

웨이블릿 변환 기반 CNN을 활용한 무선 신호 분류

송민석¹ · 임재성^{2*} · 이민우²

Classification of Radio Signals Using Wavelet Transform Based CNN

Minsuk Song¹ · Jaesung Lim^{2*} · Minwoo Lee²

¹Undergraduate Student, Department of Military Digital Convergence, Ajou University, Suwon, 47227 Korea

^{2*}Professor, Department of Military Digital Convergence, Ajou University, Suwon, 47227 Korea

요약

다양한 변조 기법을 사용하여 저피탐 능력을 갖춘 신호원들이 증가하면서, 신호의 변조 방식을 분류하는 연구가 꾸준히 진행되고 있다. 최근 신호 간섭이나 잡음 환경에서 수신 신호 분류의 성능 개선을 위하여 전처리 과정으로 FFT를 이용하는 CNN(Convolutional Neural Network) 딥러닝 기법이 제안되었다. 하지만 윈도우가 고정되는 FFT의 특성상 탐지 신호의 시간에 따른 변화를 정확히 분류해내지 못한다. 따라서 본 논문에서는 시간 영역과 주파수 영역에서 높은 해상도를 가지고 또한 다양한 유형의 신호를 시간 및 주파수 영역에서 동시에 표현할 수 있는 웨이블릿 변환(wavelet transform)을 전처리 과정으로 사용하는 CNN 모델을 제안한다. 시뮬레이션을 통해 제안하는 웨이블릿 변환 방식이 FFT 변환 방식에 비해 정확도와 학습 속도 측면에서 SNR 변화에 무관하게 우수한 성능을 보이고, 특히 낮은 SNR일 때 더욱 큰 차이를 보임을 입증하였다.

ABSTRACT

As the number of signal sources with low detectability by using various modulation techniques increases, research to classify signal modulation methods is steadily progressing. Recently, a Convolutional Neural Network (CNN) deep learning technique using FFT as a preprocessing process has been proposed to improve the performance of received signal classification in signal interference or noise environments. However, due to the characteristics of the FFT in which the window is fixed, it is not possible to accurately classify the change over time of the detection signal. Therefore, in this paper, we propose a CNN model that has high resolution in the time domain and frequency domain and uses wavelet transform as a preprocessing process that can express various types of signals simultaneously in time and frequency domains. It has been demonstrated that the proposed wavelet transform method through simulation shows superior performance regardless of the SNR change in terms of accuracy and learning speed compared to the FFT transform method, and shows a greater difference, especially when the SNR is low.

키워드: 합성곱 신경망, 신호 분류, F1-스코어, 전이 학습, 웨이블릿 변환

Keywords: Convolutional neural network, Signal classification, F1-score, Transfer learning, Wavelet transform

Received 17 June 2022, Revised 1 July 2022, Accepted 8 July 2022

* Corresponding Author Jaesung Lim (E-mail: jaslim@ajou.ac.kr, Tel:+82-31-219-2545)

Professor, Department of Military Digital Convergence, Ajou University, Suwon, 16499 Korea

Open Access <http://doi.org/10.6109/jkiice.2022.26.8.1222>

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

현대전의 양상은 정보·전자전 중심의 전쟁으로 변화하고 있다. 의도적 또는 비의도적으로 방사하는 각종 전자파 신호의 수신, 탐지, 분석 및 식별, 위치 탐지 등의 제반 활동을 통해서 획득한 정보들은 전자 공격 또는 전자 보호 대책 수립에 중요한 자료가 되며, 정보 우위의 핵심으로 그 중요도가 높아지고 있다. 정보 우위란, 필요한 적의 정보를 아군에게 정확한 시간 내에 정확한 형태로 제공함으로써 상대적인 정보 이점을 달성한 상태를 지칭한다 [1-2].

하지만 다양한 변조 기법을 사용하여 저피탐 능력을 갖춘 신호원들이 증가하면서, 전자 지원 시스템(electronic support system)에서 신호 식별은 점점 더 어려워지고 있다. 탐지된 신호의 변조 방식을 분류하는 기술은 전자 지원 시스템에서 필수적인 요소 중 하나로 이를 위한 연구가 꾸준히 진행되고 있다 [3].

최근 탐지 신호의 분류 분야에 딥러닝 기술을 적용하고자 하는 연구가 진행되고 있다 [4-5]. 딥러닝 기술의 적용은 매번 직접 분류하는 것보다 빠른 시간내에 학습이 가능하고 한번 모델을 구성하면 큰 변경 없이 유사 목적에 맞게 유연하게 활용할 수 있고 또한 낮은 비용으로 운용 가능하다는 장점이 있다. 이러한 목적으로 최근 무선 신호의 학습 모델과 전처리 과정을 다루는 연구들이 제안되어왔다 [6-7]. 탐지 신호의 데이터 처리를 위하여 데이터 정화(data cleaning)를 사용하는 방법[6]과 전처리 기법으로 FFT를 사용하는 방법[7]이 있다. 데이터 정화만 사용하는 경우는 신호가 깨끗한 상황일 때 높은 분류 정확도를 보여준다. 하지만 낮은 SNR인 경우에는 경사하강법(gradient descent method)으로 학습이 진행되는 CNN의 특성상 특징이 같은 데이터가 잡음에 의해 손상되면 분류하고자 하는 신호를 파악하지 못하고 정확도가 크게 나빠진다.

참고논문 [8]에서는 전처리 과정에 FFT를 적용한 CNN 기법을 제안하였다. FFT는 시간 영역을 주파수 영역으로 변환시키는, 즉 시간 영역에서의 신호를 주파수 성분으로 분해하는 과정이다. FFT 변환을 통해서 탐지 신호는 주파수 영역에서 비교적 쉽게 표현되고 필터를 적용하는 것과 같은 효과를 얻을 수 있지만 탐지 신호의 시간에 따른 변화를 충분히 반영하기 어렵다. 따라서 신호를 특정 길이의 윈도우로 제한하여 변환하여야 하는

데 윈도우 크기가 작아질수록 주파수 해상도가 저하되고 윈도우 크기가 커질수록 시간 영역 해상도가 떨어지는 단점이 있다. 또한 FFT 전처리 기반 CNN 기법은 다양한 종류의 변조 신호들을 분류하고자 할 때 적절한 윈도우 크기를 결정하기 어렵고 FFT의 특성으로 인하여 높은 SNR에서는 분류 정확도가 데이터 정화보다 떨어지는 문제가 발생한다 [8].

본 논문에서는 주파수 영역에 따라 scale factor가 달라지는 특성으로 시간 및 주파수 영역에서 높은 해상도를 가지고 또한 다양한 유형의 신호를 동시에 표현할 수 있는 웨이블릿 변환을 사용하여 데이터의 전처리 과정으로 이용하는 CNN 모델을 제안한다. FFT 변환 방식과 비교할 때 SNR 변화에 무관하게 정확도와 학습 속도 측면에서 우수한 성능을 보이고, 특히 낮은 SNR일 때 더욱 우수한 성능을 보임을 입증하였다.

본 논문의 구성은 다음과 같다. 2장에서는 FFT의 한계 및 제안하는 기법을 설명하고 3장에서는 시뮬레이션을 통해 제안한 기법의 성능을 분석한다. 마지막으로, 4장에서 결론을 맺는다.

II. 제안하는 웨이블릿 변환 기반 CNN 기법

본 논문에서는 그림 1과 같이 신호 분류를 위한 시스템을 구성하였다. 변조 신호 데이터 구성은 훈련(training)을 위한 데이터와 테스트 데이터로 구분하여 테스트의 결과가 학습 모델에 영향을 미치지 않도록 하였다. 이후 CNN 모델에서 학습이 용이하도록 data truncation으로 데이터 분류에 불필요한 부분을 제거하여 차원을 맞춰주었다. 정리된 데이터는 특징 추출(feature extraction)을 통해 분류가 진행되는데 본 논문에서는 데이터의 특징 추출을 위해 웨이블릿 변환으로 높은 해상도의 이미지를 만들었다. 이후 이미지 처리 능력이 뛰어난 CNN 모델을 통해 정확도를 검증하였다.

2.1. 변조 신호 데이터 구성

변조 신호 데이터 구성의 경우 데이터를 변환하고 학습시키기 이전에 데이터의 형태와 한 번에 학습할 데이터 블록의 수 등을 결정하여 데이터별 차이를 없애는 작업이다. 이 과정을 통해서 학습하는 데이터는 형태가 일정해져 CNN에서 학습하기 유리해진다. 신호의 변조를

분류하기 위해 XGboost의 앙상블 모델을 사용하였다.

앙상블 모델이란 여러 개의 분류기를 생성하고 그 예측을 결합함으로써 보다 높은 성능을 도출하는 기법이다. GBM의 경우 경사하강법을 이용하여 가중치 업데이트를 하는 방법으로 속도가 비교적 느리고 LightGBM의 경우 데이터 수의 부족으로 인한 과적합 문제가 있어 XGboost를 사용하는 것이 다른 딥러닝 모델을 사용하는 것보다 평균적으로 높은 성능을 보여주었다. 앙상블 모델의 입력 차원에 데이터를 맞추기 위하여 데이터 제거 작업을 해주었다.

그림 1에서 보이듯이 11가지의 변조 신호에 대하여 배치 크기 128개씩 나누어 학습하였다. 배치의 크기는 이보다 작은 32와 64로 설정할 경우는 본 실험 환경에서 메모리 문제가 발생하고 학습에 너무 오랜 시간이 걸렸다. 반대로 128보다 큰 배치 크기로 학습할 경우는 128보다 학습 능력이 떨어지는 결과를 보였다. 그 안의 각각의 데이터들은 성능이 높은 앙상블 모델의 차원에 맞춰 사용하기 위해 2×1024 의 형태로 잘라주었다.




Fig. 1 Proposed system model for modulated signal classification

2.2. 데이터 변환

전처리하는 기존의 데이터를 학습에 적합한 데이터로 변환하는 과정으로 모델이 생성된 이후에도 예측하고자 하는 새로운 데이터에 계속해서 적용하는 과정이다. 큰 함숫값에서 최소 함숫값을 찾아 기울기를 변화시켜가는 경사 하강법으로 학습이 진행되는 CNN의 특성상, 전처리를 통해서 데이터의 숫자 범위를 줄여 주면 큰 함숫값과 최소 함숫값의 차가 작아져 모델 학습의 성능과 학습 속도를 높일 수 있다.

전처리의 과정은 데이터 정화, 변환, 특징 스케일링의 과정을 거친다. 우선 연관성 없는 특징과 누락 데이터를 제거하는 데이터 정화 작업을 해준다. 이 작업을 통해 신호가 재밍이나 스푸핑에 당하는 등, 외부의 공격에 의한 과도한 변형이 일어나지 않은 데이터들로만 학

습함을 의미한다. 또한 테스트 시 과한 변형이 일어난 신호의 경우, 외부의 공격이 있었음을 분류해낼 수 있을 것이다. 이후 CNN에서 학습하기 편리하도록 데이터의 형식을 숫자형 데이터로 변환해준다. 배열로 변환하는 방법인 리스트와 numpy 배열 중 벡터화해서 계산하여 루프나 인덱싱없이 큰 데이터의 작업에 유리한 numpy 배열을 사용해 데이터를 정리하였다.

본 논문에서 다루고자 하는 것은 특징 스케일링 작업이다. 딥러닝 시 이미지를 숫자의 형태로 변환한 후 학습을 진행하는데 숫자의 범위가 넓은 경우 학습의 정확도가 감소한다. 기존 연구의 경우, 데이터 전처리를 스케일링만 진행하거나 주파수 관점에서 데이터를 분석하기 위해 FFT를 사용하였다. 데이터 스케일링의 경우 특성들의 평균을 0, 분산을 1로 만들어 특성들을 정규분포의 형태로 바꾸는 작업으로 잡음이 커졌을 때 높은 성능이 나오지 못했다. FFT의 경우 시계열 데이터의 분석에 많이 사용되는 기법으로 사인, 코사인 함수를 기저함수로 사용해 신호의 전체적인 주기성을 분석하는데 유용하다. 하지만 고정된 윈도우 크기로 변환이 진행되기 때문에 시간이나 주파수 중 하나의 분해능이 떨어지게 된다. 시간적 연속성을 고려하지 못하는 FFT의 특성상 높은 정확도를 보여주지 못하였다.

본 논문에서는 선행 연구의 한계를 극복하기 위해 웨이블릿 변환을 데이터 전처리 기법으로 제시한다. 웨이블릿 변환에 이용되는 웨이블릿 함수는 0을 중심으로 증가와 감소를 반복하는 진폭을 수반한 파로 국부적으로 존재하는 작은 파를 패턴으로 하여 이것을 천이시키거나 확대, 축소를 통하여 임의의 파형으로 표현된다.

웨이블릿 변환의 적용 방식은 다음과 같다. 우선 가장 낮은 스케일, 즉 고주파에서 시작하여 본 신호와 convolution한다. 이후 단계마다 스케일이 두 배가 되며 이를 최대 분해 수준까지 반복 진행한다. 처음에 적용하는 웨이블릿은 스케일이 가장 작기 때문에, 높은 주파수 영역대의 웨이블릿과의 신호와의 convolution 결과로 해당 웨이블릿과 유사한 양이 계산된다. 즉, 단계마다 필터 बैं크(filter bank)를 적용해 신호를 필터링해 특징을 표현함으로써 좋은 해상도의 이미지로 변환할 수 있다. 이러한 특징으로 웨이블릿 변환은 FFT와는 달리 신호가 비정상적인 특성을 가질 경우에도 신호의 특성을 확인할 수 있다. 연속 신호 $f(t)$ 에 대한 웨이블릿 변환은 다음과 같이 정의된다.

$$W(b,a) = \frac{1}{a} \int_{-\infty}^{+\infty} f(t) \Psi\left(\frac{t-b}{a}\right) dt \quad (1)$$

수식 (1)에서 a 는 팽창모수(dilatation parameter)로 웨이블릿 함수의 팽창과 수축을 결정한다. b 는 이동모수(translation parameter)로, b 의 변화에 따라 축을 따라 웨이블릿 함수가 움직인다.

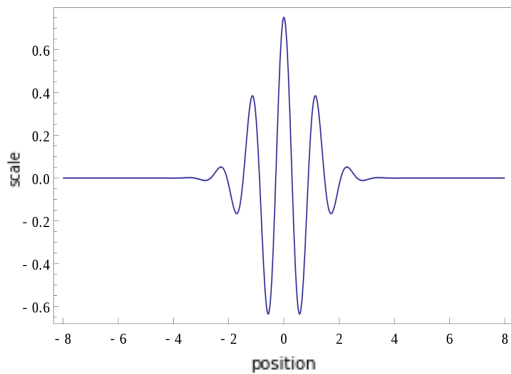


Fig. 2 Morlet wavelet function

웨이블릿 변환용 함수에는 여러 종류가 있고 현재 가장 흔하게 사용되고 있는 웨이블릿 함수는 그림 2에 보이는 함수로 Morlet 웨이블릿 함수로 다음과 같이 표현된다.

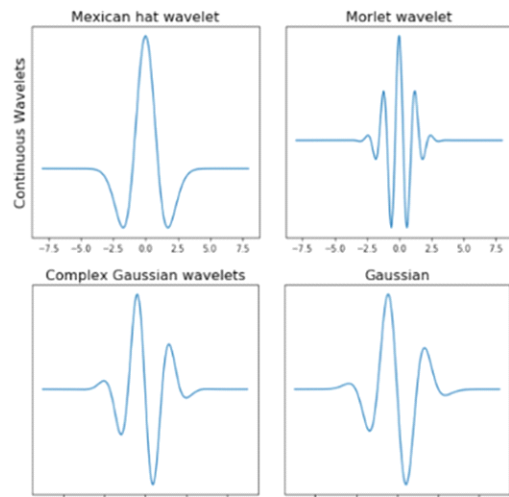
$$\Psi(t) = e^{-\frac{t^2}{2}} \cos(5t) \quad (2)$$

Morlet 웨이블릿 함수의 경우 대부분의 단변량 분석(univariate analysis)에서 사용하였을 때 타 함수들에 비해 좋은 성능을 보여준다. 그러나 이변량 분석(bivariate analysis)에서는 특성이 다른 두 시계열을 다루고 있으므로 단변량 분석에서와 같은 방식으로 모 웨이블릿(mother wavelet)을 선정하는 것이 어렵다. 모 웨이블릿을 선정할 때 하나의 시계열에는 유효하지만 다른 시계열에는 부적절할 가능성이 있기 때문이다. 하지만 단변량 분석뿐만 아니라 이변량 웨이블릿 분석에서도 특별한 근거 없이 Morlet 웨이블릿을 사용하고 있다. 이에 본 논문의 목적인 전파 시계열 데이터의 분류를 위한 가장 적합한 웨이블릿 함수를 찾아내어 사용하고자 한다.

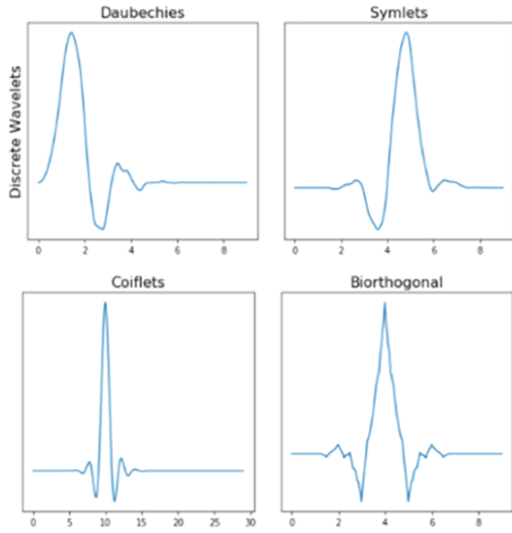
그림 3 (a)와 (b)는 본 논문에서 시뮬레이션을 위해 사용한 pytorch에서 제공하는 웨이블릿 함수들의 유형들이다. 웨이블릿 변환은 연속 웨이블릿 변환(continuous

wavelet transform)과 이산 웨이블릿 변환(discrete wavelet transform)으로 구분되며, 분석 종류에 따라 주로 사용 가능한 웨이블릿 함수 또한 달라진다. 먼저, 이산 웨이블릿 변환은 웨이블릿 규모 매개변수를 이산화하여 나타나는 것을 의미한다. 이산 웨이블릿 변환은 입력 길이와 동일한 길이의 데이터 벡터를 반환한다. 데이터는 변환 및 스케일링에 직교하는 웨이블릿 함수로 분해된다. 그러므로 그러한 신호를 신호 데이터 포인트의 수와 동일하거나 더 작은 수의 웨이블릿 계수 스펙트럼으로 분해해야 한다. 한편, 연속 웨이블릿 변환은 규모 매개변수를 보다 미세하게 이산화한 후 모 웨이블릿을 적용하는 방법이다. 연속 웨이블릿 변환은 입력 데이터보다 차원이 1개가 더 큰 배열을 반환한다. 1D 데이터의 경우 시간-주파수 평면의 이미지를 얻는다. 이에 신호의 지속 시간 동안 신호 주파수의 변화를 쉽게 관찰하고 스펙트럼을 다른 신호 스펙트럼과 비교할 수 있다 [9,10,11].

이산 웨이블릿 함수는 간단한 함수이므로 급격한 변화 혹은 계단 형태의 자료에 사용하면 결과를 얻기 쉽지만 부드러운 변화를 나타내는 것은 어렵다. 하지만 신호 데이터의 경우 서로 밀접하게 관련되어 있어 연속 웨이블릿 함수를 사용하여 큰 중복성을 찾을 수 있고 이를 통해 원하는 형태로 변환된 데이터를 관찰할 수 있다.



(a) Continuous wavelet functions



(b) Discrete wavelet functions

Fig. 3 Continuous and discrete wavelet function types

이에, 본 논문에서는 연속 웨이블릿 변환 중에서 Morlet, Mexican hat, Complex Gaussian, Gaussian의 정확도를 비교해 보고 가장 뛰어난 결과를 보이는 웨이블릿 함수를 사용할 예정이다.

2.3. 모델 학습

데이터 학습을 위한 딥러닝 기법에는 RNN, LSTM, CNN 등 다양한 방식이 존재한다. 신호 분류를 위한 딥러닝의 경우 시간 영역의 분류를 위해 RNN 계열의 모델을 사용하는 경우가 많은데, 본 논문의 경우 신호 데이터가 이미지의 형식으로 이루어져 RNN의 시변 모델의 강점보다 연산 속도의 증가나 기울기 사라짐으로 인한 학습 오류 발생의 문제가 많은 영향을 미쳤다. 이에 이미지 분류에 적합한 CNN이 사용되었다.

CNN은 이미지 인식에 주로 사용되는 신경망으로 convolution layer와 pooling layer의 조합으로 만들어진 모델을 통칭한다. CNN은 특징을 추출하는 특징 추출 계층과 추출된 특징을 분류하여 결과를 도출해 내는 분류 계층으로 이루어져 있다. 본 논문에서 사용한 CNN 모델은 그림 4와 같다 [7].

데이터 학습을 위해 훈련된 CNN 레이어 아키텍처는 그림 4와 같이 특징 추출을 위한 7개의 NN 레이어로 구성되어 있다. 처음 6개의 NN 레이어는 4개의 하위 레이어로 구성되며 회색 NN 모듈로 표시된다. 마지막 NN 계층에

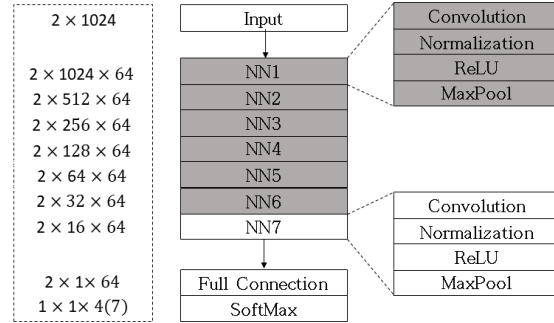


Fig. 4 CNN model

서 MaxPool 계층은 AveragePool 계층으로 대체하여 사용하였다. AveragePool을 사용한 이유는 MaxPool 사용 시 데이터의 가장 큰 특징을 두드러지게 표현하는 대신 성능이 극단적으로 나타나게 된다. 이를 막기 위해 마지막 과정으로 평균적인 특징 추출을 하는 AveragePool을 사용하였다. 분류는 sigmoid에 기반한 이진 클래스 분류가 아닌 다중 클래스 분류가 가능하고 전체 연결 계층과 교차 엔트로피 손실 함수 업데이트가 있는 SoftMax 계층을 이용하였다. 이 모든 계층은 한 층의 NN 레이어가 다음 층의 NN 레이어의 모든 뉴런과 연결된 fully connected 상태이다. 각 레이어의 차원은 왼쪽 옆에 표시된 것처럼 구성하였다. 각 1024개의 입력 데이터 예제에 대해 통계를 계산하고 예제의 통계와 연결된 실제 값 집합으로 예제를 변환하여 예제 벡터의 차원을 2×1024에서 28로 줄여 분류 작업을 간단하게 만들며 학습한다. CNN 모델의 차원을 구성할 때 2×1024에서 28로 차원을 줄이게 되는데 이를 1D CNN 모델로 구성하기 위해서 필터 크기는 3×3, 풀링 연산은 2×2가 되도록 하는 VGG 아키텍처 원칙을 따라 구성하였다. 과적합이 발생하지 않도록 50% 드롭아웃 비율을 설정하고 최대 epoch 수는 30, 미니 배치 크기는 128로 설정하였다. 데이터 세트에서 포괄적으로 학습하기 위해 0.01의 학습률로 학습을 진행하였다.

CNN 아키텍처의 변화에 따른 정확도 비교가 아닌 전처리 기법에 따른 성능 비교를 위하여 모든 경우에 위 그림의 CNN 모델의 레이어 아키텍처를 이용하였다.

III. 성능 분석

3.1. 시뮬레이션 환경

시뮬레이션을 통한 성능평가를 위해서 데이터 세트는 8개의 디지털 변조와 3개의 아날로그 변조로 이루어진 11개의 단일 반송파 변조 방식의 신호를 사용하였다. 변조 신호 방식은 다음과 같다.

- 변조 신호 방식: PAM4, QPSK, AM-SSB, BPSK, CPFSK, 16QAM, 64QAM, GFSK, AM-DSB, WBFM, 8PSK

먼저 데이터 세트의 경우 처음 비교는 깨끗한 신호의 OTA(Over The Air) 전송 채널을 고려하여 상대적으로 높은 SNR에서 간단한 분류 작업으로 이루어진다. 두 번째와 세 번째로 갈수록 분류가 어려운 데이터 세트로 낮은 SNR 환경이 고려된다.

본 시뮬레이션에서는 분류를 위한 학습 기간으로 상대적으로 짧은 관찰 기간만 고려한다. 샘플 수 1024개의 단시간 분류는 정확도가 낮아지지만, 정확도를 높이기 위해 샘플 수를 늘려 학습 시간이 길어지는 것은 비효율적이기 때문이다. 이는 수신기를 빠르게 스캔할 때와 같은 짧은 관찰 시간 또는 낮은 SNR에서의 경우로 100%의 분류율을 달성할 것이라고는 기대하지 않기 때문에 유용하게 사용될 수 있다고 판단하였다.

Table. 1 Signal Parameters

Parameter	Signal
Sampling frequency(kHz)	200
Sample length	2048
RF center frequency(MHz)	900
K factor	4
SNR(dB)	6, 0, -6
Oversampling factor	8
Number of data(samples)	2,000,000

신호에 대한 파라미터는 표 1과 같다. 샘플링 주파수는 200kHz이고 길이는 2048로 CNN에 입력 데이터가 2×1024 의 형태로 들어가게 된다. 학습에 사용된 총 데이터 수는 2백만 개이고 각각의 시뮬레이션은 SNR이 6, 0, -6dB일 때로 나누고 각각 SNR이 낮을 때부터 높을 때까지로 구분하여 각 SNR에서의 성능 비교와 정확도의 변화를 테스트하였다. 또한 정확도를 비교한 경우도 있고 confusion matrix로 결과를 분석한 경우도 있다. 정

확도는 전체 신호 중 CNN 모델이 올바르게 분류한 비율을 의미한다. Confusion matrix의 경우 F1 score를 사용해 분류가 잘 되었는지 계산하는 방법인데 준비된 데이터 셋의 경우 모든 변조 신호들의 개수가 균등하기 때문에 F1 score의 효용성이 떨어진다. 이에 성능 비교는 정확도로, 신호 분류의 오탐률 비교는 confusion matrix로 진행하였다.

그림 5는 시뮬레이션에 사용할 웨이블릿 함수를 결정하기 위해 5가지의 연속 웨이블릿 함수(Morlet, Mexican Hat, Complex Gaussian, Gaussian)의 학습 정확도를 비교한 결과이다. 보통 시간 영역에서의 해석은 Mexican Hat을, 주파수 해석은 Morlet을 사용한다. FFT와의 비교 전 웨이블릿 함수간의 성능 비교를 위해 테스트를 진행하였다.





Fig. 5 Comparison of learning accuracy of wavelet functions


실험 결과 Morlet 함수의 평균적인 정확도가 가장 높게 나타났다. Morlet 함수의 정확도는 91.7%로 Morlet 함수의 경우 다른 웨이블릿 변환에 비해서 주파수 영역의 특징을 잘 잡아내기 때문에 이러한 결과가 나온 것이라고 판단하였다. Mexican Hat의 경우와 Complex Gaussian의 경우는 epoch가 진행됨에 따라 꾸준한 정확도를 유지하지 못하고 중간에 분류 성능이 저하되는 모습을 보여 epoch 설정에 따라 성능의 차이가 보인다는 것을 확인하였다. 그 원인으로 두 함수의 경우 과적합의 문제가 발생하여 정확도가 감소하는 부분이 발생하는 것으로 판단하였다. 가우시안은 Morlet과 유사한 특성을 보이는 함수로 학습의 안정성이 높아 epoch에 따른 정확도 유지의 장점이 있으나 다른 웨이블릿 함수와 비교할 때 전체적인 정확도가 떨어졌다. 따라서 본 논문에서는 Morlet 함수를 웨이블릿 변환에 사용하여 FFT와의 비교를 진행하기로 하였다.

3.2. 시뮬레이션 결과


모델 훈련 과정에서 검증 세트(validation set)를 사용하여 테스트를 진행해 훈련 과정에서 모델 변경이 가능하게 하였다. 이는 학습 데이터의 일부를 나누어 사전 테스트를 함으로써 학습의 정확도를 예측하고 과적합이 일어나지 않는 epoch를 찾아내는 역할을 한다. 훈련에 걸리는 시간과 정확도가 중요하고 훈련을 위한 데이터 세트가 이미 많이 준비되어 있기에 훈련 과정에서 데이터 수가 부족함을 고려하여 의도적으로 훈련 데이터의 크기를 줄여 비교하는 연구는 따로 진행하지 않았다.



(a) SNR: 6dB



(b) SNR: 0dB



(c) SNR: -6dB

Fig. 6 Comparison of learning accuracy between FFT and wavelet transform: (a), (b), (c)

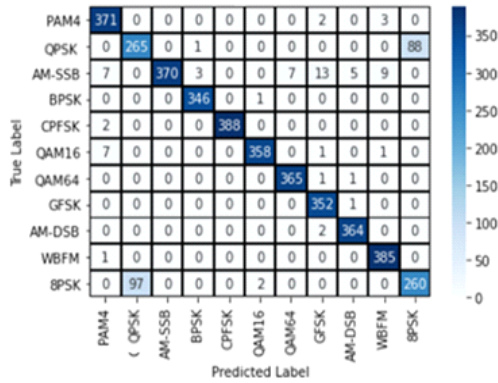
그림 6은 SNR에 따른 FFT와 웨이블릿 변환의 학습 정확도를 비교한 결과이다. SNR이 높은 신호일 때의 성능 검증은 물론 SNR이 낮아짐에 따라 정확도의 평가를 위한 목적이다.

실험 결과 SNR이 6dB 일 때는 웨이블릿 변환은 91.7%, FFT는 86.7%로 5%의 성능 차이가 발생하였다. SNR이 높은 경우에도 웨이블릿 변환의 성능이 더 좋긴 하였으나 잡음이 적어 학습 데이터와 테스트 데이터의 오차가 적고 다른 전처리 작업을 해주지 않아도 이미 해상도가 좋은 상태여서 정확도와 그에 수렴하는 속도 모두 큰 차이가 나지 않았다. 이후 SNR이 낮아짐에 따라 웨이블릿 변환과 FFT의 정확도 차이가 벌어지는 것을 확인할 수 있다. 0dB의 경우 12.8%의 차이가 -6dB의 경우 19.1%의 차이가 발생하였다.


FFT의 경우 신호를 슬라이딩 윈도우 기법처럼 특정 길이를 가진 윈도우를 시그널 위에 움직이면서, 각각 윈도우에서 FFT 변환을 한다. 특정 시간 t에 대해서 FFT를 여러 번 계산하게 되는데, 계산한 횟수만큼 평균을 구해서 특정 시간 t에서의 주파수 스펙트럼을 구한다. 이때 윈도우의 크기가 일정해야 하기에 특정 시간 주변에 주파수 스펙트럼이 비슷하게 되어 해상도가 떨어진 다. 이에 반해 웨이블릿 변환은 scale factor가 주파수의 크기에 따라 변화하기 때문에 시간 주파수 영역 모두에서 높은 해상도를 가질 수 있고 정확도 또한 SNR이 낮아짐에도 유지됨을 확인할 수 있었다. 딥러닝의 경우 학습 횟수가 늘어날수록 정확도가 일정 수준까지 증가하는데 웨이블릿 변환의 경우 FFT보다 이에 도달하기까지의 횟수가 적어지는 것을 확인할 수 있다.

그림 7은 웨이블릿 변환을 사용했을 시에 어떤 신호의 분류를 잘못했는지 확인하기 위해 SNR에 따른 웨이블릿 변환의 신호 오탐율을 나타내는 confusion matrix이다. Confusion matrix는 데이터 분석을 위한 검사 행렬로 예측값이 실제 관측값을 얼마나 정확히 예측했는지 보여주며 어떤 신호가 틀린 분류를 했는지 확인하기 위해 사용하였다.

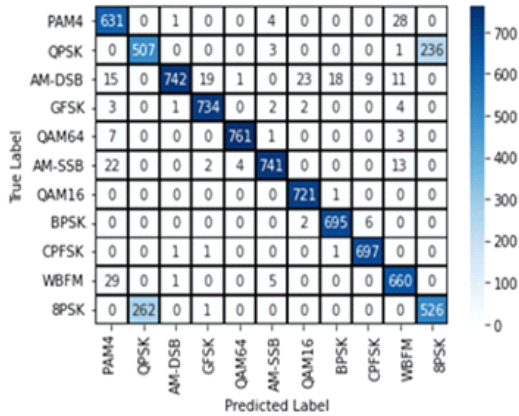
실험 결과 모든 SNR에서 QPSK와 8PSK 변조방식의 분류를 정확히 해내지 못했음을 확인할 수 있다. QPSK는 90° 위상변화를 갖는 디지털 심볼로 4진 PSK 방식이고 8PSK는 8개의 종류의 디지털 심볼로 표현되는 8진 PSK 방식이다.



(a) SNR : 6dB



(b) SNR : 0dB



(c) SNR : -6dB

Fig. 7 Confusion matrix comparison of proposed method according to SNR: (a), (b), (c)

이 두 변조 방식의 성상도(constellation map)를 비교해 보면 같은 각도에서 겹치는 심볼이 존재하여 잘못 판단하는 것을 확인할 수 있다.

IV. 결론

본 논문에서 전처리 과정에서 웨이블릿 변환을 이용한 CNN 모델을 제안하였다. FFT 변환과 다르게 웨이블릿 변환은 scale factor가 주파수의 크기에 따라 변화하기 때문에 시간과 주파수 영역 모두에서 높은 해상도를 가질 수 있어 SNR 변화에 무관하게 높은 정확도 보이고 또한 학습 속도 측면에서 우수한 성능을 보인다. 특히 낮은 SNR로 갈수록 정확도와 학습 속도의 차이가 더욱 크게 나타남을 확인했다. 하지만 변조방식의 성상도가 유사한 경우에는 여전히 구분이 모호하여 분류 성능이 제한됨을 알 수 있다. 또한 어떤 경우에도 학습한 11가지의 변조 신호 중 하나로 분류하여 신호가 손상되었을 때 정확도의 감소가 발생한다. 이에 따른 향후 개선을 위한 연구가 필요하다.

ACKNOWLEDGEMENT

This work was supported by the Future Combat System Network Technology Research Center Program of Defense Acquisition Program Administration and Agency for Defense Development under Grant UD190033ED

References

- [1] J. P. Stephens, "Advances in signal processing technology for electronic warfare," *IEEE Aerospace and Electronic Systems Magazine*, vol. 11, no. 11, pp. 31-38, Nov. 1996.
- [2] USA Joint Chief of Staffs, "Joint Vision 2010," *US Gov. Printing Office, Washington DC*, May. 1996.
- [3] P. E. Pace, "Detecting and Classifying Low Probability of Intercept Radar," MA: *Artech House, USA*, 2009.
- [4] X. Li, F. Dong, S. Zhang, and W. Guo, "A Survey on Deep Learning Techniques in Wireless Signal Recognition," *Special Physical-layer Wireless Communications*, vol. 2019, Article no. 5629572, Feb. 2019.
- [5] T. J. O'Shea and N. West, "Radio machine learning dataset generation with GNU radio," in *Proceedings of the 6th GNU Radio Conference*, Boulder: CO, USA, vol. 1, no. 1, 2016.
- [6] T. J. O'Shea, J. Corgan, and T. C. Clancy, "Convolutional

- radio modulation recognition networks,” in *Proceedings of Engineering Applications of Neural Networks*, Aberdeen, U.K., pp. 213-226, 2016.
- [7] T. J. O’Shea, T. Roy, and T. C. Clancy, “Over-the-Air Deep Learning Based Radio Signal Classification,” *IEEE Journal of Selected Topics in Signal Processing*, vol. 12, no. 1, pp. 168-179, Feb. 2018.
- [8] T. Xu and I. Darwazeh, “Deep Learning for Over-the-Air Non-Orthogonal Signal Classification,” in *Proceedings of 2020 IEEE 91st Vehicular Technology Conference*, Antwerp, Belgium, pp. 1-5, 2020.
- [9] X. Liu, D. Yang, and A. El Gamal, “Deep neural network architectures for modulation classification,” in *Proceedings of 2017 51st Asilomar Conference on Signals, Systems and Computers*, Pacific Grove: CA, USA, pp. 915-919, 2017.
- [10] S. A. A. Karim, M. H. Kamarudin, B. A. Karim, M. K. Hasan, and J. Sulaiman, “Wavelet Transform and Fast Fourier Transform for signal compression: A comparative study,” in *Proceedings of 2011 International Conference on Electronic Devices, Systems and Applications*, Kuala Lumpur, Malaysia, pp. 280-285, 2011.
- [11] M. Akin, “Comparison of wavelet transform and FFT methods in the analysis of EEG signals,” *Journal of Medical Systems*, vol. 26, no. 3, pp. 241-247, Jun. 2002.



송민석(Minsuk Song)

2022년 2월 : 아주대학교 국방디지털융합학과 졸업
2022년 6월~현재 : 공군 소위
※관심분야 : 무선신호처리, 인공지능



임재성(Jaesung Lim)

1983년 2월 : 아주대학교 전자공학 학사
1985년 2월 : KAIST 영상통신 석사
1994년 8월 : KAIST 디지털통신 박사
1995년 9월~1998년 2월 SK텔레콤 중앙연구원 책임연구원
1998년 3월~현재 : 아주대학교 국방디지털융합학과 정교수
2006년 8월~현재 : 아주대학교 국방전술네트워크 연구센터장
※관심분야 : 이동 및 위성통신, 무선네트워크, 국방전술통신



이민우(Minwoo Lee)

1998년 3월 : 한국항공대학교 항공통신정보공학과 학사
2013년 2월 : 아주대학교 일반대학원 NCW공학 박사
2019년 3월~현재 : 아주대학교 국방디지털융합학과 대우교수
※관심분야 : 위성통신, 네트워크보안, 사이버전자전