱스 i 는 1에서 N 까지가 아닌 1에서 ρ 까지의 인덱스를 의미한다.

표 1의 마지막 4개 신호는 polytime 신호이다. Polytime의 위상을 계산하는 식이 표 1에 기술되어 있다^[11]. 여기서 N 은 위상 분할 개수, T 는 생성한 신호의 길이, k 는 시간 분할 개수, t 는 시간, j 는 시간 분할 인덱스를 의미한다. ΔF 는 사용 주파수 대역을 의미한다.

훈련 데이터 생성을 위해 사용된 변수들의 범위가 표 3에 표시되어 있다. $U[a,b]$ 표기는 a 에서 b 사이의 임의의 실수값을 사용함을 의미한다. $\{a, b, c\}$ 표기는 a, b, c 중 하나의 값을 임의로 사용함을 의미한다. 신호를 생성 후 AWGN(additive white gaussian noise)을 신호에 더하고 사용하였다. 각 SNR과 신호종류에 따라서 1,000개의 데이터를 생성하기 위해 총 120,000($12 \times 10 \times 1,000$)개의 신호를 훈련을 위해 생성하였다. 추가로 LFM과 Costas 신호는 f_1 과 f_2 사이에 $0.05f_s$ 의 최소 이격을 두었다.

2-2 시간-주파수 분석

앞서 서술한 12가지의 저피탐 레이다 신호는 시간이 지남에 따라 특정 패턴으로 위상이 변화하는 공통점을 가지고 있다. TFA를 사용하면 시간에 따른 주파수 성분의 변화를 확인할 수 있다. 따라서 저피탐 레이다 신호 식별을 위해 TFA를 입력으로 사용하였다.

TFA를 위해 실수인 입력 신호를 해석적 신호로 변환

표 3. 훈련 데이터 생성을 위한 확률 변수의 범위
Table 3. Range of random variable for train dataset.

Modulation type	Parameters	Range
Barker	Center frequency	$U[0.05 f_s, 0.45 f_s]$
	Barker code length	$\{3,4,5,7,11,13\}$
LFM	Start frequency	$U[0.05 f_s, 0.45 f_s]$
	Stop frequency	$U[0.05 f_s, 0.45 f_s]$
Costas	Costas code length	$\{3,4,5,6\}$
	Min frequency	$U[0.05 f_s, 0.45 f_s]$
	Max frequency	$U[0.05 f_s, 0.45 f_s]$
Frank, P1	Center frequency	$U[0.05 f_s, 0.45 f_s]$
	Polyphase segments	$\{4,5,6,7,8,9,10\}$
P2	Center frequency	$U[0.05 f_s, 0.45 f_s]$
	Polyphase segments	$\{4,6,8,10\}$
P3, P4	Center frequency	$U[0.05 f_s, 0.45 f_s]$
	Compression ratio	$(\{4,5,6,7,8,9,10\})^2$
T1, T2	Center frequency	$U[0.05 f_s, 0.45 f_s]$
	Time segments	$\{4,5,6,7,8,9,10\}$
	Phase segments	$\{4,5,6,7,8,9,10\}$
T3, T4	Center frequency	$U[0.05 f_s, 0.45 f_s]$
	Bandwidth	$U[0.01 f_s, 0.01 f_s]$
	Phase segments	$\{4,5,6,7,8,9,10\}$
Common	Signal length	1,024
	SNR	$\{-10, -8, -6, -4, -2, 0, 2, 4, 6, 8\}$ dB

한다^[8]. 식 (1)의 힐버트 변환은 푸리에 변환과 역푸리에 변환을 사용한다. 식 (2)를 통해 실수 신호를 복소수 형태의 해석적 신호로 변환할 수 있다. 생성된 해석적 신호는 복소수 형태이고 양의 주파수 성분만을 포함한 신호다.

$$H\{x(t)\} = F^{-1}\{-j\text{sgn}(f)F\{x(t)\}\} \quad (1)$$

$$z(t) = x(t) + jH\{x(t)\} \quad (2)$$

식 (3)~식 (5)는 각각 spectrogram, WVD, CWD를 생성하는 식이다^{[8],[9]}. Spectrogram은 연산량이 적으며, $w(t)$ 윈도우 함수를 통해 cross-term이 줄어든다는 장점이 있다. 하지만, 다른 TFA에 비해 시간-주파수 해상도가 가장 낮다. WVD는 가장 간단한 이차 TFA 형태로 spectrogram에 비해 시간-주파수 해상도가 높지만, cross-term이 존재한

다. CWD는 WVD에 가우시안 커널이 추가된 TFA 방법이다. 식 (5)에 포함된 σ 값을 변경하여 cross-term을 적절히 제거할 수 있다. 본 학습을 위해서는 $\sigma=1$ 을 사용하였다. CWD는 시간-주파수 해상도가 높고, cross-term도 적다. 하지만, 연산량이 다른 TFA에 비해 월등히 많다. 1,024 길이의 신호를 128×128 TFA 이미지로 생성할 때의 소요 시간을 측정하였다. Spectrogram, WVD, CWD 생성 시간이 각각 0.360 ms, 1.780 ms, 207.314 ms로 측정되었다. 연산량이 가장 많은 CWD 생성이 spectrogram 생성에 비해 500배 이상 긴 시간이 소요되었다.

$$SPEC(t, f) = \left| \int z(\tau) w(\tau - t) e^{-j2\pi f\tau} d\tau \right|^2 \quad (3)$$

$$WVD(t, f) = \int z\left(t + \frac{\tau}{2}\right) z^*\left(t - \frac{\tau}{2}\right) e^{-j2\pi f\tau} d\tau \quad (4)$$

$$CWD(t, f) = \iint \frac{\sqrt{\pi\sigma}}{|\tau|} e^{-\frac{\pi^2\sigma(t-u)^2}{\tau^2}} z\left(u + \frac{\tau}{2}\right) z^*\left(u - \frac{\tau}{2}\right) e^{-j2\pi f\tau} du d\tau \quad (5)$$

각 TFA의 특징은 Costas 신호의 TFA를 나타낸 그림 1에서 확인할 수 있다. 이는 FFT의 주파수 구간 개수를 128개로 설정하고, 시간 간격을 적절히 조정하여 인공 신경망을 학습할 때 사용한 128×128 형태로 만든 시간 주파수 분석 이미지이다. 가로축은 시간, 세로축은 주파수를 의미한다. 값이 클수록 노란색에 가깝고, 값이 작을수록 보라색에 가깝다. Spectrogram의 주파수 분해능이 다른 이미지에 비해 낮은 것을 그림 1(a)에서 확인할 수 있다. WVD의 주파수 분해능은 spectrogram에 비해 좋지만, 원하지 않는 cross-term이 보이는 것을 그림 1(b)에서 확인할 수 있다. CWD의 주파수 분해능이 높고 cross-term도 보이지 않는 것을 그림 1(c)에서 확인할 수 있다.

그림 1(d)~그림 1(f)는 그림 1(a)~그림 1(c)의 Costas 신호에 SNR이 0 dB가 되도록 AWGN을 더한 신호의 TFA 이미지이다. 그림 1(d) 및 그림 1(f)에서는 Costas 신호의 주파수 도약 성분을 쉽게 확인할 수 있다. 반면에, 그림 1(e)에서는 WVD의 잡음에서 생기는 cross-term 때문에 Costas 신호의 주파수 도약 성분을 확인하기 어렵다.

III. 인공 신경망 학습

인공 신경망이 시간-주파수 이미지 정보를 효과적으로

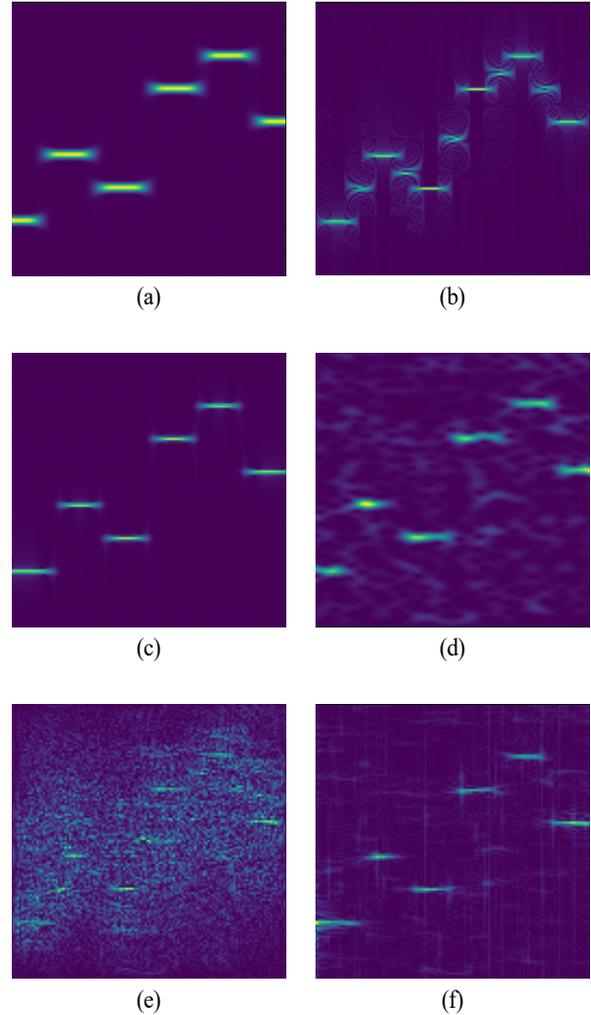


그림 1. Costas 신호의 TFA; (a), (b), (c): 각각 잡음이 없는 Costas 신호의 spectrogram, WVD, CWD; (d), (e), (f): 각각 0 dB SNR의 잡음이 추가된 Costas 신호의 spectrogram, WVD, CWD

Fig. 1. TFA of Costas signal; (a), (b), (c): spectrogram, WVD, CWD of Costas signal without noise; (d), (e), (f): spectrogram, WVD, CWD of 0 dB SNR Costas signal.

사용할 수 있도록 합성곱 신경망 구조를 사용하였다^[4]. 합성곱층과 풀링층으로 이루어진 계층을 총 3개 사용하였다. 이후 총 3개의 완전 연결 계층을 통해 12개의 출력이 나오도록 인공 신경망을 설계하였다. 인공 신경망은 TFA를 입력으로 받아 각각 저피탐 레이더의 종류 중 하나를 선택해야 한다. 인공 신경망의 출력이 각 레이블에

대한 확률의 의미가 되도록 인공 신경망의 출력층에 softmax 함수를 사용하였다. 손실 함수는 softmax 함수를 사용하는 레이블 분류 모델을 위한 크로스 엔트로피 손실 함수를 사용하였고, optimizer는 Adam optimizer를 사용하였다. 인공 신경망의 hyperparameter를 변화해가며 모든 모델의 평균 정확도가 가장 높은 경우를 선택하였다. 이를 통해 합성곱층의 채널 수가 각각 32개, 16개, 8개가 되고, 풀링층과 합성곱층의 커널 크기는 5와 7을 사용한 그림 2의 인공 신경망 구조를 사용하였다.

인공 신경망 학습을 위한 장비는 intel i5 12th gen processor, NVIDIA GeForce RTX 3060을 사용하였다. 인공 신경망 학습은 epoch마다 데이터 검증을 포함하여 30 epoch를 수행하였고, 한 모델에 57분이 소요되었다. 하나의 TFA 이미지를 인공 신경망에 입력하여 예측할 때

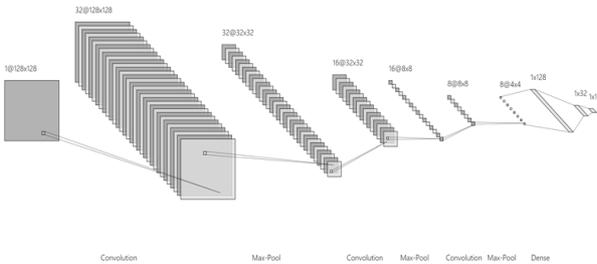


그림 2. 합성곱 신경망 구조를 사용한 인공 신경망
Fig. 2. Neural network with convolutional layers.

표 5. 모델 1(spectrogram)의 -6 dB SNR 신호 예측 결과

Table 5. Prediction result of model 1 (spectrogram) for -6 dB SNR signals.

SPEC	LFM	Barker	Costas	Frank	P1	P2	P3	P4	T1	T2	T3	T4
LFM	990	0	1	0	0	7	0	1	0	1	0	0
Barker	0	964	0	4	3	6	0	0	1	14	3	5
Costas	1	3	986	0	1	2	0	1	0	1	1	4
Frank	0	24	3	774	7	0	150	8	4	14	6	10
P1	0	0	0	1	635	0	0	298	46	17	1	2
P2	0	2	0	0	0	996	0	0	0	0	0	2
P3	0	2	4	168	2	0	764	8	2	3	23	24
P4	0	0	1	0	142	1	0	814	28	7	5	2
T1	1	1	0	2	101	0	3	90	678	93	21	10
T2	0	16	2	3	50	0	0	48	130	738	9	4
T3	0	11	0	4	12	1	2	42	14	14	767	133
T4	0	4	0	4	3	3	5	26	5	9	59	882

표 4. TFA 생성 시간과 인공 신경망 예측 시간을 포함한 저피탐 레이다 예측 시간

Table 4. Total prediction time of LPI radar classification including TFA generation and neural net prediction.

TFA	Generation time	Total prediction time
Spectrogram	0.360 ms	0.864 ms
WVD	1.780 ms	2.284 ms
CWD	207.314 ms	207.818 ms

0.504 ms가 소요되었다. 2.2절에서 측정한 TFA 생성 시간과 위의 인공 신경망의 예측 시간을 통해 최종 소요 시간을 계산할 수 있다. 표 4는 디지털 신호를 입력받고, TFA를 생성한 후, 신호를 예측하는 시간을 계산하였다. CWD가 spectrogram에 비해 생성 시간이 500배 이상 길었기에 최종 예측 소요 시간도 200배 이상 차이를 보였다.

IV. 인공 신경망 학습 결과

인공 신경망의 학습 결과를 확인하기 위해 학습 때와 동일한 조건으로 10개의 SNR과 12개의 신호종류에 대해 각각 1,000개씩 총 120,000개의 신호를 새롭게 생성하였다. 앞으로 이 장에서는 spectrogram을 사용한 모델을 모델 1, WVD를 사용한 모델을 모델 2, CWD를 사용한 모델을 모델 3으로 사용한다. 표 5~표 7은 -6 dB SNR에서

표 6. 모델 2(WVD)의 -6 dB SNR 신호 예측 결과

Table 6. Prediction result of model 2 (WVD) for -6 dB SNR signals.

WVD	LFM	Barker	Costas	Frank	P1	P2	P3	P4	T1	T2	T3	T4
LFM	884	3	16	6	7	6	4	2	28	41	0	3
Barker	1	641	10	66	45	21	23	5	35	61	34	58
Costas	1	18	716	20	9	25	49	11	50	19	25	57
Frank	0	46	34	388	27	3	296	23	55	23	40	65
P1	1	22	11	26	310	6	52	359	93	43	24	53
P2	4	77	42	10	39	506	9	57	4	38	86	128
P3	0	8	22	131	23	1	622	33	37	15	34	74
P4	0	6	11	15	159	6	59	589	66	18	23	48
T1	2	19	23	45	60	3	93	80	465	63	69	78
T2	4	59	19	73	66	9	48	53	163	413	37	56
T3	0	25	18	37	10	6	84	41	96	28	485	170
T4	0	16	7	13	23	3	27	29	24	12	26	820

표 7. 모델 3(CWD)의 -6 dB SNR 신호 예측 결과

Table 7. Prediction result of model 3 (CWD) for -6 dB SNR signals.

CWD	LFM	Barker	Costas	Frank	P1	P2	P3	P4	T1	T2	T3	T4
LFM	997	0	1	0	0	0	0	0	2	0	0	0
Barker	0	972	0	3	4	9	0	0	1	9	1	1
Costas	3	1	968	4	3	13	1	0	0	5	1	1
Frank	0	19	0	834	3	0	133	3	4	1	1	2
P1	0	2	0	0	708	0	0	185	82	18	3	2
P2	0	1	0	0	0	997	0	0	0	0	2	0
P3	0	1	1	123	1	0	861	3	0	0	5	5
P4	0	1	0	1	151	0	0	772	40	14	16	5
T1	0	0	0	0	45	0	2	24	820	83	21	5
T2	0	19	0	4	26	1	0	14	120	812	2	2
T3	0	13	0	4	0	2	0	1	11	3	869	97
T4	0	2	3	0	7	4	0	3	6	3	129	843

각각 모델 1~모델 3의 정답과 예측값을 비교한 표이다. 행은 정답인 신호의 종류를 나타내고, 열은 이를 모델이 예측한 신호의 종류를 나타낸다. 하나의 예로 표 5에서 첫 번째 신호의 종류인 LFM 신호를 1개는 Costas, 7개는 P2, 1개는 P4, 1개는 T2 신호라고 잘못 예측하여 총 1,000개의 신호 중 990개를 옳게 예측하고 10개를 잘못 예측하였다. 모델 2는 표 5에서 cross-term 때문에 다른 모델보다 잡음에 취약한 결과를 보였다. 모델 3이 모델 1보다 정확

도가 전체적으로 높은 것을 표 4와 표 6에서 확인하였다.

그림 3은 TFA 종류와 SNR에 따른 정확도를 표시한 그래프이다. 다른 모델보다 모델 2의 성능이 전 구간에서 떨어지는 것을 확인할 수 있다. 그 원인은 잡음에서 생기는 cross-term으로 추정된다. 모델 1과 모델 3의 정확도의 차이는 SNR이 작을수록 크게 드러났다. SNR이 가장 낮은 -10 dB SNR에서 모델 1과 모델 3의 정확도 차이가 7.5 %로 가장 컸다. -2 dB SNR 이상에서는 모델 1과

모델 3의 정확도의 차이가 1 %p 이하를 유지하였다.

노이즈가 클수록 모델 1과 모델 3의 정확도 차이가 큰 이유는 spectrogram과 CWD의 해상도 차이 때문으로 추정된다. 이는 그림 1(d)와 그림 1(f)에서 확인할 수 있으며 그림 1(d)가 그림 1(f)에 비해 해상도가 낮아서 노이즈 성분이 넓게 퍼져 있음을 확인할 수 있다. 그리고 노이즈의 크기가 클수록 이 해상도의 차이가 인공 신경망의 판단에 큰 영향을 끼치는 것으로 예상된다. 이 때문에 해상도가 비교적 낮은 spectrogram을 사용한 모델 1이 해상도가 높은 CWD를 사용하는 모델 3에 비해서 낮은 정확도를 보이며, 낮은 SNR에서 두 모델 간의 정확도 차이가 더 크게 나타난다.

V. 결 론

주파수 공동 사용을 위한 인지통신 기술에서 저피탐 레이다 식별 기술을 유용하게 활용할 수 있다. 주파수 식별 기술은 특정 대역을 사용하기 전에 빠르고 정확하게 해당 대역의 전파 환경을 파악할 수 있어야 한다. 본 논문에서는 수신한 신호를 시간-주파수 분석 이미지로 변환 후 인공신경망을 학습하여 저피탐 레이다 신호의 종류를 예측하는 모델을 구현하였다. 식별 결과는 SNR이 -2 dB 이상인 환경에서는 spectrogram 모델의 예측 정확도와 CWD 모델의 예측 정확도가 1 %p 이내로 차이가 크지 않다. CWD 모델과 spectrogram 모델의 예측 정확도 차이는 -10 dB에서 가장 큰 7.5 %p 차이를 보였다. TFA 생성 시간을 포함한 최종 예측 시간은 spectrogram, WVD, CWD 모델이 각각 0.864 ms, 2.284 ms, 207.818 ms를 소요하였다.

SNR이 낮은 경우 CWD 모델의 성능이 spectrogram 모델에 비해 우수하지만, TFA 생성을 포함한 최종 예측 시간이 200배 이상 느리다. 따라서 예측 소요 시간과 예측 정확도 간의 절충을 고려하여 저피탐 레이다 신호 식별 모델에서 사용할 시간-주파수 분석의 종류를 적절히 선택해야 한다.

References

[1] J. P. Choi, W. C. Lee, "Study on the introduction of

spectrum policy to revitalize the domestic spectrum sharing," *Journal of Korean Institute of Electromagnetic Engineering and Science*, vol. 29, no. 3, pp. 200-213, Mar. 2018.

[2] K. M. Kang, J. C. Park, S. N. Choi, S. J. You, S. H. Hwang, and W. J. Byun, "Spectrum policy and standardization trends on frequency sharing," *Electronics and Telecommunications Trends*, vol. 33, no. 3, pp. 1-10, Jun. 2018.

[3] J. P. Choi, W. C. Lee, "Study on cognitive engine platform based on the spectrum sharing for the military tactical communications," *Journal of Korean Institute of Electromagnetic Engineering and Science*, vol. 27, no. 7, pp. 559-611, Jul. 2016.

[4] S. H. Kong, M. Kim, L. M. Hoang, and E. Kim, "Automatic LPI radar waveform recognition using CNN," *IEEE Access*, vol. 6, pp. 4207-4219, Jan. 2018.

[5] M. Zhang, L. Liu, and M. Diao, "LPI radar waveform recognition based on time-frequency distribution," *Sensors*, vol. 16, no. 10, p. 1682, Oct. 2016.

[6] T. O. Gulum, "Autonomous non-linear classification of LPI radar signal modulations," M. S. thesis, Naval Postgraduate School, Monterey, CA, 2017.

[7] S. W. Golomb, H. Taylor, "Constructions and properties of Costas arrays," in *Proceedings of the IEEE*, vol. 72, no. 9, pp. 1143-1163, Sep. 1984.

[8] H. Meikle, *Modern Radar Systems*, 2nd ed. Norwood, MA, Artech House, pp. 315-326, 2008.

[9] B. Boashash, *Time-Frequency Signal Analysis and Processing: A Comprehensive Reference*, London, Elsevier, pp. 1-385, 2016.

[10] J. Perdoch, Z. Matousek, J. Ochodnický, and J. Kurty, "Polyphase coded radar waveforms in active noise jamming," in *2019 29th International conference Radioelektronika(RADIOELEKTRONIKA)*, Pardubice, Apr. 2019, pp. 1-6.

[11] J. E. Fielding, "Polytime coding as a means of pulse compression," *IEEE Transactions on Aerospace and Electronic Systems*, vol. 35, no. 2, pp. 716-721, Apr. 1999.

유 준 상 [한동대학교/학사과정]

<https://orcid.org/0000-0003-3973-7053>



2017년 2월~현재: 한동대학교 전산전자공학부 학사과정
[주 관심분야] Mixed Signal Circuit, VLSI, Machine Learning, Signal Processing

최 희 열 [한동대학교/부교수]

<https://orcid.org/0000-0002-0855-8725>



2010년: TAMU, Computer Science and Engineering (Ph.D)
2010년~2011년: Indiana University (Post Doc)
2015년~2016년: University of Montreal 방문연구원
2011년~2016년: 삼성전자 중기원 전문연구원

2016년~현재: 한동대학교 전산전자공학부 조교수-부교수
[주 관심분야] Deep Learning, Machine Translation

조 윤 석 [한동대학교/교수]

<https://orcid.org/0000-0002-7166-6390>



1987년 2월: 경북대학교 전자공학과 (공학사)
1989년 2월: 한국과학기술원 전기및전자공학과 (공학석사)
1994년 2월: 한국과학기술원 전기및전자공학과 (공학박사)
1995년 3월~현재: 한동대학교 전산전자공학부 교수

[주 관심분야] 신호처리, 임베디드시스템

김 영 식 [한동대학교/교수]

<https://orcid.org/0000-0003-1590-8233>



1993년 2월: 포항공과대학교 전자전기공학과 (공학사)
1995년 2월: 포항공과대학교 전자전기공학과 (공학석사)
1999년 2월: 포항공과대학교 전자전기공학과 (공학박사)
1999년 3월~현재: 한동대학교 전산전자

공학부 정교수

[주 관심분야] 메쉬 네트워크, 무선 송수신용 RF/ Analog IC 설계, 초저전력 Wake Up 수신기, 통신 신호처리, 반도체 집적 회로설계 및 제작

김 창 주 [(주)휴라/수석연구원]

<https://orcid.org/0000-0002-3689-8137>



1980년 2월: 한국항공대학교 항공전자공학과 (공학사)
1988년 2월: 한국과학기술원 전기및전자공학과 (공학석사)
1993년 2월: 한국과학기술원 전기및전자공학과 (공학박사)
1979년 12월~1983년 3월: ADD 연구원

1983년 3월~2018년 12월: ETRI 책임연구원
1994년 3월~1998년 12월: ETRI 전파신호처리연구실장
1999년 1월~2001년 4월: ETRI 이동통신모뎀연구부장
2003년 2월~2010년 12월: ETRI 전파기술연구부장
2019년 3월~2022년 2월: 한동대학교 전산전자공학부 초빙교수
2022년 3월~현재: (주)휴라수석연구원
[주 관심분야] 이동통신, 위성통신, 전파 기술 등