

딥 러닝 기법을 이용한 레이더 신호 분류 모델 연구

김용준^{*,1)} · 유기훈¹⁾ · 한진우¹⁾

¹⁾LIG넥스원(주) 전자전연구소

Research for Radar Signal Classification Model Using Deep Learning Technique

Yongjun Kim^{*,1)} · Kihun Yu¹⁾ · Jinwoo Han¹⁾

¹⁾Electronic Warfare R&D, LIG NEXI Co., Ltd., Korea

(Received 16 October 2018 / Revised 18 December 2018 / Accepted 25 February 2019)

ABSTRACT

Classification of radar signals in the field of electronic warfare is a problem of discriminating threat types by analyzing enemy threat radar signals such as aircraft, radar, and missile received through electronic warfare equipment. Recent radar systems have adopted a variety of modulation schemes that are different from those used in conventional systems, and are often difficult to analyze using existing algorithms. Also, it is necessary to design a robust algorithm for the signal received in the real environment due to the environmental influence and the measurement error due to the characteristics of the hardware. In this paper, we propose a radar signal classification method which are not affected by radar signal modulation methods and noise generation by using deep learning techniques.

Key Words : Deep Learning(딥 러닝), Convolutional Neural Network(컨볼루션 신경망), Recurrent Neural Network(순환 신경망), Radar Signal Classification(레이더 신호 분류), Electronic Warfare(전자전)

1. 서론

전자전은 적의 네트워크, 레이더, 통신 등을 탐지하여 교란하거나 해킹하여 피해를 주고 아군의 정보 우위를 확보하는 군사 활동을 통칭한다. 크게 3가지의 하위 분야가 있으며 각각 ES(Electronic Support), EA

(Electronic Attack), EP(Electronic Protection)로 구분된다. 레이더 신호 분석 및 식별은 ES분야의 핵심적인 부분 중 하나로서 전자전 장비를 통해 수신된 적 위협 레이더 신호를 분석하여 주파수, PRI(Pulse Repetition Interval), PW(Pulse Width) 등의 범위 및 변조 형태와 같은 상세 특성을 도출한 후 아군이 보유하고 있는 위협 라이브러리와 매칭하여 레이더 종류를 판별하는 것을 말한다. 식별된 최종 정보는 전자전 장비의 운용자에게 보고되며 EA 및 EP 활동에 사용될 수 있다.

* Corresponding author, E-mail: yongjun.kim@lignex1.com
Copyright © The Korea Institute of Military Science and Technology

기존 전자전 장비의 분석 및 식별 알고리즘은 수신된 레이더 신호의 주파수, 펄스반복주기, 펄스폭 등의 범위 및 변조 특성을 분석하여 사전에 작성된 레이더 방사체 유형 별 특성 테이블의 데이터 범위 및 변조 특성의 카테고리화 비교하는 방식을 주로 사용한다^[1]. 그러나 이러한 방법은 특성 테이블 작성 및 갱신에 숙련된 전문가가 필요하고 작성에 많은 시간이 소요된다는 단점이 있다. 또한 전자전 장비의 실제 운용시에 수신되는 데이터에는 지형 및 구조물, 탐재 장비의 형상 등에 의한 신호의 누락과 레이더 신호 제원을 측정하여 디지털화하는 과정에서 발생하는 측정 오차 등이 발생하게 되는데 고정된 룰(rule)에 의한 분석과 특성 값의 범위에 의한 매칭 방식을 따르는 기존 알고리즘은 이러한 데이터를 정확히 판별해 내는데 취약점을 갖고 있다. 본 논문에서는 이러한 문제점을 해결하기 위해 최근에 각광받고 있는 방법인 딥 러닝 기법을 적용한 레이더 신호 분류 방법 연구를 수행하였다. 딥 러닝 기법은 심층신경망을 통해 방대한 양의 데이터를 처리하여 데이터에 내재되어 있는 해당 도메인의 속성이 자동으로 학습되도록 하는 기법으로 고차원의 복잡한 데이터를 인식하고 분류할 수 있다. 본 논문에서는 대표적인 딥 러닝 기법인 CNN(Convolution Neural Network) 및 RNN(Recurrent Neural Network)을 이용한 레이더 신호 분류 방법을 제안하고자 한다.

신경망을 이용한 레이더 신호 분류에 대한 연구는 꾸준히 진행되어 왔다. Anderson은 1990년에 서로 다른 종류의 방사체(Emitter)들에 의해 레이더 신호가 방사되고 노이즈가 발생하는 환경에서 신경망을 이용하여 신호를 클러스터링하고 방사체의 종류를 분류하는 시스템을 제안하였다^[3]. Petrov는 수신한 신호에서 분류된 펄스열을 이용해 신경망 기반 레이더 인식 시스템을 개발하였다. 제안하는 시스템은 12개의 펄스열 특징점을 추출하여 신경망의 레이어(layer) 수 및 노드 수를 조절하면서 인식률을 측정하였으며 정확도는 평균 80 % 정도를 나타내었다^[4]. Lin은 입력 특징점의 구간정보를 이용하는 ‘Interval Type-2 Fuzzy Neural Network’를 제시하였다^[5]. Shieh는 주파수, PRI, PW를 입력으로 사용하는 Vector Neural Network 기반의 Emitter Identification 방법을 제시하였다^[6]. 또한 Zhou는 레이더 신호의 펄스내 변조 정보를 입력값으로 하여 deep Restricted Boltzmann machine을 이용한 인식기를 모델링하였다^[7]. 본 논문에서는 딥 러닝 네트워

크를 이용하여 비교적 단순한 구조에서 높은 분류 성능을 제공하는 레이더 신호 분류 모델을 제안하고자 한다.

본 논문의 구성은 다음과 같다. 2장에서는 분류 대상 레이더 신호의 특성과 전자전 시스템에서 일반적으로 적용되는 레이더 신호 분류 과정에 대해 설명하고 3장에서는 본 논문에서 제안하는 딥 러닝 기법을 적용한 레이더 신호 분류 모델에 대해 소개한다. 4장에서는 모델의 학습에 사용된 데이터 생성 및 전처리 방법과 실험 구성 및 실험 결과에 대해 분석한 내용을 보인다. 마지막으로 5장에서는 결론 및 향후 연구 과제에 대해 설명한다.

2. 일반적인 레이더 신호 분류 방법

2.1 레이더 신호 특성

레이더 신호는 용도에 따라 서로 다른 주파수 대역을 사용하고 전자전 장비의 탐지 및 공격을 어렵게 하기 위해 다양한 형태의 변조 방식을 사용한다. 지속파(CW : Continuous Wave)형태의 신호를 사용하는 레이더도 존재하나 대부분의 레이더는 펄스(Pulse) 형태의 신호를 사용한다. 본 논문에서는 펄스 형태의 레이더 신호에 대한 분류를 수행하며 대표적인 주파수 및 PRI 변조 형태를 갖는 신호들에 대한 분류 성능을 확인한다. 주파수 변조 형태는 다음 그림과 같이 고정, 어자일(Agile), 패턴 사인형(sinusoid), 패턴 슬라이딩(sliding)+/-, 호핑(Hopping) 등의 형태를 갖는다.

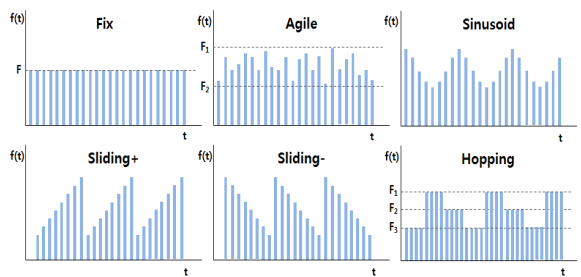


Fig. 1. Frequency modulation type

PRI 변조 형태는 다음 그림과 같이 고정, 스테거(Stagger), 지터(Jitter), 패턴 사인형(Sinusoid), 패턴 슬라이딩(Sliding)+/-, Dwell&Switch 등의 형태를 갖는다.

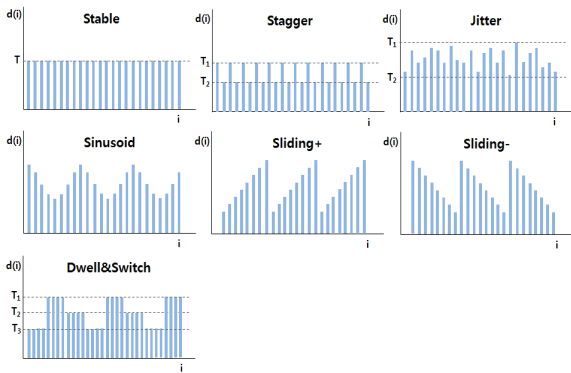


Fig. 2. PRI modulation type

2.2 전자전 시스템의 레이더 신호 분류 방법

일반적인 전자전 시스템에서 안테나로 수신된 레이더 신호의 펄스는 디지털화되어 PDW(Pulse Description Word)라는 형태의 데이터로 생성된다. PDW는 다음과 같은 주요 정보를 포함하며 단일 펄스에 대한 특성을 나타낸다.

Table 1. Details of PDW

Item	Description
TOA	Time of Arrival
Frequency	Frequency of Pulse
PW	Pulse Width
PA	Pulse Amplitude
AOA	Angle of Arrival

추가적으로 PRI는 펄스 간의 TOA차에 의해서 계산되는 특성으로서 펄스의 반복 주기를 나타내며 레이더 신호의 주요 특성 중 하나이다.

PDW는 펄스열 추출 과정을 거쳐 여러 개의 펄스열로 구분되며 각각의 펄스열에 대해 주파수/PRI 범위 및 변조 특성이 분석된다. 분석된 결과는 사전에 입력된 위협 제원 데이터베이스 정보와 매칭되어 일치하는 제원이 있으면 해당 위협으로 식별하게 된다²⁾.

이와 같이 전통적인 레이더 신호 분류 방법은 각 레이더 신호의 고유한 변조 특성 및 변경 범위 등을 분석하여 위협을 판별하는 방식이며 위협 식별 과정에서 사용되는 위협 제원 라이브러리의 신뢰성 및 완성도에 따라 시스템의 성능이 좌우될 수 있다.

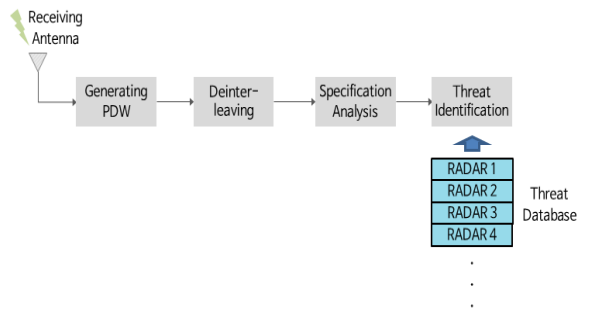


Fig. 3. Conventional radar signal classification

이러한 이유로 인해 위협 제원 라이브러리는 숙달된 전문가에 의해 작성되어야 하며 기존의 전자전 시스템은 이 과정에서 발생하는 인적 오류(human error)에 취약하다는 문제점이 있다. 또한 레이더 장비가 발전하면서 새로운 변조 신호를 사용하는 레이더들이 출현하고 있으며 고정된 형태의 알고리즘을 사용하는 기존의 시스템으로는 대응이 어려울 수 있다. 본 논문에서 제안하는 딥 러닝 모델 기반의 레이더 신호 분류 모델의 경우 전문가의 개입 없이 데이터에 의해 레이더 신호의 특징을 학습하고 인식할 수 있으며 신규 신호에 대한 분류 능력 추가가 용이하다는 장점이 있다.

3. 딥 러닝 레이더 신호 분류 모델

레이더 신호 분류 모델 구현을 위해 대표적인 딥 러닝 모델인 CNN(Convolution Neural Network), RNN(Recurrent Neural Network)의 발전된 형태인 LSTM(Long Short-Term Memory), GRU(Gated Recurrent Units) 구조를 이용하였다.

CNN은 이미지 처리에 특화되어 있는 네트워크 구조를 가지므로 레이더 신호를 이미지 데이터와 유사하게 다루도록 한다. 데이터 전처리를 통해 생성된 주파수 정보의 배열이 이미지 데이터처럼 입력되도록 설계하면 신호의 변조 특성에 따라 주파수 값에 해당하는 픽셀의 위치가 레이더 별로 특징적인 모습을 나타낼 것이므로 같은 레이더 신호 간에는 유사하고 다른 레이더 신호와는 구분되는 형상 특성이 학습되도록 할 수 있다. 주파수 정보 배열의 형태를 가로 64, 세로 64 단일 색상을 갖는 이미지 데이터의 형태처럼 변환하여 입력되도록 구성하였다. 입력 데이터의 크기

는 실험 대상 레이더 신호의 특성이 충분히 나타나는 한도 내에서 실험 환경에서 처리 가능한 연산량을 감안하여 설정하였다.

CNN을 이용한 모델의 구조는 다음과 같다. 컨볼루션(convolution) 레이어를 생성하여 [3,3,1] 크기의 필터를 4개 설정하고 필터가 이동하는 간격인 스트라이드(stride)는 [1,1,1,1]로 설정한다. 활성화함수(activation function)로 ReLu(Rectified Linear Unit)를 설정하여 기울기 소실(Gradient Vanishing) 문제가 발생하지 않도록 하였다. 이 과정을 통해 이미지 형태로 변환된 레이더 신호가 다른 신호들과 구분될 수 있는 형태적 특징들이 학습될 수 있다.

다음으로 맥스 풀링(Max Pooling)을 이용하여 연산량을 감소시키고 과적합(overfitting)을 줄일 수 있도록 한다. 풀링(Pooling)을 위한 윈도우 크기는 [4,4]로 설정하여 16개의 데이터마다 1개의 결과가 출력되도록 한다. 같은 형태의 컨볼루션 레이어, ReLu, 맥스 풀링을 한번 더 통과하도록 하고 마지막으로 완전연결(fully-connected) 레이어를 구성하여 계산된 결과가 100차원 벡터 출력값으로 생성되도록 한다. 출력된 100차원 벡터 중에서 가장 높은 값을 갖는 요소가 이 데이터가 100개의 레이더 신호 중 어떤 신호인지를 나타내게 된다. 또한 가중치 초기화 시 효율적인 초기화를 수행하는 것으로 알려진 제비어 초기화(xavier initialization) 방법을 사용하였다⁸⁾.




Fig. 4. CNN-based classification model

다음은 LSTM 및 GRU 모델을 이용한 레이더 신호 분류 모델을 설명한다. RNN 계열의 모델은 시계열 데이터를 처리하는 데 적합하며 입력 데이터는 시간의 흐름에 따라 레이더에서 발생시킨 펄스의 주파수 정보를 나타낸 것이므로 레이더 신호 별로 특징적인 순서를 갖게 되며 RNN 모델을 통해 학습시켰을 때 좋은 분류 성능을 기대할 수 있는 데이터 형태라고

할 수 있다. 다음은 RNN 기반 레이더 신호 분류 모델의 구조이다. LSTM 및 GRU 모델의 차이는 은닉층(Hidden Layer)의 셀(Cell) 내부 구조 차이이다.

CNN의 경우와 유사하게 입력 데이터를 [64,64] 크기로 받고 출력 데이터를 레이더 신호 클래스 크기만큼 출력하도록 설정한다. RNN에서는 입력 데이터에 깊이 차원은 존재하지 않는다는 것이 약간의 차이점이다. 데이터의 크기를 [64,64]로 설정하였으므로 RNN의 은닉층 셀 개수 및 각각의 셀에 입력되는 데이터 벡터의 크기를 64로 설정하여 입력 데이터가 처리될 수 있도록 한다. 이 과정에서 레이더 신호 별로 보유하고 있는 주파수 값의 특징적인 순서 형태가 학습되게 되며 다른 신호들과 구분할 수 있는 분류 모델이 만들어지게 된다.

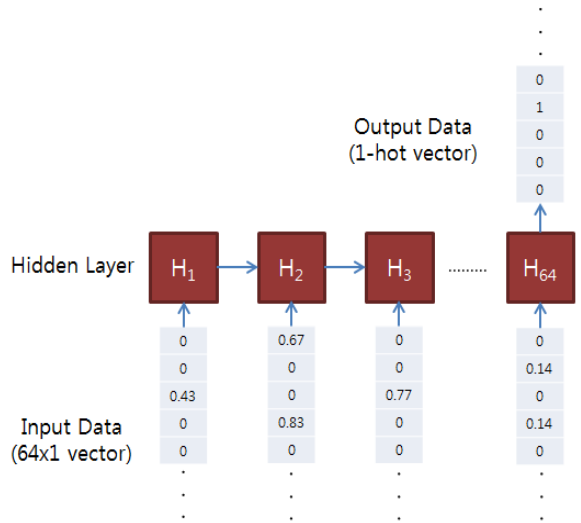


Fig. 5. RNN-based classification model

4. 데이터 생성 및 실험 결과

4.1 학습 및 테스트 데이터 생성

레이더 신호 분류 실험을 위해 100종 클래스의 서로 다른 레이더 신호 데이터를 입력 데이터로 사용하였다. 데이터는 레이더 신호 모의 발생기를 이용하여 생성하였으며 클래스 별로 400개의 PDW 셋(Set)을 생성하여 총 40,000개의 PDW셋을 학습 및 테스트에 사용하였다. 한 레이더 신호가 다른 신호들과 구분되는 가장 특징적인 속성은 주파수 및 PRI의 값 범위 및

변조 특성이라고 할 수 있으며 대부분의 전자전 시스템에서 주로 레이더의 주파수 및 PRI 특성을 이용하여 위협을 식별한다. 이러한 이유로 본 논문에서는 주파수 및 PRI 정보를 사용하여 레이더 신호 분류 실험을 수행하였다. PW 및 PA 등의 특성도 레이더 신호의 특징적인 요소이나 외부 환경에 의한 노이즈 및 오차가 반영될 가능성이 많은 속성들이므로 실험의 입력 속성에서는 제외하였다. 데이터 모의 시 주파수 및 PRI 범위와 변조 형태를 일반적으로 사용되는 범위 안에 골고루 분포되게 하여 데이터 범위 및 변조 형태를 설정하였다. 다음 그림은 실험에 사용된 데이터의 주파수 및 PRI 값 분포를 나타낸 것이다.




Fig. 6. Distribution of training data Freq/PRI

주파수 호핑, 어자일, 패턴 등의 값 범위가 넓은 변조 형태에 대해서는 중심주파수 값을 그래프에 표시하였으며 PRI 스테거, 지터, 패턴, Dwell&Switch 등의 변조 형태에 대해서도 유사하게 중심PRI 값을 표시하였다.

주파수 및 PRI 변조 형태 또한 존재 가능한 신호의 특성들이 반영되도록 변조 특성을 적절히 분배하여 설정하였으며 각 변조 형태의 분포는 다음과 같다.




Fig. 7. Distribution of training data Freq/PRI modulation type

전자전 시스템에서 실제로 수신되는 레이더 신호는 장비의 특성에 따른 측정 오차가 포함되게 되며 운용

환경의 영향으로 레이더 신호 펄스가 누락되는 현상이 빈번히 발생한다. 실험에 사용되는 데이터는 모의 데이터이므로 실제 데이터와 유사한 특징을 갖도록 하기 위해 랜덤하게 측정 오차 및 펄스 누락을 모의하여 데이터를 생성하였다.

각 레이더 신호의 고유한 특성이 잘 학습될 수 있도록 전체 데이터의 30 %는 오차 및 누락을 반영하지 않았으며 나머지 70 %에 대해 주파수의 경우 ± 7 MHz 내에서, PRI의 경우 $\pm 0.5 \mu s$ 내에서 오차가 발생하도록 하고 전체 펄스 중 10 %가 누락되도록 설정하였다.

다음 그림은 주파수 Fix 형태를 갖는 레이더 신호의 PDW셋에 대한 오차 적용 전/후를 비교한 것이다.

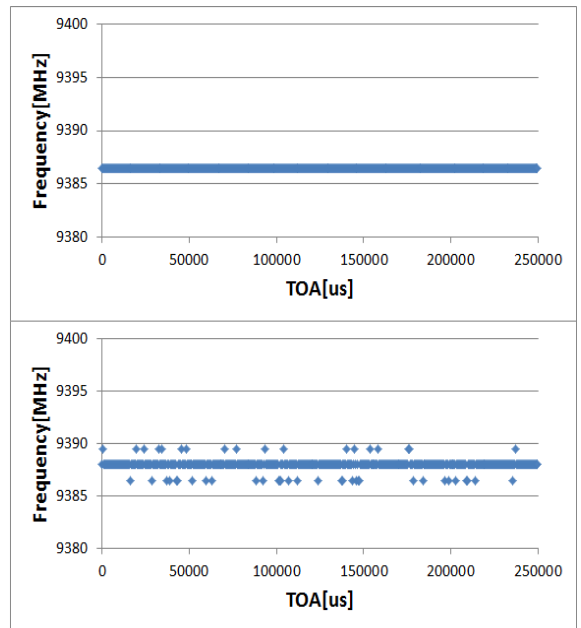


Fig. 8. Comparison of before and after application of frequency error

다음 그림은 $680 \mu s$, $720 \mu s$, $660 \mu s$ 의 3단 Dwell & Switch 변조 형태를 갖는 레이더 신호의 펄스 누락 적용 전/후 비교이다.

누락 발생 전 신호의 PRI 값은 $680 \mu s$, $720 \mu s$, $660 \mu s$ 에서만 변화하며 누락 적용 후 신호에서는 $680 \mu s$, $720 \mu s$, $660 \mu s$ 의 배수 값을 갖는 PRI가 추가적으로 나타나며 이러한 특성 또한 학습된 모델에 반영되게 된다.




Fig. 9. Comparison of before and after application of pulse missing

4.2 데이터 전처리

레이더 신호의 디지털화된 데이터인 PDW셋은 주파수, PW, PRI, TOA, PA, AOA 등의 속성을 갖는다. 이 중 주파수는 전자전 시스템의 하드웨어적 특성이나 수신 환경 및 레이더 위치 등의 외부 요인에 크게 영향받지 않고 원 신호의 값을 비교적 잘 유지한다. 펄스 간 TOA 차를 의미하는 PRI의 경우도 펄스의 누락이 발생할 경우를 제외하고는 측정 오차가 상대적으로 적게 발생하므로 주파수 및 PRI가 전자전 시스템에서 레이더 신호를 구분하는데 사용하기 적합한 핵심 속성이라고 할 수 있다. 실험 수행을 위해 레이더 신호 모의 데이터에서 주파수 및 PRI 특성을 추출하여 입력 데이터로 활용할 수 있는 주파수 값의 배열을 생성하였다. 주파수 값은 다음 수식을 적용하여 입력 데이터의 범위 내에서 0~1사이의 값으로 정규화하였다.

$$Freq_n = \frac{Freq - Freq_{min}}{Freq_{max} - Freq_{min}} \quad (1)$$

PRI는 펄스 간의 간격이므로 PRI의 특성을 주파수 배열 상에서 나타내기 위해 배열 한 칸의 길이를 10

μs로 설정하여 펄스가 존재하는 위치에서는 정규화된 주파수 값을 넣고 펄스가 존재하지 않는 구간에는 '0' 값을 넣는다. 이러한 방식으로 각 레이더 신호마다 주파수 정보 배열을 생성하여 레이더 신호의 고유한 주파수 및 PRI 특성이 포함되도록 한다. 예를 들어 30 us 고정 PRI를 갖는 신호의 경우 다음과 같은 형태의 주파수 배열이 생성된다.

$$[F_1, 0, 0, 0, F_2, 0, 0, 0, F_3, \dots, F_n, 0, 0, 0, F_{n+1}, \dots]$$

이렇게 생성한 배열을 학습 모델의 입력 데이터 형태인 64 × 64 크기로 변환하여 입력하게 된다.

4.3 실험 환경

Google에서 제공하는 오픈소스 딥러닝 라이브러리인 Tensorflow를 이용하여 CNN 모델 및 RNN의 개량된 구조인 LSTM, GRU 모델을 사용한 학습 모델을 구현하였으며 모든 모델은 Python 언어를 이용하여 구현하였다. 실험에 사용된 컴퓨터 환경 및 라이브러리 내역은 다음 표와 같다.

Table 2. Computer resource and library list

Item	Spec. or Version
CPU	Intel Core i5-3470
Main memory	16 GB
OS	Windows 7 64 bit
Language	Python 3.5.2
Library	Tensorflow 1.1.0-rc2

4.4 학습 및 테스트 결과

3장에서 설명한 CNN, LSTM, GRU 모델에 모의 생성한 100종의 레이더 신호를 입력으로 하여 학습을 진행하였다. 각 레이더 별로 생성된 400개의 PDW셋 중 300개는 학습에 사용하고 100개는 학습이 완료된 모델의 테스트에 사용하였다.

각 모델 별로 동일하게 1000 epoch 씩 학습을 수행하였고 1회 학습에 사용되는 데이터의 크기(batch size)는 1024로 설정하여 수행하였다. 모델의 학습 진행 정도를 파악하기 위해 매번 학습에 사용된 입력 데이터

를 모델에 입력했을 때 발생한 손실을 바탕으로 비용(cost)을 계산하였다. 학습 진행 속도를 알아보기 위해 각 모델 별로 비용 값이 변화하는 추이를 그래프로 나타내었으며 결과는 다음 그림과 같다.

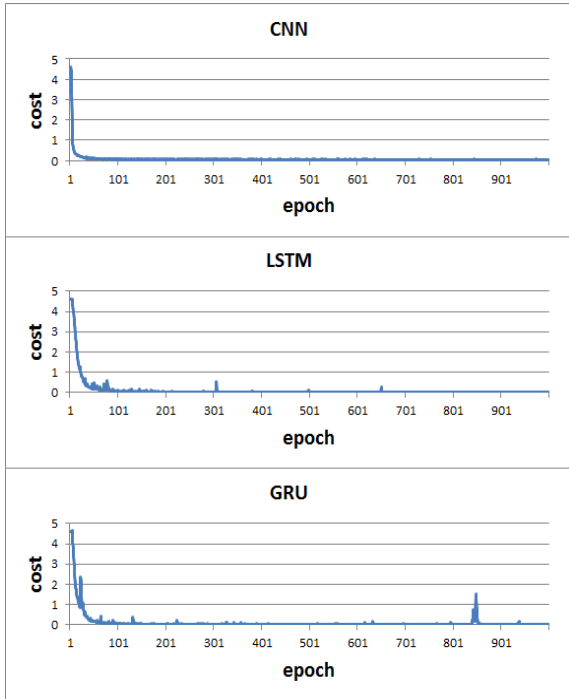


Fig. 10. Change in cost value by model

비용 값은 입력 데이터를 바탕으로 모델이 예측한 결과값이 실제값과 얼마나 차이가 나는지를 계산한 값으로 학습 진행에 따라 비용 값이 0에 가깝게 수렴해간다면 모델의 학습이 원하는 방향으로 이루어지는 것으로 볼 수 있다. CNN 모델은 약 40 epoch부터 수렴하며 LSTM과 GRU 모델은 약 100 epoch부터 수렴하는 결과를 보였다. CNN 모델의 경우 LSTM이나 GRU 모델보다 다소 빠르게 수렴하는 모습을 보인다. LSTM과 GRU 모델은 유사한 속도로 수렴하는 결과를 보였다.

다음은 학습된 모델에 테스트용 데이터를 입력하여 도출된 레이더 신호 별 분류 정확도이다. 클래스 별 100개의 PDW셋을 테스트 데이터로 사용하였으며 전체적으로 CNN 보다는 RNN 계열 모델이 좀 더 좋은 결과를 보였다. 분류 정확도는 입력된 테스트 데이터의 클래스와 레이더 신호 분류 모델이 예측한

클래스가 동일한지를 확인하여 전체 10000개 PDW셋 입력 대비 모델이 예측한 정답율을 계산하여 산출하였다.

모델 별 전체 분류 정확도를 계산한 결과는 다음과 같다. CNN 모델보다는 RNN 계열 모델이 다소 우수한 결과를 보였고 LSTM 모델이 GRU 모델보다 근소한 우위를 나타냈다.

Table 3. Classification accuracy by model

Total Classification Accuracy(%)		
CNN model	LSTM model	GRU model
94.42	97.53	97.43

4.5 결과 분석

세 모델 모두 전체 분류 정확도가 90 % 이상으로 비교적 우수한 결과를 나타냈으며 CNN 보다는 LSTM 및 GRU 모델이 좋은 결과를 보였다. 클래스 별 정확도 결과를 보면 2, 18, 25, 31, 44, 45, 55~58, 71~74번 신호에서 RNN계열의 모델이 CNN 모델보다 확연히 우수한 결과가 나왔다. 해당 신호들은 대부분 주파수 및 PRI의 값 범위가 동일하거나 서로 중첩되고 여차일, 패턴, 호핑 등 복잡한 변조 형태를 갖는 신호이며 일반적인 전자전 시스템에서 서로 구분하기 쉽지 않은 특성을 갖고 있다. 특히 56~58번 신호의 경우 주파수 범위 및 변조 형태가 완전히 동일한 신호들로서 PRI의 경우 4단(level) D&S 형태의 특성을 갖고 있으며 단 별 PRI의 값은 동일하고 순서만 다른 특성을 갖고 있는데 LSTM 및 GRU 모델은 높은 정확도로 분류해 내는 성능을 보였다. 이는 순서를 갖는 시계열 데이터 처리에 특화된 RNN 계열 모델의 장점이 나타난 결과로 해석할 수 있다. 유사하게 CNN에서도 레이더 신호의 시간적인 변화 특성이 이미지 상에서의 위치적인 특성으로 표현되어 학습되었을 것으로 예측되거나 컨볼루션 레이어나 풀링 레이어를 거치면서 다른 신호와 구분 가능한 정보가 다소 사라진 것으로 보인다. 또는 컨볼루션 레이어에서 사용한 필터의 크기가 이 신호들을 서로 구분하기에 충분하지 않았을 수 있다.

다음은 56~58번 신호의 PRI 변화 그래프를 순서대로 나열한 것이다. 각각의 PRI 단 값은 동일하지만 순서는 서로 다른 것을 알 수 있다.

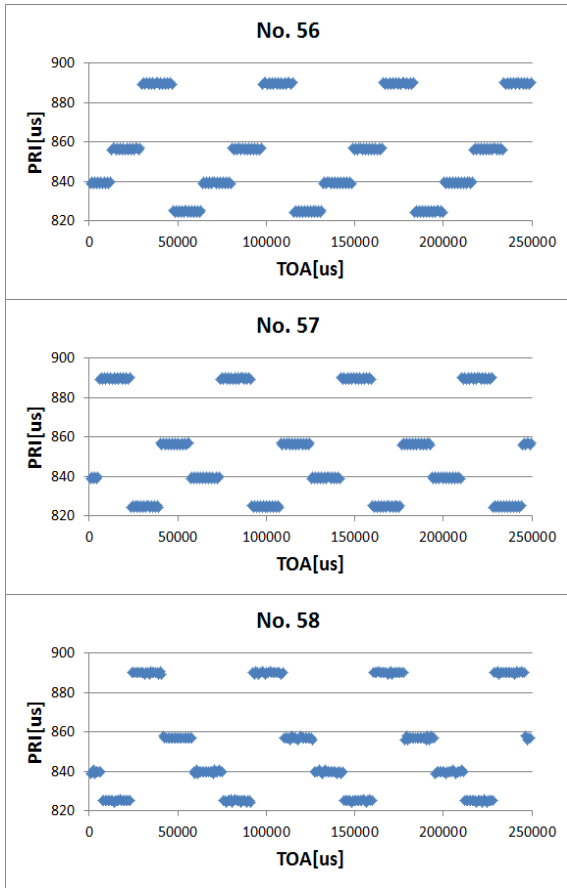


Fig. 11. Comparison of No. 56~58 PRI characteristic

32, 33, 79, 81번 신호의 경우 세 모델 모두 전체 정확도에 크게 미치지 못하는 정확도를 보였다. 32, 33번 신호의 경우 PRI 범위 및 변조 특성이 동일하고 33번 신호가 32번 신호의 주파수 특성을 포함하여 서로 신호 특성이 매우 유사한 관계로서 상대 신호로 인식한 분류 결과가 다수 발생하였다. 79, 81번 신호의 경우도 동일한 경우이다.

다음은 32, 33번 신호의 주파수 특성 그래프이다. 32번은 고정 형태이며 33번은 어자일 형태로서 32번이 33번의 주파수 범위 내에 포함되는 것을 알 수 있다.

두 가지 경우 모두 PRI 특성은 완전히 동일하고 주파수 특성은 한 신호가 다른 신호를 거의 포함하는 경우이다. 이 경우 본 논문에서 구축한 레이더 분류 모델은 신호를 서로 잘 구분하지 못하는 결과를 보였다. 이러한 문제 해결을 위해서는 RNN 계열 모델의 경우 은닉층의 개수를 늘려 더 긴 시퀀스 정보를 학

습할 수 있도록 하거나 더 많은 데이터에 의해 좀 더 다양한 패턴 변화를 학습시켜 작은 차이를 잘 구분할 수 있도록 하는 방법을 생각해 볼 수 있다.

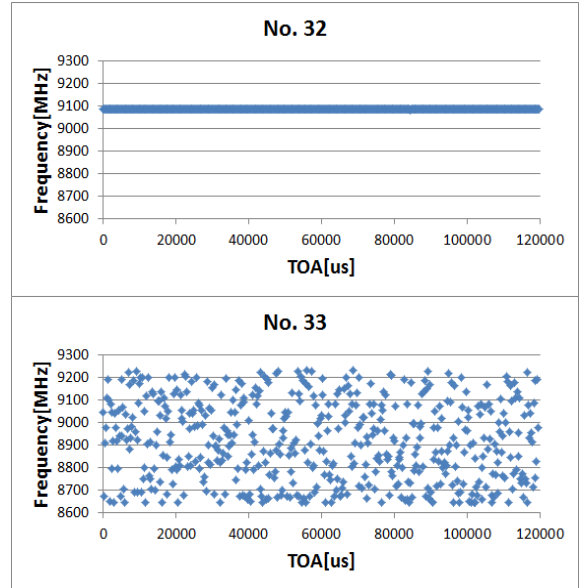


Fig. 12. Comparison of No. 32, 33 frequency characteristic

5. 결론 및 향후 연구

전자지원 분야의 전자전 시스템 운용은 상대 레이더 신호를 빠르게 탐지하고 분석하여 아군에 유리한 정보를 제공하는 데 목적이 있다. 이를 위해 오차 및 신호 누락 등의 노이즈 발생 환경에서 다양한 변조 특성을 갖는 위협 레이더 신호를 정확히 분류하는 성능이 요구된다. 본 논문에서는 전자전 시스템에서 활용 가능한 딥 러닝 기반의 레이더 신호 분류 모델을 구현하고 실제 적용 가능성을 실험해 보았다. 100종의 서로 다른 변조 특성을 갖는 레이더 신호 데이터를 모의하고 딥 러닝 모델을 통해 학습시켜 분류 성능을 확인하였다.

학습 시 CNN 모델이 LSTM, GRU 모델보다 빠르게 수렴하는 결과를 보였으나 전체 클래스에 대한 분류 정확도를 테스트한 결과에서는 CNN 모델이 94.42 %, LSTM 모델이 97.53 %, GRU 모델이 97.43 %의 정확도를 보였으며 CNN 보다는 RNN 계열의 모델이 다소

우수한 성능을 보였다. 각 클래스 별 결과를 보면 특정 클래스에서 RNN 계열 모델이 월등한 정확도를 보였으며 대상 클래스들의 신호 특성을 살펴보면 주파수, PRI의 값과 범위는 유사하나 순서가 달라지는 특성을 갖는 경향이 있었다. 이는 시간에 따른 펄스의 주파수 값 및 간격이 변화하는 특징을 가진 레이더 신호를 분류하는 데 순서 정보 처리에 강점이 있는 RNN 계열의 모델이 더 적합함을 보인 결과라고 할 수 있다. 그러나 CNN 모델 또한 다른 레이더 신호들과 구분되는 신호의 시간적인 특성을 충분히 학습할 수 있도록 필터의 크기나 네트워크 구조를 변경할 경우 성능을 향상시킬 수 있는 가능성이 있다.

몇 가지 클래스들에서 세 모델 모두 분류 성능이 떨어지는 결과가 나왔으며 대상 클래스들의 신호 특성을 살펴보면 한 신호가 다른 신호의 변조 특성 및 범위를 완전히 포함하는 경우가 많았다. 이러한 신호들의 분류 성능 향상을 위해서는 시간에 따른 주파수 및 PRI의 변화 패턴이 더 잘 학습되도록 모델을 설계해야 하며 RNN 계열 모델에서 은닉층의 길이를 늘리거나 더 많은 학습 데이터를 통해 신호 간의 구분 가능한 특성이 분류 모델에 충분히 학습되도록 하는 방안을 고려해 볼 수 있다.

전통적인 전자전 장비의 레이더 신호 분류 방법과 비교해 보면 기존 방식은 2.2절에서 설명한 바와 같이 위협 식별 과정에서 사용되는 위협 데이터베이스의 완성도에 따라 분류 결과의 성능이 좌우되므로 본 논문에서 제시한 분류 모델과의 정량적인 성능 비교는 어렵다. 다만 제안한 모델은 사용자의 위협 데이터베이스 작성 시 발생할 수 있는 오류에서 자유로우며 기존에 알려지지 않은 새로운 형태의 변조 특성에 유연하게 대응할 수 있다는 장점을 갖는다.

실험 결과를 통해 딥 러닝 모델의 장점을 이용하면 레이더 신호와 같은 다차원 특성을 갖는 데이터의 패턴을 학습하여 오차 및 신호 누락에 크게 영향 받지 않는 레이더 신호 분류 모델을 생성할 수 있는 것으로 판단할 수 있다. 또한 새로운 레이더 출현 시 해당 신호의 특성을 추가적으로 학습시켜 기존 소프트웨어 수정 없이 신호 식별 성능을 향상시킬 수 있는 전자

전 시스템의 구현도 가능하다.

향후 유사 신호 구분을 위한 네트워크 구조 연구를 수행하여 본 연구에서 드러난 약점을 보완한다면 실제 전자전 시스템에서도 활용 가능한 수준의 레이더 신호 분류 모델을 구축할 수 있을 것으로 기대된다.

References

- [1] Richard G. Wiley, "ELINT The Interception and Analysis of Radar Signals," Artech House, Norwood, MA, pp. 385-388, 2006.
- [2] D. Curtis Schleher, "Electronic Warfare in the Information Age," Artech House, Norwood, MA, pp. 336-345, 1999.
- [3] James A. Anderson, et al., "Radar Signal Categorization Using a Neural Network," Proceedings of the IEEE, Vol. 78, No. 10, pp. 1646-1657, 1990.
- [4] Nedyalko Petrov et al., "Radar Emitter Signals Recognition and Classification with Feedforward Networks," Procedia Computer Science 22, pp. 1192-1200, 2013.
- [5] Chih-Min Lin, et al., "A Self-Organizing Interval Type-2 Fuzzy Neural Network for Radar Emitter Identification," International Journal of Fuzzy Systems, Vol. 16, No. 1, pp. 20-30, 2014.
- [6] Ching-Sung Shieh, et al., "A Vector Neural Network for Emitter Identification," IEEE Transactions of Antennas and Propagation, Vol. 50, No. 8, pp. 1120-1127, 2002.
- [7] Dongqing Zhou, et al., "A Novel Radar Signal Recognition Method Based On a Deep Restricted Boltzmann Machine," Engineering Review, Vol. 37, Issue 2, pp. 165-171, 2017.
- [8] Xavier Glorot, et al., "Understanding the Difficulty of Training Deep Feedforward Neural Networks," International Conference on Artificial Intelligence and Statistics PMLR 9, pp. 249-256, 2010.