

인지 무선 네트워크에서 딥러닝을 이용한 특징 기반의 자동 변조기법 분류 방법

최익수*, 장성진*, 유상조^o

Feature-Based Automatic Modulation Classification Using Deep Learning in Cognitive Radio

Ik-Soo Choi*, Sung-Jeen Jang*, Sang-Jo Yoo^o

요약

자동변조기법 분류기술은 인지무선 환경에서 주 사용자 신호의 변조기법을 식별하기 위해 중요한 역할을 수행한다. 본 논문에서는 수신신호로부터 스펙트럼 상관함수와 그 외의 통계적 특징들을 추출하고, 추출된 데이터를 사용하여 딥러닝을 통해 신호의 변조기법을 구분하는 방법을 제시한다. 제안하는 방법에서 딥러닝 학습알고리즘 중 하나인 CNN(Convolutional Neural Network)을 신호로부터 추출된 특징의 인지 및 분류의 방법으로 사용하였고, 아날로그 및 디지털 변조신호가 분류를 위해 사용되었다. 시뮬레이션 결과를 통해 제안된 방법이 낮은 SNR에서 다른 변조신호 분류기법들보다 뛰어난 성능을 보이는 것을 확인하였다.

Key Words : Automatic modulation classification, convolutional neural network, spectral correlation function, feature extraction

ABSTRACT

The AMC (automatic modulation scheme classification) plays an important role in identifying the modulation scheme of the primary user signal in the cognitive radio environment. In this paper, we propose a method of extracting the spectral correlation function and other statistical features from the received signal and distinguishing the modulation technique of the signal through the deep learning using the extracted data. In the proposed method, CNN (Convolutional Neural Network), one of the deep learning algorithms, was used as a method of recognizing and classifying features extracted from signals and used for classifying analog and digital modulated signals. Simulation results show that the proposed method shows better performance than other modulation signal classification methods at low SNR.

※ 이 논문은 2018년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업(2017R1A2B4003512). 본 연구는 과학기술정보통신부 및 정보통신기술진흥센터의 대학ICT연구센터 육성 지원사업의 연구결과로 수행되었음 (IITP-2018-2014-1-00729)

♦ First Author : Inha University Department of Information and Communication Engineering, ischoi.win@gmail.com, 학생회원

^o Corresponding Author : (ORCID:0000-0003-1533-0814) Inha University Department of Information and Communication Engineering, sjyoo@inha.ac.kr, 종신회원

* (ORCID:0000-0002-0087-9751) Inha University Department of Information and Communication Engineering, sungjeen_jang@inha.edu

논문번호 : KICS2018-02-001, Received February 22, 2018; Revised May 30, 2018; Accepted May 30, 2018

1. 서 론

주파수 스펙트럼에 대한 수요가 더욱 증가하면서 할당 가능한 주파수 자원이 부족해지고 있기 때문에 전파 스펙트럼을 효율적으로 사용할 수 있는 스마트한 기법이 필요하다. 따라서 주 사용자의 주파수 스펙트럼을 감지(sensing)하여 주 사용자의 존재 여부를 확인하고 기회적으로 해당 주파수에 접근하여 주파수 사용효율을 증가시킬 수 있는 인지무선기술이 관심을 받고 있다¹⁾. 인지무선(CR : Cognitive Radio)기술은 주파수 대역을 배타적으로 사용하는 주 사용자(Primary User)가 특정 주파수 대역을 사용하고 있는지의 여부를 확인하기 위해 전파환경을 측정하고, 해당 주파수 대역이 비어 있는 경우 그 환경에 적합하도록 무선기기의 운용 파라미터를 설정하여 동작하는 무선통신 기술이다. 인지무선에서는 채널특성을 고려한 무선기기 용량의 최대화, 주 사용자와 부 사용자(Secondary User)간의 간섭 최소화, 기기종 시스템간의 상호 연동성 등이 중요하게 고려되어야 한다²⁾. CR 네트워크 환경에서 특정 주파수에 대한 권한이 없는 부 사용자는 해당 주파수에 대한 권한을 가진 주 사용자가 이를 사용하지 않을 때 이러한 유휴대역(Spectrum hole, white space)을 기회적으로 사용할 수 있어야 한다.

인지무선의 필수적인 동작 방법은 스펙트럼 감지와 다음에 이어지는 데이터 전송이다. 스펙트럼 감지를 통해 전송기회를 확보한 후의 데이터 전송은 주 사용자에게 미치는 간섭을 최소화하고 처리량을 최대함으로써 시스템의 전체 성능을 최적화할 수 있도록 이뤄져야 한다³⁾. 인지무선 시스템은 기존의 무선통신 시스템과 달리 고정된 주파수 대역에서 동작하지 않고 유휴대역을 찾아 다양한 주파수 대역을 이동하며 통신을 수행한다. 인지무선시스템은 이러한 특성을 사용하여, 상업적인 측면에서 다양한 주파수 대역에서 여러 변조기술을 사용할 수 있는 다표준 통신시스템(multi-standard communication system)이 부가적인 정보 없이 송신신호를 인식(블라인드 변조 인식 : Blind modulation recognition)하여 송신기와 동기화를 수행하는 경우 오버헤드(overhead) 감소를 통해 전송효율을 증가시킬 수 있고, 균용적인 측면에서는 블라인드 변조인식을 통해 통신시스템에 대한 피아식별이 가능하고 그에 따른 보안관리가 가능해진다⁴⁾. 따라서 인지무선에서는 해당대역에서 동작하는 우선사용자들은 구분하기 위해 다양한 변조기법들을 효과적으로 분류할 수 있는 기술이 필요하다.

자동변조분류기술은 인지무선환경에서 주사용자가 사용하고 있는 신호변조형태를 구분하기 위해 사용되는 중요한 기술이다⁵⁻⁷⁾. 자동변조분류기술에는 우도(Likelihood) 기반의 자동변조 분류기법과 특징추출(Feature extraction) 기반의 자동변조 분류기법이 있다. 우도기반의 결정이론기법은 확률밀도 함수를 정의하고 가설검정을 사용하여 이뤄진다. 우도기반의 자동변조 분류는 최적의 성능을 제공하지만 수신신호의 위상, 타이밍 오류 주파수 오프셋과 같은 다양한 파라미터에 대한 정확한 정보가 필요하고 복잡도가 높기 때문에 실제 시스템에서 구현하기 어렵다⁸⁾.

반면 특징추출 기반의 자동변조 분류기법은 수신신호에 대한 사전인지정보를 덜 요구하는 준최적 방법이다. 대부분의 특징추출 기반의 자동변조 분류기법은 최대전력스펙트럼밀도, 진폭의 표준편차, 위상, 주파수, 영점교차(zero crossing)에 대한 분산을 사용한다^{9,10)}. 이외에도 고차원 통계값(HOS : High Order Statistics) 기반의 자동변조 분류 알고리즘은 잡음이 있는 기저대역에서 분포의 모양에 대한 특징을 도출할 수 있는 고차원 통계값을 이용한다. 각각의 통계값들을 통해 개별적으로 변조기법을 분류할 수는 없으나 통계값들을 사용하여 적절한 분류구조 및 조합을 사용하여 최적의 성능을 낼 수 있다. 이러한 특징기반의 분류기법들은 수신된 신호로부터 특징들을 추출하고 분류기를 사용하여 각 변조기법의 특징들을 인지하여 변조기법을 분류한다^{11,12)}.

신호변조의 분류에 사용될 수 있는 또 다른 특징은 신호의 주기적 정상성(cyclostationarity)이다. 주기적 정상성은 신호의 주기성이나 평균과 자기상관과 같은 통계적 특성에 기인한다. 전력스펙트럼 밀도 대신에 변조된 신호에 대한 주기적 상관함수를 사용하여 특정변조 신호에 대한 독특한 주기성 패턴을 도출할 수 있으며 이는 잡음에 민감하지 않다.

디지털 신호 및 아날로그 신호에서 특징을 추출하여 해당 특징을 적용한 자동변조 분류기술에 대해 많은 연구가 진행되고 있다. 기존 알고리즘들의 경우 DT(Decision Tree)와 SVM(Support Vector Machine), ANN(Artificial Neural Network)를 통한 자동변조인식 연구가 주로 진행되어왔다¹³⁻¹⁵⁾. 최근에는 딥러닝(Deep-learning)을 이용한 자동변조분류기술이 제안되고 있다. 딥러닝¹⁶⁾은 빅데이터(Big Data)와 하드웨어¹⁷⁾ 성능의 향상으로 인해 주목을 받고 있는 기계학습 방법의 새로운 영역이며 최근 컴퓨터 비전(vision), 자연어 처리(NLP : Natural Language Processing) 등의 응용프로그램에서 성공적으로 사용

되고 있다. 딥러닝은 성능향상을 위한 파라미터의 최적화를 위해 특징을 추출하는데 있어 유연한 방법을 제공하기 때문에 기존의 일반적인 기계학습에 비해 더 나은 성능을 보인다¹⁸⁾. 그러나 딥러닝 모델은 충분한 데이터가 지원되지 않으면 깊고 복잡한 구조에서 과적합 문제가 발생한다. 합성곱 신경망 (CNN : Convolutional Neural Network)는 컴퓨터 비전에 있어 대표적으로 사용되는 딥러닝의 구조들 중 하나이다.

본 논문에서는 인지무선환경에서 딥러닝을 이용하여 신호의 특징을 이용하는 자동변조기법 분류방법을 제안한다. 신호를 생성하여 해당 신호를 디지털 또는 아날로그 신호로 변조시킨 후에 레일리 페이딩 (Rayleigh fading)과 AWGN (Additive White Gaussian Noise) 채널로 신호를 전송한다. 이후 수신기에서 대역통과필터(Bandpass filter)를 사용하여 관심 있는 대역의 신호를 수신한 후에 특징을 신호로부터 추출한다. 본 논문에서 사용하는 특징은 신호의 주기적 정상성과 변조신호의 통계적인 특징이다. 해당 특징을 얻은 후에 딥러닝 기법 중의 하나인 CNN을 이용한 분류방법을 사용하여 변조신호의 종류를 구분한다.

본 논문의 구성은 다음과 같다. 2장에서는 기존에 제안된 변조분류방법에 대해 살펴본다. 3장에서는 제안된 시스템의 구조를 기술하였다. 4장에서는 CNN 기반의 분류방법에 대해 기술하였다. 5장에서는 제안된 기법의 성능을 시뮬레이션을 통해 확인할 수 있고 6장에서는 본 논문의 결론을 기술하였다.

II. 관련연구

자동변조 분류기술은 최대우도 및 신호의 특징값을 이용한 분류기술이 있다. Zhijin은 기존의 변조기법을 분류하기 위해 최대사후확률(MAP : Maximum Posteriori Probability)을 사용하는 최적 분류기를 확장하여 MPSK 분류를 위해 반송파주파수 추정오차에 의한 영향과 전송전력변화 및 심볼률 변화에 의한 영향을 줄이는 최대우도 분류기를 제안하였다¹⁹⁾. Chavali는 잡음이 시간적으로 상관된 비가우시안인 경우 디지털 진폭-위상변조 신호들의 분류를 위해 백색화 필터를 사용하여 최대우도 변조신호분류의 복잡도를 감소시켰다²⁰⁾. 한편, Wei는 디지털 진폭-위상 변조에 대한 일반적인 최대우도 분류기의 이론적인 성능분석을 제시하였다²¹⁾. 최대우도기법은 최적의 성능을 제공하지만 높은 복잡도를 갖는다. 반면, 적절히

디자인된 특징기반 분류기법은 계산복잡도를 감소시키면서 최대우도기법에 근사한 성능을 보일 수 있다.

신호의 특징값을 사용하는 방법으로 Nandi는 신호의 진폭, 위상, 푸리에 변환의 순시값을 사용하여 특징값을 계산하고 각각의 특징값에 대한 문턱값을 기반으로 결정트리를 통해 변조신호를 구분하였다²²⁾. Khoribi과 Louis는 위상, 진폭, 주파수의 순시값을 사용하여 인공신경망을 통해 변조신호를 학습 및 분류하였다^{23,24)}. Nandi는 또 신호의 중심변환 정규화된 순시진폭의 전력스펙트럼에 대한 최대값, 순시위상의 비선형값들에 대한 특정값 이상의 절대값 표준편차, 순시위상의 비선형값들에 대한 특정값 이상의 표준편차, 스펙트럼 대칭성, 순시진폭의 중심변환 정규화된 절대값에 대한 표준편차, 순시주파수의 중심변환 정규화된 절대값에 대한 표준편차의 특징값을 계산하고 이를 인공신경망을 통해 학습 및 분류하였다²⁵⁾. Yin은 변조신호의 진폭, 위상, 주파수에 대한 통계적 특성을 one-class SVM의 훈련벡터 샘플로 사용하고 베이시안(bayesian) 분류기를 사용하여 변조신호를 분류하였다²⁶⁾. Kim은 진폭, 위상, 주파수의 순시값, 고차 통계누울 및 진폭의 첨도(kurtosis), 왜도(skewness)를 포함한 21개의 통계적 특성을 특징값으로 사용하여 딥러닝을 통해 변조신호를 분류하였다²⁷⁾. Engin은 변조신호의 특징값을 추출하기 위한 웨이블릿 변환필터 종류와 엔트로피(entropy) 변수, 그리고 SVM 분류기에 사용할 커널(kernel)함수종류, 커널함수 변수, SVM의 소프트 마진(soft margin) 상수를 유전자알고리즘의 염색체로 사용하여 분류특성이 좋은 염색체를 얻고 SVM을 통해 변조신호를 분류하였다²⁸⁾.

한편 웨이블릿(wavelet) 변환을 통해 잡음의 영향을 최소화하고자 하는 연구들도 이뤄져왔다. Liu는 디지털 변조신호의 분류를 위해 웨이블릿 변환과 FRFT (FRactional Fourier Transform)을 통해 관측신호간의 차이를 증가시켜 이를 변조신호 구분의 특징으로 사용하였다²⁹⁾. Hassan은 변조신호들에 대한 연속 웨이블릿 변환의 고차 통계 모멘트 특성을 주성분 분석법 (PCA : Principle Component Analysis)으로 부분집합화하여 결합된 고차 통계 모멘트(moment)에서 최적의 부분집합을 선택할 수 있는 기반을 만들었다. 최종적으로는 인공신경망을 통한 학습 및 분류로 디지털 변조신호와 변조차수를 분류하였다³⁰⁾.

한편, Chen은 디지털 변조신호들의 스펙트로그램을 사용하여 17개의 모멘트 특성³²⁾과 주성분분석법을 사용해 각 변조신호들의 특징을 추출하고, SVM을 분류기로 사용하였다³¹⁾. Spooner는 간섭신호가 있는 상

황에서 n 차 순환누율(cyclic cumulant)을 사용하여 특징을 추출하고 최소거리분류를 사용하여 변조신호를 분류하였다^[33].

그리고 변조신호에 내재되어 있는 주기성을 사용하여 분류하고자 하는 연구들이 이뤄져왔다. Satija는 스펙트럼 상관함수를 통해 변조신호의 주기적정상성을 신호특징으로 추출하고 이를 인공신경망, SVM, k-NN (k-Nearest Neighbor), 선형판별분석법 (LDA : Linear Discriminant Analysis), 나이브 베이즈 분류기 (Naive Bayes Classifier), 뉴로-퍼지 분류기 (Neuro-Fuzzy Classifier)로 분류성능을 검증하였다. Mendis는 변조신호의 주기적 상관성을 신호 특징값으로 사용하여 딥러닝을 통해 변조신호를 분류하였다^[34].

최근 이미지 처리 및 다양한 인공지능 알고리즘으로 관심을 받고 있는 딥러닝은 변조신호들의 추출된 특징을 이용하여 학습을 시키고 변조신호를 분류하는 연구에 많이 이용되고 있다. 하지만, 딥러닝 알고리즘에서 계층의 개수가 증가하거나 각 계층이 가지는 노드의 수가 증가하게 되면 학습 시간이 길어진다는 단점이 있다. 또한 일정량 이상의 학습 데이터를 확보해야 성공적으로 학습시킬 수 있다. 이러한 단점을 해결하기 위해 본 논문에서는 디지털 변조신호와 아날로그 변조신호를 충분히 사용하고, 딥러닝 알고리즘 중 강력한 성능을 가지는 CNN (Convolutional Neural Network)을 사용하여 최소한의 데이터로 변조 정확도의 높은 성능을 보이려 한다. 제안한 시스템에서는 수신된 신호에서 주기적 상관함수 데이터와 순시값을 가지는 특징 데이터 값을 모두 사용하여 변조신호를 분류한다.

III. 제안하는 분류기 시스템 구조

본 논문에서의 시스템 구조는 그림 1과 같다. 디지털 정보를 가진 신호와 아날로그 신호를 발생시켜 변조를 하고 레일레이 페이딩과 AWGN을 가지는 채널에 전송한다. 이후 수신기는 대역통과필터(Bandpass filter)를 거쳐 관심 있는 대역폭의 신호를 샘플링하여 스펙트럼상관함수 (SCF : Spectral Correlation Function) 데이터와 본 논문에서 정의하는 특징값을 추출한 후 CNN을 이용하여 학습시킨다. 제안된 시스템에서는 2차원 정보를 갖는 SCF는 컨볼루션 레이어로 직접 입력되고 그 외 특징 데이터들은 완전연결 계층(Fully connected layer)로 입력된다. 일반적으로 CNN을 사용하는 경우에 학습에 이용되는 입력 데이

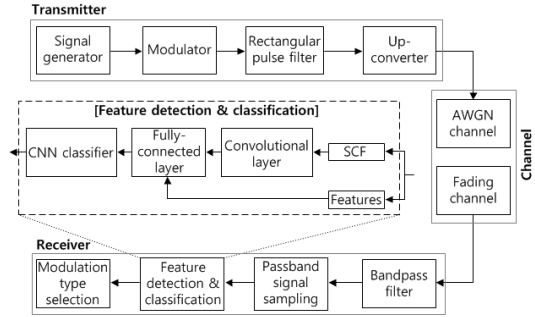


그림 1. 제안하는 시스템 구조
Fig. 1. Proposed system architecture

터를 한 종류만 입력시켜 학습을 하지만 제안하는 구조는 두 종류의 데이터를 사용하여 CNN이 신호특성을 학습하는데 한 종류의 데이터를 사용할 때보다 더 적은 데이터의 양을 효율적으로 학습시킬 수 있다. 최종적으로 수신기는 분류기를 통해 송신신호의 변조기법을 판별한다.

3.1 스펙트럼 상관 함수 (Spectral Correlation Function)^[35]

본 논문에서는 그림 1과 같은 시스템 구조의 학습 알고리즘에 적용하는 데이터를 추출하는데 있어서 신호의 주기적 정상성을 특징으로 사용하기 위해 스펙트럼 상관 함수를 사용한다. 랜덤과정 $x(t)$ 의 평균과 자기상관이 주기적이면 (즉, $\mu(t+T) = \mu(t)$, $R_s(t+T, w+T) = R_s(t, w)$) 이를 주기적 정상과정이라 한다. 스펙트럼 상관 함수는 수신된 신호의 자기상관에 대한 푸리에 변환을 통해 얻을 수 있다. 원 신호 $x(t)$ 의 자기상관은 식 (1)과 같이 정의된다.

$$R_s(\tau) = E \left[x \left(t + \frac{\tau}{2} \right) x \left(t - \frac{\tau}{2} \right) \right] \quad (1)$$

T 에 대해 주기적인 주기적 정상신호의 자기상관은 다음과 같이 나타낼 수 있다.

$$R_s(t+T, \tau) = R_s(t, \tau) \quad (2)$$

따라서 푸리에 급수를 사용하여 다음과 같이 확장할 수 있다.

$$R_s \left(t + \frac{\tau}{2}, t - \frac{\tau}{2} \right) = \sum_{\alpha_0} R_s^{\alpha_0} e^{-j2\pi\alpha_0 t} \quad (3)$$

여기서, α 는 주기적 주파수(cyclic frequency)라고 하며 $k = 1, 2, 3, \dots$ 에 대해 k/T 이다.

$$R_s^{\alpha_0}(\tau) = \lim_{T \rightarrow \infty} \int_{-T/2}^{T/2} R_s(t, \tau) e^{i2\pi\alpha_0 t} dt \quad (4)$$

Weiner 이론은 주기적 정상상태로 확장될 수 있다. 그러면 스펙트럼상관함수는 주기적 자기상관함수의 푸리에변환으로 다음과 같이 나타낼 수 있다.

$$S_s^{\alpha_0} = \int_{-\infty}^{\infty} \hat{R}_x^{\alpha_0} e^{-j2\pi f\tau} d\tau \quad (5)$$

시간에 대해 불변인 푸리에변환 $S_t(t, f)$ 의 주기적 주기도표(cyclic periodogram)를 다음과 같이 정의할 수 있다.

$$S_{sT}^{\alpha_0}(t, f) = \frac{1}{T} S_T\left(t, f + \frac{\alpha_0}{2}\right) S_T^*\left(t, f - \frac{\alpha_0}{2}\right) \quad (6)$$

여기서,

$$S_T(t, f) = \int_{t-T/2}^{t+T/2} s(v) e^{-j2\pi f v} dv \quad (7)$$

따라서 주기적 상관함수는 $S_{sT}^{\alpha_0}(t, f)$ 의 주파수 평활화(frequency smoothing)로 추정된다.

$$S_{sT}^{\alpha_0}(t, f)_{\Delta f} = \frac{1}{\Delta f} \int_{f-\Delta f/2}^{f+\Delta f/2} S_{sT}^{\alpha_0}(t, u) du \quad (8)$$

그러면 주기적 상관함수는 관측시간 T 를 증가시키고 Δf 를 줄여서 다음과 같이 얻을 수 있다.

$$S_s^{\alpha_0}(f) = \lim_{\Delta f \rightarrow 0} \lim_{T \rightarrow \infty} S_{sT}^{\alpha_0}(t, f)_{\alpha_0} \quad (9)$$

따라서 스펙트럼 일관성(spectral coherence) 함수는 주파수가 $-\alpha_0/2$ 와 $\alpha_0/2$ 인 두 스펙트럼의 공분산이 된다. 따라서 스펙트럼 일관성 함수는 다음과 같다.

$$C_s^{\alpha_0}(f) = \frac{S_s^{\alpha_0}(f)}{[S_u(f)S_v(f)]^{1/2}} \quad (10)$$

여기서,

$$S_u(f) = S_s(f + \alpha_0/2) \text{ and } S_v(f) = S_s(f - \alpha_0/2) \quad (11)$$

주기적 정상성은 주파수 차원과 주기적 주파수 차원의 2차원 정보로써 각 변조신호마다 고유한 주기적 특징을 나타내므로 본 논문에서는 CNN의 합성곱 계층에 입력하여 변조신호의 특징으로 사용한다.

3.2 특징 추출 방법(Feature Extraction Method)

제안하는 시스템에서는 수신된 변조신호의 주기적 정상성 외에도 진폭, 위상, 주파수의 순시값에 관련된 특징값을 추출하여 사용한다. 제안하는 시스템에서는 11개의 특징값을 사용한다^{12,27}. 다양한 특징값들이 사용가능하지만, 우리는 각 변조신호의 실험적인 분포가 잘 구분되는 특징들을 선택하여 사용한다. 선택된 특징은 CNN내에서 완전연결계층의 입력으로 사용되어 SCF데이터 학습이후에 추가적인 신호의 특징을 같이 포함하여 변조신호의 분류성능을 향상시키고자 하였다.

첫 번째 특징은 복소신호와 실수신호를 구분하기 위해 다음과 같이 신호의 동 위상 성분과 직각 성분의 전력비율을 사용한다.

$$\beta = \frac{\sum_i a_Q^2[i]}{\sum_i a_I^2[i]} \quad (12)$$

여기서, $a_I[i]$ 과 $a_Q[i]$ 은 수신된 신호에 대한 동 위상 성분과 직각 성분 신호의 샘플이다. 신호전력이 상당히 높은 경우 복소신호에 대해 $\beta \approx 1$ 이며 실수신호에 대해 $\beta \approx 0$ 이다.

두 번째 특징은 일정크기 이상의 신호에서의 순시 위상(절대값이 아닌)에 대한 비선형 요소의 표준편차이다.

$$\sigma_{dp} = \sqrt{\frac{1}{C} \left(\sum_{a_n[i] > a_t} \phi_{NL}^2[i] \right) - \left(\frac{1}{C} \sum_{a_n[i] > a_t} \phi_{NL}[i] \right)^2} \quad (13)$$

여기서, $a[i] = a_I[i] + ja_Q[i]$, $a_n[i] = a[i]/E(a[i])$ 이고, $\phi_{NL}[i]$ 는 시간 $t = iT_s$ 에서의 순간 위상이다. a_t 는 문턱값이고 C 는 문턱값 이상의 진폭에 대한 위상 샘플의 개수이다.

세 번째 특징은 일정크기 이상의 신호에서 순시위상의 비선형 요소에 대한 절대값의 표준편차이다²²⁾.

$$\sigma_{ap} = \sqrt{\frac{1}{C} \left(\sum_{a_n[i] > a_t} \phi_{NL}^2[i] \right) - \left(\frac{1}{C} \sum_{a_n[i] > a_t} |\phi_{NL}[i]| \right)^2} \quad (14)$$

네 번째 특징은 정규화 및 중심이동된 신호의 순시진폭에 대한 절대값의 표준편차이다.

$$\sigma_{aa} = \sqrt{\frac{1}{N} \left(\sum_{i=1}^N a_{cn}^2[i] \right) - \left(\frac{1}{N} \sum_{i=1}^N |a_{cn}[i]| \right)^2} \quad (15)$$

여기서, $a_{cn}[i] = a[i]/E(a[i]) - 1$ 이고 N 은 $a_{cn}[i]$ 에 대한 샘플 수이다.

다섯 번째 특징은 신호에 대해 평균화 및 중심이동된 순시주파수에 대한 표준편차이다.

$$\sigma_{af} = \sqrt{\frac{1}{N_s} \left[\sum_{i=1}^{N_s} f_N^2(i) \right] + \left[\frac{1}{N_s} \sum_{i=1}^{N_s} |f_N(i)| \right]^2} \quad (16)$$

여기서, $f_N(i)$ 는 중심이동된 순간 주파수이다.

여섯 번째 특징은 다음과 같이 얻을 수 있다.

$$\sigma_v = \sqrt{\frac{1}{N} \left(\sum_{i=1}^N a_v[i]^2 \right) - \frac{1}{N} \left(\sum_{i=1}^N |a_v[i]| \right)^2} \quad (17)$$

여기서, a_v 는 평균화된 신호 크기이다 (즉, $\sqrt{a[i]/\text{Var}(a[i])} - 1$).

일곱 번째 특징은 신호크기의 평균값을 사용한다.

$$X = \frac{1}{N} \sum_{n=1}^N |a[i]| \quad (18)$$

여기서, $|a[i]|$ 는 순간크기이다. 위상천이키잉신호의 진폭은 심볼모양에 의해 변하더라도 진폭은 크기 1의 근처에서 진동한다. 반면 직교진폭변조의 진폭에 대한 평균은 위상천이보다 상당히 크기 때문에 구분할 수 있는 인자가 된다.

다음 특징은 신호샘플들의 크기의 합을 표준화한 제공근 값을 사용한다.

$$X_2 = \frac{\sqrt{\sum_{i=1}^N |a[i]|}}{N} \quad (19)$$

그리고 표준화된 신호샘플의 전력 스펙트럼 밀도의 최대값은 다음과 같이 정의한다.

$$\gamma_{\max} = \frac{1}{N} \max |\text{DFT}(a_{cn}[i])|^2 \quad (20)$$

순시진폭의 평균화는 채널이득을 보상하기 위해 필요하다. 따라서 γ_{\max} 는 신호의 평균화 및 중심이동된 순시진폭에 대한 전력스펙트럼밀도의 최대값이다.

또한 우리는 제공평균 대비 최대 비율인 PR(Peak-to-rms Ratio)과 평균 대비 최대 비율인 PA(Peak-to-Average)를 사용한다.

$$PR = \frac{\max |a|^2}{\frac{1}{N} \sum_{i=1}^N (a[i])^2} \quad (21)$$

$$PA = \frac{\max |a|}{\frac{1}{N} \sum_{i=1}^N a[i]} \quad (22)$$

다음과 같이 정의한 11개의 특징을 수신된 신호로부터 추출하여 딥러닝의 입력으로 사용한다. 본 논문에서는 수신된 신호에 대해 SCF와 정의한 11개의 특징을 동시에 추출하여 CNN 구조의 병렬적으로 입력하여 학습시킨다. 두 종류의 특징을 사용하는 이유는 SCF는 매우 낮은 SNR(Signal-to-Noise Ratio)을 가진 채널과 다중경로의 페이딩을 가진 채널을 동시에 통과하게 되면 SCF 패턴을 잘 확인할 수 없기 때문에 해당 환경에서도 변조신호의 특징이 잘 드러나도록 하기 위해 사용한다.

IV. 제안하는 CNN 알고리즘 동작 방법

딥러닝 알고리즘 중 하나인 CNN은 크게 세 가지 종류의 계층인 합성곱 계층과 풀링(pooling) 계층, 그리고 전체 연결 계층을 가지고 있다. 합성곱 계층은 입력으로부터 통과해온 이전 계층의 특징을 추출하고 입력과 학습하는 필터의 집합 사이에서 2차원적인 합성곱 동작을 한다. 그 후에 새로운 특징을 가지는 스택(stack)이 생성되어 다음 계층으로 공급된다. 수학적으로 각 계층의 출력 특징맵(feature map)은 다음과 같이 정의 할 수 있다.

$$X_n = f \left(\sum_m W_n^m * X^m + b \right) \quad (23)$$




그림 2. 제안하는 CNN 블록 선도
Fig. 2. Proposed-CNN block diagram

여기서, X_n 은 n 번째 특징 맵을 나타내고, W_n^m 은 컨볼루션 동작을 하는 필터를 의미한다. 그리고 b_n 은 각 특징맵에 대응하는 바이어스 값을 나타낸다.

합성곱 계층의 연결은 뉴런(neuron)이 입력 크기의 로컬(local) 영역과 연결될 수 있게 하므로 모델의 매개변수 수를 크게 줄일 수 있다. 이러한 연결 패턴은 CNN이 일반 신경망에서는 계산할 수 없는 더 큰 차원의 입력을 사용할 수 있도록 허용한다. 풀링 계층은 일반적으로 합성곱 계층 다음에 삽입되어 특징 맵의 크기를 줄여주므로 마찬가지로 매개변수의 수를 줄이는 동작을 한다. 이것은 특징맵에서 단위의 작은 패치(patch)를 모으는 비선형 다운샘플링 연산이며, 일반적으로 쉬프트(shift) 보폭 1을 가지는 영역의 값을 최대화하는 최대화 풀링(Max Pooling)을 사용한다. 더불어 CNN기반의 모델의 마지막 부분에는 일반적으로 사용되는 다수의 완전연결 계층을 사용한다. 완전연결 계층은 모든 뉴런이 이전 계층의 뉴런과 완전히 연결되어 있는 행렬곱셈을 구현하는 일반 신경네트워크의 계층과 동일하다.

그림 2로부터 제안하는 시스템의 CNN 분류기 구조는 크게 보서는 일반적인 CNN과 동일하다. 하지만 본 논문에서는 일반적인 CNN의 구조와는 다르게 두 가지 종류의 입력 데이터를 사용한다. SCF 데이터는 SNR이 높은 경우에 변조신호를 분류 및 인지하기에 용이하고 특징 데이터는 잡음에 강하기 때문에 SNR

이 낮을 때에도 인지가 가능하다. SCF 데이터에서 인지가 어려운 경우에 추가적으로 특징 데이터를 입력함으로써 일정량의 데이터로 최대의 성능을 낼 수 있다. 그래서 수신자는 수신된 신호로부터 SCF의 데이터와 특징 데이터 두 가지 모듈을 추출하여 SCF 데이터는 합성곱 계층의 입력으로 들어가고, 특징 데이터는 완전연결 계층의 입력으로 사용하여 병렬적으로 학습을 하여 매우 불안정한 무선환경에서도 변조방식을 잘 분류할 수 있는 학습알고리즘을 제안한다.

제안하는 CNN의 상세구조는 그림 3과 같이 나타낼 수 있다. SCF 데이터는 3개의 합성곱 계층과 2개의 풀링 계층을 거친 후에 특징 데이터와 함께 완전연결 계층의 입력으로 사용되어 변조방식을 분류하게 된다. 제안하는 시스템에서 사용하는 SCF 데이터의 크기는 주파수 차원과 순환주파수 차원에 해당하는 $[512 \times 512]$ 의 이차원 행렬을 사용하고(주기적 주파수 α 의 개수는 512), 각 합성곱 계층에서 사용하는 필터의 크기와 개수는 $[5 \times 5 \times 3, 5 \times 5 \times 6, 5 \times 5 \times 12]$ 를 사용한다. 풀링 계층에서 사용되는 최대값 풀링은 보폭이 1인 $[2 \times 2]$ 크기의 필터를 사용한다. 그렇다면 입력값의 크기는 완전연결 계층으로 통과하기 전까지 처음 크기보다 줄어들게 된다. 이후 줄어든 입력크기 값에 특징 데이터를 추가한 데이터를 일차원으로 변환하여 완전연결 계층의 입력으로 사용한다. 마지막 계층에서는 소프트 맥스




그림 3. 제안하는 CNN 동작 상세 구조
Fig. 3. Proposed-CNN operation architecture

(Soft Max) 계층을 사용하여 각 변조방식으로 선택될 값을 확률값으로 출력하도록 설계하였다.

V. 성능평가

5.1 시뮬레이션 환경 조건

제안하는 시스템의 성능을 평가하기 위해서 조건들을 크게 3가지의 측면에서 나눌 수 있다. 첫 번째는 변조신호를 생성하고 송신하는 송신자의 측면에서 조건들을 표 1과 같이 나타낼 수 있다. 제안하는 시스템에서 사용하는 그림 1의 신호 발생기에서 만든 신호는 기저대역에서 변조된 후 높은 주파수를 가지는 통과대역의 신호로 변환하여 전송한다. 통과대역의 신호로 변환할 때 가지는 반송 주파수의 크기는 500MHz 이고, 관심 있는 대역폭은 1MHz이다. 제안하는 CNN 학습 알고리즘에 적용하는 변조방식은 디지털 변조방식인 BPSK, BASK, BFSK, QPSK, 16QAM과 아날로그 변조방식인 AM, FM을 사용한다. 각 변조방식이 가지는 심볼 속도는 일정한 값으로 지정하고, 데이터 속도는 각 변조방식에 따라 다르게 하였다. 그리고 잡음이 나타나는 채널은 SNR 값을 랜덤으로 설정한 것과 고정된 값을 설정하여 두 가지의 상황을 고려했다.

수신기는 송신기로부터 수신한 신호에 대해 대역통과필터를 사용하여 관심있는 대역의 신호만을 추출하고 추출한 신호를 샘플링 주파수의 크기로 샘플링을 한다. 이때 샘플링 주파수의 값은 표 2에 나타낸 바와 같이 대역폭의 2.5배정도이고, 수신된 신호의 길이는 감지시간에 따라 달라지는데, 감지시간이 길어질수록

표 2. SCF와 특징 추출 부분의 파라미터(수신자 측면)
Table. 2. Part of extracting SCF and feature data(receiver)

Parameters	Value
Sensing Time	3 ms
Sampling Frequency(f_s)	$f_s > 2.5 \times W(\text{bandwidth})$
Number of Cyclic Frequency(α)	512
N-pont FFT	512
Window Length	128

샘플 수는 늘어난다. 샘플링한 신호를 사용하여 SCF 데이터와 특징데이터를 뽑게 되는데, SCF 데이터를 추출할 때 고속 푸리에 변환(FFT : Fast Fourier Transform)를 사용하여 연산속도를 줄였고, 중첩 윈도우(Overlapping Windows) 푸리에 변환을 사용하여 SCF 특징이 잘 나타나도록 설계하였다.

추출된 SCF데이터와 특징데이터를 각각 합성곱 계층과 완전연결 계층의 입력으로 통과시켜 학습을 시킨다. 표 3은 CNN의 실험 파라미터를 나타낸다. 512×512 의 크기를 가지는 SCF데이터는 3개의 합성곱 계층과 2개의 맥스 풀링 계층을 통과한 후 $128 \times 128 \times 12$ 의 크기로 감소하고, 완전연결 계층을 통과하기 전에 SCF데이터와 특징 데이터를 합쳐서 통과시킨다. 하나의 신호로부터 SCF데이터와 특징데이터 한 세트를 추출하는데, 각 변조신호 종류별로 1000개의 데이터 집합을 추출하고, 총 8000개의 데이터로 학습을 시킨다. 사용하는 변조방식은 7개이지만 잡음만 전송되는 경우도 있기 때문에 잡음에 대한 데이터

표 1. 신호 생성 부분의 파라미터(송신자 측면)
Table. 1. Part of signal generation(transmitter)

Parameters		Value
Carrier Frequency(Up-convert) Bandwidth		500MHz 499.5MHz ~ 500.5MHz(1MHz)
Modulation Type		BPSK, BASK, BFSK, QPSK, 16QAM, AM, FM
Symbol Rate [M symbol/s]		1 (fixed value on all modulation type)
Data Rate [M symbol/s]		1 (binary modulation, analog modulation) 2 (QPSK) 4 (16QAM)
Channel State (AWGN, Fading)	AWGN channel [dB]	SNR = -6 ~ +6 (random generation) SNR = -6, -3, 0, +3, +6
	Fading channel(Rayleigh)	Sample period = 1×10^{-5} sec Maximum doppler shift = 100Hz Path delays = [0 1e-004 2.1e-004] sec Average path gain(dB) = [0 0 0]

표 3. 딥러닝 부분의 실험 파라미터 값
Table. 3. Part of CNN parameters

Parameters	Value
Size of SCF Data	[512, 512]
Size of Feature Data	11
The Number of Total Modulation Signal Data	8,000
Learning Rate	0.001
Convolutional Layer	3(each layer has $5 \times 5 \times 3, 5 \times 5 \times 6, 5 \times 5 \times 12$ filters)
Pooling Layer	2 Max pooling layer (2×2 filters)
Fully-connected Layer	5(each layer has 200, 150, 100, 50, 30 nodes)
Activation Function	ReLU
Classification Function	Softmax

도 추출하여 함께 학습시킨다. 학습성능과 관련이 있는 학습속도는 0.001로 고정하고, 각 계층의 활성화 함수는 ReLu(Rectified Linear Unit)를 사용하며, 마지막 계층의 분류 함수는 Softmax를 사용하여 각 변조방식을 확인한다.

5.2 시뮬레이션 결과

제안하는 시스템에서의 성능평가를 위해 동일한 데이터에 대해 다른 학습 알고리즘들과 정확도를 비교하였다. 인공지능 학습알고리즘과 관련한 정확도는 시험용 데이터(Test data)에 대해 정확도를 나타낸 것이며, 전체 데이터의 개수에서 학습용 데이터(Training data) : 검증용 데이터(Validation data) : 시험용 데이터의 비율은 7 : 2 : 1로 사용하였다. 제안하

는 시스템은 CNN구조를 사용하고, SCF데이터와 특징데이터 두 가지를 사용한다. 이와 비교하는 학습 알고리즘 시스템은 3가지인데, 첫 번째는 완전연결 계층 학습알고리즘(FCN : Fully-Connected Networks)을 사용하고, 21개의 특징 데이터를 사용한 시스템이다 [27]. FCN 시스템의 경우에 해당 시스템이 사용한 파라미터를 그대로 사용하여 제안하는 시스템과 비교하였다. 두 번째는 일차원의 CNN구조를 사용하고, 수신된 신호의 샘플을 사용한 시스템이고 일차원 CNN(1-D CNN)의 파라미터 값은 제안하는 시스템의 파라미터 값과 동일하다. 마지막으로 학습 알고리즘으로 GMM(Gaussian Mixture Model)을 사용하고 데이터는 수신된 신호의 샘플을 사용한 시스템이다. GMM 기계학습 알고리즘은 비지도 학습(unsupervised learning)의 한 종류이고, GMM 내부의 변수를 추정할 때에는 EM(Expectation Maximization) 알고리즘이 사용되었다. 본 시뮬레이션을 진행할 때 표 1, 표 2, 표 3에 나타난 변수들의 값을 모두 동일하게 조정하여 4개의 분류기의 성능을 평가하였다.

그림 4의 좌측 그림은 시험용 데이터에 대해 SNR의 변화에 따라 변조신호의 평균 분류정확도를 나타낸 것이고, 우측 그림은 각 분류 알고리즘에 대해 좌측 그림의 정확도의 평균값을 나타낸 것이다. 제안한 시스템의 실험환경(변조방식개수, 샘플 개수, 채널 환경 ...)에서는 GMM 알고리즘보다 딥러닝 학습 알고리즘의 성능이 뛰어난 것을 알 수 있고, 학습 알고리즘에 사용하는 데이터는 수신된 신호의 샘플보다 특징을 사용하는 데이터의 시스템 성능이 뛰어난 것을 볼 수 있다. 또한 두 종류의 데이터를 사용하여 제안


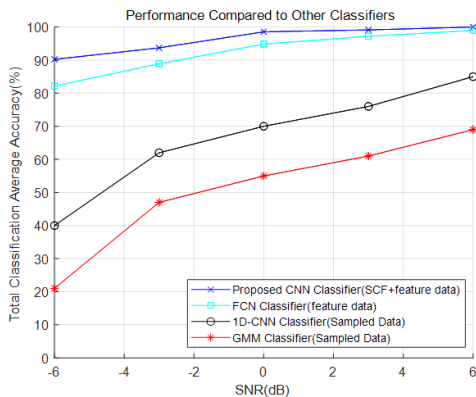


그림 4. SNR에 따른 분류 정확도 비교
Fig. 4. Classification Accuracy Compared to SNR value.

하는 CNN 시스템의 성능이 FCN을 사용한 시스템보다 뛰어난 것을 알 수 있다. 그리고 제안하는 시스템은 SNR이 -6dB인 경우에 유일하게 90% 이상의 정확도를 갖는다. 그림 4의 정확도와 관련하여 각 시스템에 대해 표준편차를 계산해 보았다. SNR의 크기별로 표준편차를 계산하고, 이에 대해 평균값을 계산하였다. 각 시스템별로 표준편차의 평균값은 2.19, 2.88, 11.08, 12.4(Proposed CNN, FCN, 1-D CNN, GMM)의 값을 가지고, 제안한 시스템과 FCN 시스템의 결과는 안정적인 것을 확인할 수 있다.

그림 5와 6은 SNR=-6dB인 경우와 SNR=+6dB인 경우에 각 분류 알고리즘이 각 변조방식을 정확하게 분류해내는 정확도와 해당 분류 알고리즘별 분류정확도를 나타낸 것이다. 변조방식 중 잡음만 존재하는 신호(only noise)는 SNR크기별로 잡음만 넣은 신호로 정의하였다. SNR=+6dB인 경우에는 특징 데이터를 사용한 학습시스템은 높은 성능을 보였고, 신호의 샘플링 데이터를 사용한 시스템은 보다 낮은 성능을 보

인다. SNR=-6dB인 경우에는 제안하는 시스템을 제외하고는 정확도의 값이 90%를 넘기지 못하는 것을 알 수 있다. 딥러닝의 특성상, 데이터의 양이 많아지면 100%의 성능을 낼 수 있지만 제한된 데이터의 양에서는 제안하는 시스템이 가장 뛰어난 것을 알 수 있다. 특이한 점은 딥러닝 학습 알고리즘을 사용하더라도 위상편이 방식을 사용하는 변조방식의 분류 정확도가 다른 변조방식에 비해 낮다는 것을 알 수 있다. 그 이유는 SCF 데이터는 신호의 주기적 특성을 사용하기 때문에 CNN이 분류성능이 뛰어나더라도 위상편이 방식을 사용하는 변조방식들을 잘 구분할 수 없지만 제안된 방법을 SCF 외에도 변조신호의 다른 11개 특징들을 추가적으로 사용하기 때문에 신호분류의 성능이 높은 것을 알 수 있다.

그림 7은 실제 통신시스템에서 SNR값은 일정하지 않기 때문에 -6dB~+6dB 범위에서 정규분포를 갖도록 무작위로 설정하여 그에 대한 성능을 나타낸 것이다. 이전의 그림 4, 5와 비슷하게 SNR 값이 무작위

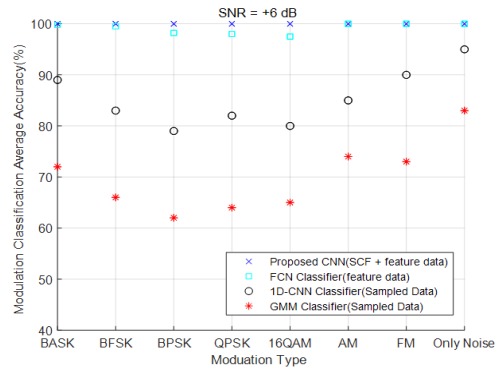
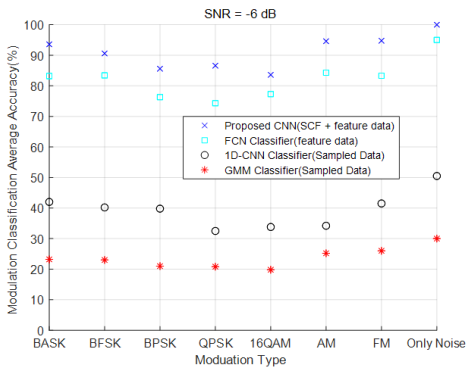


그림 5. SNR = -6dB, +6dB인 경우에 각 시스템에 대한 변조 분류 성능
 Fig. 5. Modulation Classification Accuracy of Each Classifiers for SNR = -6dB, +6dB.

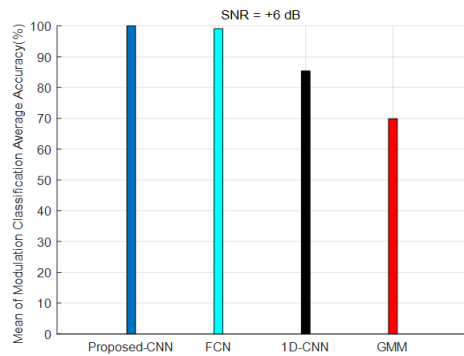
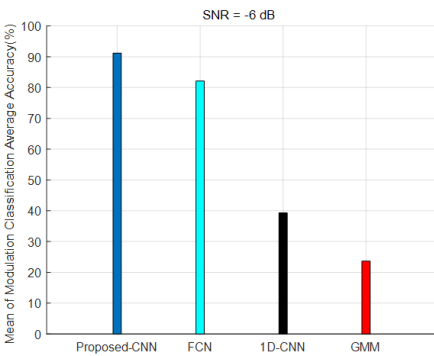


그림 6. SNR = -6dB, +6dB인 경우에 각 시스템에 대한 전체 분류 정확도
 Fig. 6. Total Classification Accuracy of Each Classifiers for SNR=-6dB, +6dB

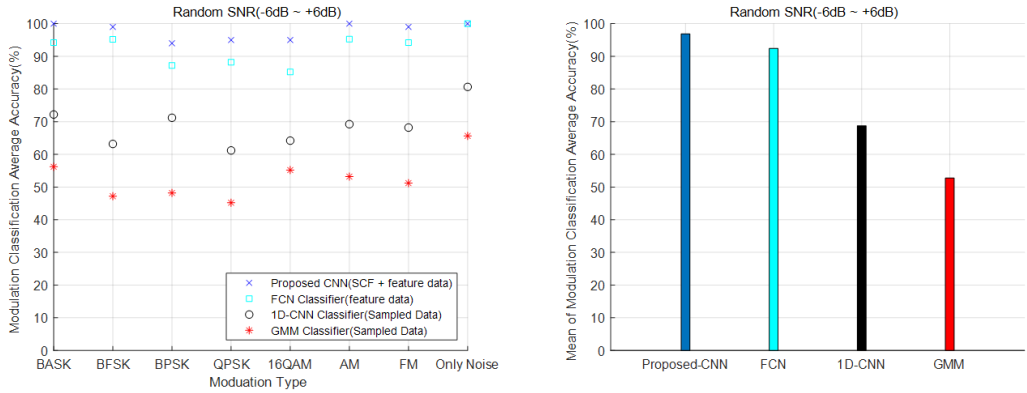


그림 7. SNR 값이 무작위인 경우에 각 시스템에 대한 분류 정확도
 Fig. 7. Classification Accuracy of Each Classifiers for Random SNR Value.

인 경우에도 제한하는 시스템 성능이 가장 뛰어난 것
 을 알 수 있다. 정확하게 제한하는 시스템의 성능은
 97.23%의 정확도를 나타내고 FCN 시스템의 성능은
 97.28%의 정확도를 얻었다.

그림 8은 SNR 크기가 증가함에 따라 각 시스템에

서 성공적으로 변조방식을 분류하는 정확도를 나타낸
 것이다. 모든 시스템에서 잡음만 있는 경우가 제일 높
 았고, 각 시스템에 따라 다르긴 하지만 위상편이방식
 의 변조방식이 각 시스템에서는 정확도가 낮은 것을
 확인할 수 있다. 제한하는 시스템에서 SNR이 나쁜 환

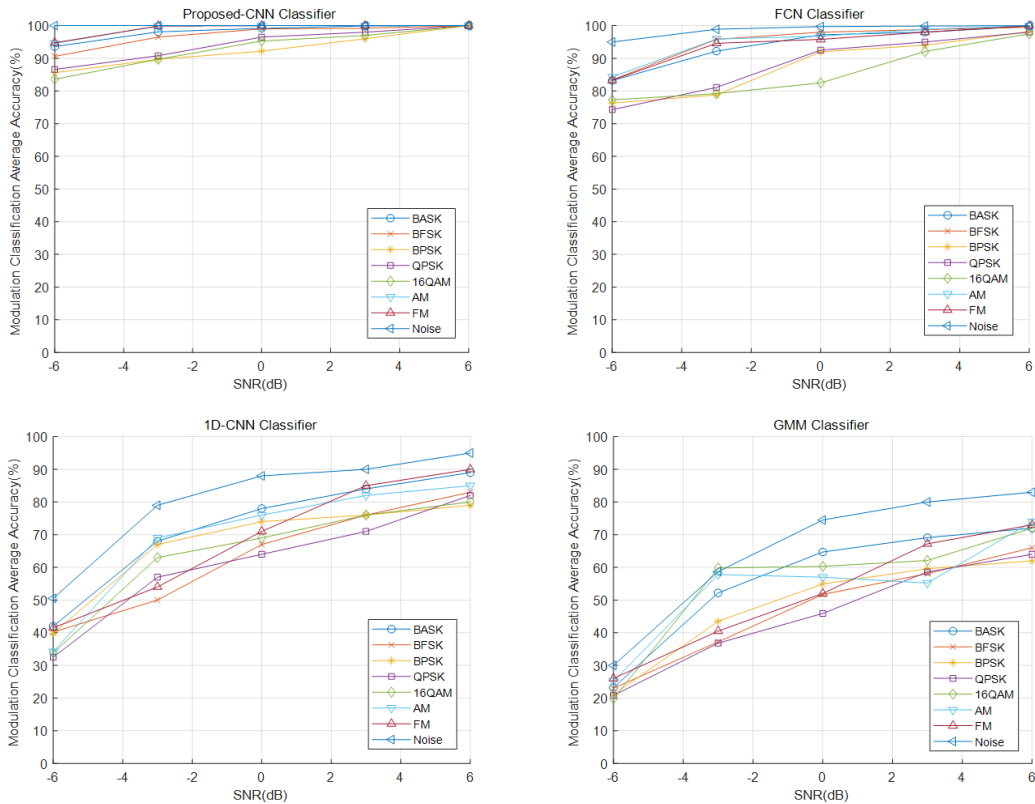


그림 8. SNR에 따른 각 시스템에 대한 변조 분류 정확도
 Fig. 8. Modulation Accuracy for Each Classifiers according to SNR value

경에서도 높은 정확도가 나온 것을 확인할 수 있다.

그림 9는 제안하는 시스템에서 특징 데이터의 유무에 따른 변조분류 정확도를 나타낸 것이다. SCF 데이터와 특징 데이터 두 개를 사용한 경우가 SCF 데이터만 사용한 경우보다 더 높은 성능을 나타내고 있고, SCF 데이터만 사용한 경우는 FCN 시스템의 성능과 비슷한 것을 알 수 있다. 하지만 FCN 시스템의 경우에는 해당 논문^[18]에서 사용한 변수를 사용했기 때문에 데이터의 양을 비교해보면 제안하는 시스템의 데이터 개수가 더 적은 것을 확인할 수 있다. FCN 시스템의 경우는 총 25,000개의 데이터를 사용하였지만, 제안하는 시스템은 8,000개의 데이터를 사용하였다.

그림 10은 과적합 문제 확인을 위해 SNR이 무작위로 설정되어 있을 때 학습용 데이터, 검증용 데이터, 시험용 데이터의 정확도를 나타낸 것이다. 머신러닝 알고리즘을 이용하여 어떠한 데이터를 인식 및 분류하는데 있어서 과적합은 거의 해결이 불가능한 수준

의 문제인 경우가 많이 발생하고, 과적합 문제가 발생하는 지점을 정확하게 판단하는 것 또한 매우 어려운 일이다. 그럼에도 그림 10의 결과를 통해 제안하는 시스템에서는 과적합이 발생하지 않았다고 판단할 수 있다. 시험용 데이터에 대한 정확도가 다른 데이터의 정확도와 비교하여 크게 차이가 나지 않기 때문에 제안하는 시스템의 학습 자체는 성공적으로 이루어진 것을 알 수 있다.

VI. 결 론

본 논문에서는 인지무선 네트워크에서 딥러닝 학습 알고리즘을 사용하여 특징기반의 자동변조 분류기술에 대해 제안하였다. 제안하는 시스템은 송신기로부터 수신한 변조신호에 대해 스펙트럼 상관밀도 함수와 특징을 추출한다. 스펙트럼 상관밀도 함수와 특징은 주파수 분해능 및 잡음에 관련하여 강인한 장점을 가

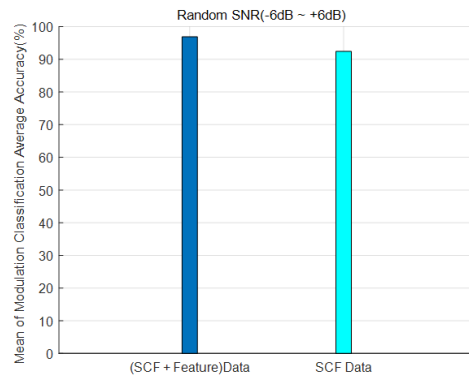
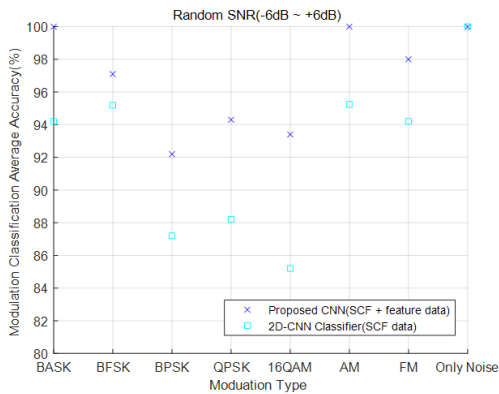


그림 9. 특징 데이터의 유무에 따른 변조 분류 정확도
Fig 9. Modulation Classification Accuracy according to presence of feature data or not.

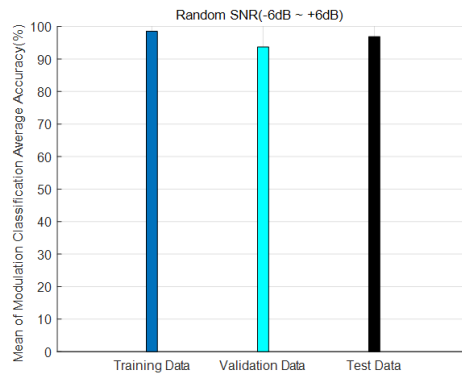
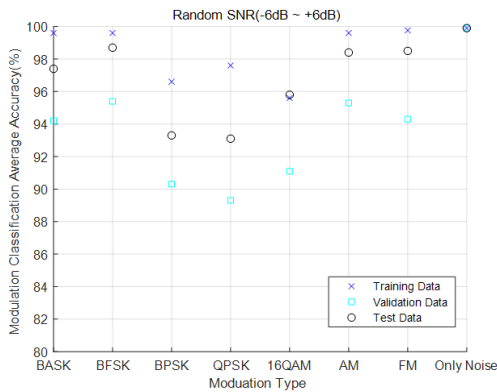


그림 10. 제안하는 시스템의 데이터 역할에 따른 정확도
Fig. 10. Classification accuracy for data role on proposed CNN

지고 있기 때문에 통신의 환경에서 적용한다. 해당 특징들을 적용하여, 제안하는 시스템에서는 딥러닝 학습 알고리즘 중 뛰어난 성능을 가지는 CNN 알고리즘을 사용하였다. 일반적인 CNN 구조를 사용하지만, 학습 과정에서 스펙트럼 상관함수 데이터는 합성곱 계층에서 학습되고, 완전연결 계층에서는 통계적 특성이나 순시값을 갖는 특징들을 포함한 데이터를 학습시킨다. 즉 두 종류의 데이터를 CNN 네트워크에 학습을 하여 학습효율을 높일 수 있도록 하였다. 실제 통신환경을 고려한 시뮬레이션 실험을 통해 여러 가지 분류시스템과 다양한 성능비교를 하여 제안한 시스템이 뛰어난 성능을 보이는 것을 확인하였다. 또한 학습용 데이터, 검증용 데이터, 시험용 데이터 별로 정확도를 측정하여 제안한 시스템에서 과적합 문제가 발생하지 않음을 확인하였고, 또한 시뮬레이션 결과들을 통해 과적합 문제를 가지고 있지 않음을 확인하였다.

References

- [1] Y. Saleem and M. H. Rehmani, "Primary radio user activity models for cognitive radio networks: A survey," *J. Netw. Comput. Appl.*, vol. 43, pp. 1-16, Aug. 2014.
- [2] J. Mitola III, "Cognitive radio: an integrated agent architecture for software defined radio," Ph.D. Dissertation, Royal Inst. Technol. Sweden, May 2000.
- [3] S. Haykin, "Cognitive radio: brain-empowered wireless communications," *IEEE J. Select. Areas Commun.*, vol. 3, no. 2, pp. 201-220, Feb. 2005.
- [4] O. Dobre, A. Abdi, Y. Bar-Ness, and W. Su, "Survey of automatic modulation classification techniques: classical approaches and new trends," *IET Commun.*, vol. 1, no. 2, pp. 137-156, 2007.
- [5] A. Ali and F. Yangyu, "Automatic modulation classification using deep learning based on sparse autoencoders with nonnegativity constraints," *IEEE Sign. Process. Lett.*, vol. 24, no. 11, pp. 1626-1630, Nov. 2017.
- [6] G. J. Mendis, J. Wei, and A. Madanayake, "Deep learning-based automated modulation classification for cognitive radio," in *Proc. IEEE Int. Conf. Commun. Syst. (ICCS)*, pp. 1-6, Shenzhen, China, Dec. 2016.
- [7] A. K. Nandi and E. E. Azzouz, "Algorithms for automatic modulation recognition of communication signals," *IEEE Trans. Commun.*, vol. 46, no. 4, pp. 431-436, Apr. 1998.
- [8] F. Hameed, O. A. Dobre, and D. C. Popescu, "On the likelihood-based approach to modulation classification," *IEEE Trans. Wireless Commun.*, vol. 8, no. 12, pp. 5884-5892, Dec. 2009.
- [9] A. K. Nandi and E. E. Azzouz, "Algorithms for automatic modulation recognition of communication signals," *IEEE Trans. Commun.*, vol. 46, no. 4, pp. 431-436, Apr. 1998.
- [10] S. Z. Hsue and S. S. Soliman, "Automatic modulation classification using zero crossing," *IEE Proc. F. Radar Signal Process.*, vol. 137, no. 6, pp. 459-464, Dec. 1990.
- [11] A. Swami and B. M. Sadler, "Hierarchical digital modulation classification using cumulants," *IEEE Trans. Commun.*, vol. 48, no. 3, pp. 416-429, Mar. 2000.
- [12] J. Bagga and N. Tripathi, "Automatic modulation classification using spectral and statistical features and artificial neural networks," *The J. Applied Sci. Res.*, vol. 1, no. 4, pp. 250-260, Dec. 2014.
- [13] J. J. Popoola and R. van Olst, "Effect of training algorithms on performance of a developed automatic modulation classification using artificial neural network," in *Proc. Africon*, pp. 1-6, Pointe-Aux-Piments, Mauritius, Sept. 2013.
- [14] H. Gang, L. Jiandong, and L. Donghua, "Study of modulation recognition based on HOCs and SVM," in *Proc. IEEE Veh. Tech. Conf.*, vol. 2, pp. 898-902, Milan, Italy, May 2009.
- [15] M. W. Aslam, Z. Zhu, and A. K. Nandi, "Automatic modulation classification using combination of genetic programming and KNN," *IEEE Trans. Wireless Commun.*, vol. 11, no. 8, pp. 2742-2750, Aug. 2012.
- [16] Z. Zheng, T. Huang, H. Zhang, S. Sun, J.

- Wen, and P. Wang, "Towards a resource migration method in cloud computing based on node failure rule," *J. Intell. Fuzzy Syst.*, vol. 31, no. 5, pp. 2611-2618, 2016.
- [17] X. Shi, et al., "Graph processing on GPUs: A survey," *ACM Comput. Surv.*, vol. 50, no. 6, 2017.
- [18] T. Wang, C.-K. Wen, H. Wang, F. Gao, T. Jiang, and S. Jin, "Deep learning for wireless physical layer: Opportunities and challenges," *China Commun.*, vol. 14, no. 11, pp. 92-111, Nov. 2017.
- [19] Z. Zhao and L. Tao, "A MPSK modulation classification method based on the maximum likelihood criterion," in *Proc. Int. Conf. Sign. Process.*, vol. 2, pp. 1805-1808, Beijing, China, Aug. 2004.
- [20] V. G. Chavali and C. R. C. M. da Silva, "Classification of digital amplitude-phase modulated signals in time-correlated non-Gaussian channels," *IEEE Trans. Commun.*, vol. 61, no. 6, pp. 2408-2419, Jun. 2013.
- [21] W. Wei and J. M. Mendel, "Maximum-likelihood classification for digital amplitude-phase modulations," *IEEE Trans. Commun.*, vol. 48, no. 2, pp. 189-193, Feb. 2000.
- [22] A. K. Nandi and E. E. Azzouz, "Automatic analogue modulation recognition," *Signal Process.*, vol. 46, no. 2, pp. 211-222, Oct. 1995.
- [23] R. A. El-Khoribi, M. A. I. Shoman, and A. G. Ahmed Mohammed, "Automatic digital modulation recognition using artificial neural network in cognitive radio," in *IJETTCS*, vol. 3, no. 3, pp. 132-136, May-Jun. 2014.
- [24] C. Louis and P. Sehier, "Automatic modulation recognition with a hierarchical neural network," in *Proc. MILCOM*, vol. 3, pp. 713-717, Fort Monmouth, NJ, USA, Oct. 1994.
- [25] A. K. Nandi and E. E. Azzouz, "Modulation recognition using artificial neural networks," *Signal Process.*, vol. 56, pp. 165-175, 1997.
- [26] Z. Yin, "Research of communication signal modulation scheme recognition based on one-class SVM bayesian algorithm," in *Proc. IEEE WiCom'2009*, pp. 1-4, Beijing, China, Sept. 2009.
- [27] B. Kim, J. Kim, H. Chae, D. Yoon, and J. W. Choi, "Deep neural network-based automatic modulation classification technique," in *Proc. ICTC*, pp. 579-582, Jeju, South Korea, Oct. 2016.
- [28] A. Engin, "Selecting of the optimal feature subset and kernel parameters in digital modulation classification by using hybrid genetic algorithm-support vector machines: HGASVM," *ELSEVIER, Expert Syst. with Appl.*, pp. 1391-1402, 2009.
- [29] J. Liu and Q. Luo, "A novel modulation classification algorithm based on daubechies5 wavelet and fractional fourier transform in cognitive radio," in *Proc. ICCT 2012*, pp. 115-120, Chengdu, China, Nov. 2012.
- [30] K. Hassan, I. Dayoub, W. Hamouda, M. Berbineau, et al., "Automatic modulation recognition using wavelet transform and neural networks in wireless systems," *EURASIP J. Advances in Signal Process.*, vol. 2010, 2010.
- [31] H.-B. Guan, C.-Z. Ye, and X.-Y. Li, "Modulation classification based on spectrogram," in *Proc. Int. Conf. Machine Learning and Cybernetics*, pp. 3551-3556, Shanghai, China, Aug. 2004.
- [32] S. Theodoridis and K. Kourtroumbas, *Pattern Recognition*, New York: Academic Press, 1999.
- [33] C. M. Spooner, "Classification of co-channel communication signal using cyclic cumulants," in *Proc. Asilomar*, pp. 531-536, Pacific Grove, CA, USA, Nov. 1995.
- [34] U. Satija, M. S. Manikandan, and B. Ramkumar, "Performance study of cyclostationary based digital modulation classification schemes," in *Proc. ICIS2014*, pp. 1-5, Gwalior, India, Dec. 2014.
- [35] B. Ramkumar, "Automatic modulation classification for cognitive radios using cyclic feature detection," *IEEE Circuits and Systems*

Mag., vol. 9, pp. 27-45, 2009.

- [36] I. S. Choi, S. J. Jang, S. J. Yoo, J. K. Choi, M. H. Seo, M. H. Park, and K. E. Lee, "History-based optimal sensing band selection algorithm in cognitive radio ad-hoc networks," *J. KICS*, vol. 43, no. 2, pp. 227-280, 2017.
- [37] S. M. Yang, W. J. Song, I. S. Choi, and S. J. Yoo, "Implementation of deep learning-based motion classification system for IoT device control in ultrasonic sound environments," *J. KICS*, vol. 42, no. 9, pp. 1796-1805, 2017.
- [38] Q. Yang and S. J. Yoo, "Optimal UAV path planning: Sensing data acquisition over IoT sensor networks using multi-objective bio-inspired algorithms," *IEEE Access*, vol. 6, pp. 13671-13684, Mar. 2018.

최익수 (Ik-Soo Choi)



2016년 2월 : 경상대학교 정보통신공학과(공학사)
 1994년 2월 : 인하대학교 정보통신공학과(공학석사)
 2018년 3월~현재 : 프람트테크 놀로지
 <관심분야> 통신공학, 인공지능, Cognitive Radio, DB, Web Application

장성진 (Sung-Jeen Jang)



2007년 2월 : 인하대학교 전자공학과(공학사)
 2009년 2월 : 인하대학교 정보통신공학과(공학석사)
 2009년 3월~현재 : 인하대학교 정보통신공학과 박사과정
 <관심분야> Cognitive Radio Network, 무선센서네트워크

유상조 (Sang-Jo Yoo)



1988년 2월 : 한양대학교 전자통신학과(공학사)
 1990년 2월 : 한국과학기술원 전기및전자공학과(공학석사)
 2000년 8월 : 한국과학기술원 전자전산학과(공학박사)
 1990년 3월~2001년 2월 : KT 연구개발 본부
 1990년 3월~2000년 11월 : NIST(미국 표준기술연구원) 초빙연구원
 2001년 3월~현재 : 인하대학교 정보통신공학과 교수
 <관심분야> 무선 네트워킹 프로토콜, Cross-layer 프로토콜 설계, Cognitive Radio Network, 무선센서네트워크, 미래인터넷