

딥러닝 기반 자동 변조 인식 성능 분석

강종진¹ · 김재현^{2*}

Performance analysis in automatic modulation classification based on deep learning

Jong-Jin Kang¹ · Jae-Hyun Kim^{2*}

¹Senior engineer, C4I R&D Center, Hanwha Systems, Seongnam, 13524 Korea

^{2*}Professor, Department of Electrical and Computer Engineering, Ajou University, Suwon, 16499 Korea

요약

본 논문에서는 미상의 통신신호에 대한 자동 변조 인식을 위하여 심층신경망인 딥뉴럴네트워크를 적용하여 변조 형태를 식별하고 그 성능을 분석하였다. 신경망 입력 데이터는 변조된 신호의 시간영역 디지털샘플 데이터, FFT(Fast Fourier Transform)를 적용한 주파수영역 데이터, 시간 및 주파수영역 혼합데이터를 사용하여 각각의 변조 인식 성능을 확인하였다. 아날로그 변조 및 디지털 변조 신호 11종에 대하여 -20~18 dB 까지 다양한 SNR(Signal to Noise Ratio) 환경에서 변조인식 성능을 확인하고 그 성능을 분석하였으며, 입력 데이터의 종류에 따른 학습 속도를 확인함으로써 제안한 방법이 실제적인 자동변조 인식 시스템 구축에 효과적인 방법임을 확인 하였다.

ABSTRACT

In this paper, we conduct performance analysis in automatic modulation classification of unknown communication signal to identify its modulation types based on deep neural network. The modulation classification performance was verified using time domain digital sample data of the modulated signal, frequency domain data to which FFT was applied, and time and frequency domain mixed data as neural network input data. For 11 types of analog and digitally modulated signals, the modulation classification performance was verified in various SNR environments ranging from -20 to 18 dB and reason for false classification was analyzed. In addition, by checking the learning speed according to the type of input data for neural network, proposed method is effective for constructing an practical automatic modulation recognition system that require a lot of time to learn.

키워드 : 자동변조인식, 딥러닝, 신경망, 신호대잡음비, 고속푸리에변환

Keywords : Automatic modulation classification, Deep learning, Neural network, SNR, FFT

Received 13 January 2021, Revised 20 January 2021, Accepted 28 January 2021

* Corresponding Author Jae-Hyun Kim(E-mail:jkim@ajou.ac.kr, Tel:+82-31-219-2477)

Professor, Department of Electrical and Computer Engineering, Ajou University, Suwon, 16499 Korea

Open Access <http://doi.org/10.6109/jkiice.2021.25.3.427>

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. 서론

미상의 통신신호를 수집/감청하여 상대방의 동향, 의도 등을 파악하는 신호정보(Signal Intelligence) 장비는 신호 수집의 시작 단계에서 대상 신호에 대한 변조형태를 신속하고 정확하게 식별하여야만 복조를 통한 감청 및 정보추출을 원활하게 수행 할 수 있다.

종래의 통신신호 변조형태 식별방법은 디지털 녹음기 등과 같은 RF 신호 저장장치에 저장된 수신 데이터를 운용자가 직접 수동으로 분석하는 형태로 수행되었다. 하지만 수집할 데이터의 양이 증가하고 그 형태가 다양해짐에 따라 분석시간이 증가하였고, 변조형태의 식별 정확도도 낮아졌다. 따라서 이러한 수동 변조 식별 방법의 문제점을 해결하기 위해 소프트웨어를 통한 자동 변조 인식(AMC: Automatic Modulation Classification) 방법에 대한 연구가 진행 중이다 [1].

자동 변조 인식 방법 연구 초기에는 신호의 대역폭, 평균 신호세기 등 미리 정의된 주요 특징(Key Feature)을 추출하여 결정 순서도(Decision Flowchart) 등을 통해 변조방식을 분류하였다 [2]. 그러나 이는 수신신호의 신호 대 잡음비(SNR: Signal to Noise Ratio)를 충분히 확보해야만 가능하다. 이러한 단점들을 보완하는 방안이 지속적으로 연구되어 오다가 하드웨어의 발전으로 최근에는 인공지능을 적용한 방안들이 연구되고 있다.

인공지능을 적용한 자동 변조 인식 방법 연구 초기에는 신호의 다양한 통계적 특징을 직접 생성하여 신경망을 학습하였으나[3], 최근에는 딥러닝(Deep Learning) 기술을 적용하여 데이터에 포함된 특징을 신경망이 스스로 학습하여 변조형태를 인식하는 방법이 진행되고 있다 [4-9].

현대의 통신신호는 스펙트럼 확산 기술이 적용되어 신호의 대역폭이 증가하고 있으며, 소프트웨어 정의 라디오(SDR: Software Defined Radio) 기술이 적용된 무선 통신시스템은 신호의 변조형태를 빠르게 변경할 수 있다[10]. 이에 따라 AMC 시스템에서 요구되는 수신 대역폭이 증가하고 처리할 데이터량이 늘어나고 있다. 그러므로 딥러닝 기술을 AMC에 적용하기 위해서는 대량의 데이터를 효과적으로 빠르게 학습할 수 있는 방법이 필요하다.

본 논문에서는 딥러닝 기술을 적용한 AMC 시스템 설계에 있어서, 학습속도 향상을 위하여 수신 신호의 시

간영역 정보와 고속푸리에변환(FFT: Fast Fourier Transform)을 통한 주파수영역 정보를 사용하는 방법을 제안한다.

II. 자동 변조 인식 시스템 설계

2.1. 시스템 구조

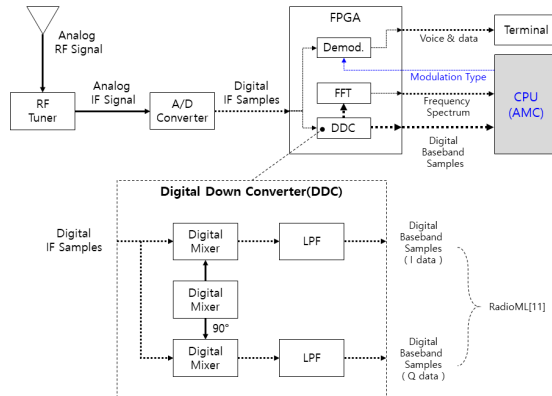


Fig. 1 System structure for AMC

그림 1은 AMC가 적용된 시스템 구조이다. 안테나를 통해 수신된 미상의 통신신호는 RF 튜너를 통하여 중간 주파수인 IF 신호로 변환된 후 아날로그 디지털 변환기(ADC: Analog to Digital Converter)를 이용하여 디지털 데이터로 변환된다. 디지털 신호는 디지털하향변환기(DDC: Digital Down Converter)를 사용하여 디지털 기저대역 샘플(I/Q) 데이터로 변환된다. 주파수영역 정보 생성을 위한 FFT 연산은 통상 처리속도가 빠른 FPGA(Field Programmable Gate Array)를 사용한다. 본 논문의 AMC는 그림 1의 CPU에서 구동되며, 입력데이터는 FPGA로부터 처리된 데이터로 가정한다.

2.2. 실험 데이터 선정

AMC의 실험을 위해서는 다양한 변조신호에 대하여 다중경로 페이딩, 중심주파수 및 샘플링 시간 드리프트, AWGN 등 채널 특성이 반영된 실험 데이터가 필요하다. 실제 환경에서 학습데이터를 확보하는 것은 매우 어려운 문제이다.

본 논문에서는 기계학습 모델의 학습 및 평가를 위하여 공개된 데이터 세트인 RadioML[11]을 이용하였다.

RadioML은 GNU radio를 사용하여 실제 통신채널특성 및 신호 환경 등을 반영한 샘플데이터를 제공하여 많은 자동변조인식분야 연구에 활용되고 있다.

실험 데이터의 구성은 표 1과 같이 변조형태 11종(아나로그 3종, 디지털 8종)을 사용하였으며, SNR은 -20~18 dB, 2 dB 간격으로 총 20종으로 구성되어 있다. 변조 형태에 식별에 사용된 한 프레임은 1 MSPS의 속도로 샘플링된 128개의 샘플로 구성되며 128 μ s 동안의 신호를 의미한다.

Table. 1 Dataset of automatic modulation classification

Modulation type	Analog (3)	Digital (8)
	AM-DSB, AM-SSB, WB-FM	BPSK, QPSK, 8PSK, 16QAM, 64QAM, BFSK, CPFSK, PAM4
Sample length	128 sample / frame	
SNR	-20dB ~ 18dB @ 2dB step	
Number of training frame	76,978	
Number of validation frame	4,052	
Number of test frame	81,030	

딥러닝 시스템의 성능을 결정하는 주요한 요소로써 입력데이터를 잘 선정하여 모델이 특징을 잘 추출하도록 학습해줘야만 좋은 성능을 발휘할 수 있다. 본 논문에서는 AMC 입력신호로 시간영역 정보(I/Q data), 주파수영역 정보(FFT data) 및 시간-주파수영역 데이터(I/Q+FFT data)를 이용하여 모델을 학습하였다.

그림 2는 모의실험에 사용할 데이터 프레임의 예로써, SNR 이 0 dB인 QPSK 변조신호에 대한 시간영역(I/Q) 샘플 및 주파수영역(FFT) 데이터 이다. I/Q 데이터의 샘플은 잡음에 의한 왜곡이 발생하였으나, 주파수 진폭 스펙트럼은 잡음대비 상대적으로 깨끗한 모습을 보인다.

2.3. 신경망 구조

본 논문에 사용된 딥러닝 모델은 이미지 식별 등에 사용되는 비교적 간단한 모델인 완전연결 네트워크(Fully Connected Network)를 적용하였다.

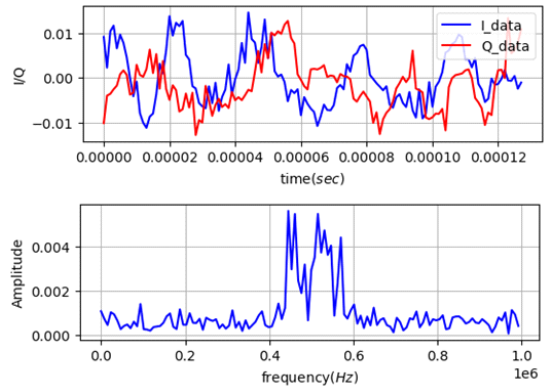


Fig. 2 Example of test data (QPSK modulated Signal)

입력 레이어는 I/Q 데이터의 경우 각각 프레임당 128 샘플씩 256개의 레이어로 구성되며, FFT 데이터의 경우 진폭스펙트럼 128개만을 사용하고, I/Q+FFT의 경우 384개의 입력 레이어로 구성하였다. 히든 레이어는 총 4개로 구성하였으며 출력 레이어는 변조 신호 11종에 대한 변조형태 식별을 위하여 11개의 레이어로 구성하였다. 각 히든 레이어별 활성화 함수는 ReLU(Rectified Linear Unit), 출력 레이어의 최종 분류단계에 소프트맥스 함수를 적용하였으며, 매개변수 최적화는 Adam, 손실 함수는 교차 엔트로피가 적용되었다. 그림 3은 학습 모델에 대한 구조이다.




Fig. 3 Architecture of proposed fully connected network

합성곱 신경망(CNN:Convolutional Neural Network) 등 향상된 신경망 모델이 활발히 연구되고 있으나[5], 본 논문에서는 학습데이터의 선정에 따른 학습속도, SNR 변화에 따른 인식 정확도의 변화를 확인하기 위하여 간단한 완전연결 신경망 모델을 적용하였다.

III. 모의실험 및 분석

모의실험 환경은 기계학습 분야에 광범위하게 활용되고 있는 공개소프트웨어인 Python 3.6을 이용하였으며 신경망 학습에 Keras 및 Tensorflow 프레임워크를 적용하였고, 하드웨어는 CPU i7-4770, RAM 32GByte, GPU NVIDIA GTX 960, OS Win7 64bit를 사용하였다.

총 데이터 중 학습데이터 50%, 검증데이터는 학습데이터의 5%를 적용하였고, 최대 학습 회수(epoch) 30회, 배치사이즈 1024를 적용하였다.

모의실험에 사용된 데이터는 시간영역의 데이터를 이용한 방법, 주파수영역 데이터를 이용한 방법, 2가지 데이터를 모두 이용한 방법으로 나누어 수행하고 그 결과를 분석하였다.

그림 4는 SNR별 식별 정확도를 도시한 그림이다. 각 입력데이터 별 평균 정확도는 62~63% 범위에서 유사한 결과를 보여준다. I/Q 데이터를 이용한 방법은 SNR이 6 dB, 14 dB 인 경우 정확도가 4% 감소하는 현상이 발생하였는데, 이는 학습데이터에 과적합(overfitting)된 결과를 알 수 있다[12]. 반면, FFT를 이용하여 주파수영역

데이터를 추가하여 학습할 경우 과적합이 완화되었고, 학습속도가 향상됨을 알 수 있다.

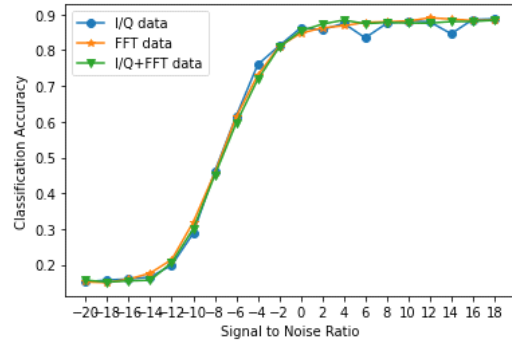


Fig. 4 Comparison of classification accuracy

그림 5는 몇 가지 SNR에 대하여 변조형태별 식별 정확도를 혼동행렬(CM: Confusion Matrix)로 표시하였다. 사용된 입력 데이터는 I/Q+FFT 데이터이다.

SNR 이 비교적 좋은 그림 5 (e) 및 (f) 경우 8PSK↔QPSK 및 AM-DSB↔WBFM 변조신호에 대하여 오인식이 발생하였다. PSK 계열의 디지털 변조신호는 constellation

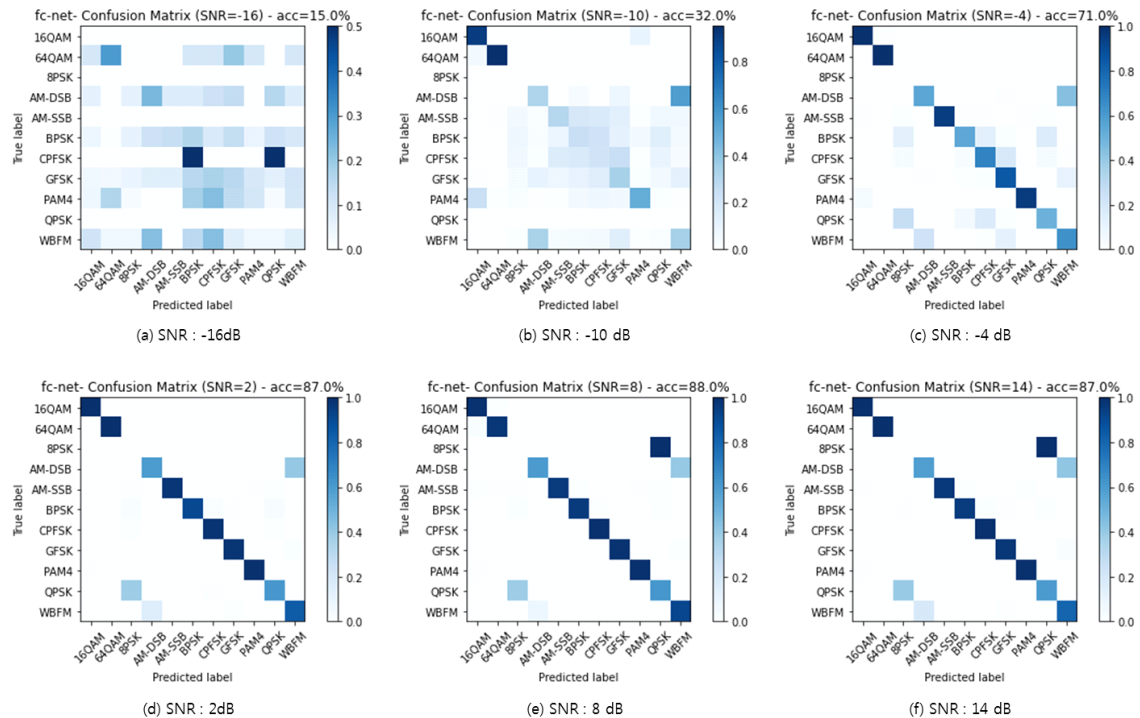


Fig. 5 Confusion matrix of each SNR

다이어그램 상 위상의 유사성이 높기 때문에 신경망의 학습 성능이 열화 되었을 것으로 추측되며, 식별 성능 향상을 위해서는 신경망의 구조 및 학습파라미터를 최적화 할 필요가 있다. 아날로그 변조 형태인 AM-SSB와 달리 AM-DSB와 WBFM 간 오인식이 발생하였는데, 아날로그 변조신호의 특성 상 무음구간의 경우 캐리어가 고정된 지속파 톤이 발생되므로 해당 구간의 데이터로 학습하거나 실험한 경우 오인식이 발생했을 것으로 판단된다.

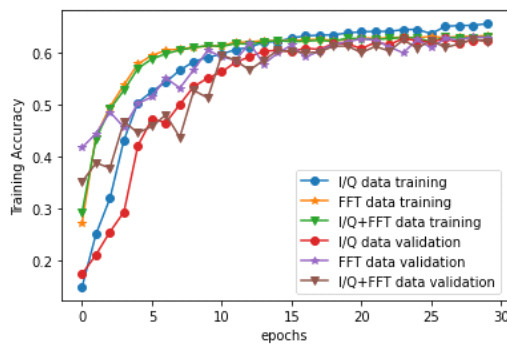


Fig. 6 Comparison of training speed & accuracy

그림 6은 학습 회수 별 학습 및 검증 정확도를 표시한 그래프이다. 학습 회수 10회 미만까지 FFT 및 I/Q+FFT 데이터의 경우 I/Q 데이터만을 이용한 방법 대비 학습 정확도가 상대적으로 높다. 통상 FFT를 이용하여 신호 처리를 수행하는 경우 잡음이나 간섭을 저감시키는 프로세싱 이득을 가진다[13]. 그러므로 I/Q 데이터만을 사용한 학습대비 낮은 SNR에서 학습 효과가 빠름을 알 수 있다. 실험결과를 바탕으로 실제 무선 환경에서 수집되는 대용량의 수신 데이터를 신속히 학습하기 위해서는 FFT 입력데이터를 활용하는 경우 학습속도 개선을 기대할 수 있을 것이다.

IV. 결 론

본 논문에서는 기계학습 분야에 널리 사용되고 있는 딥러닝 기법 중 비교적 간단한 4개의 히든 레이어로 구성된 완전연결네트워크를 사용하여 수신된 신호의 변조형태를 식별하고 그 성능을 분석하였다. 특히 학습에 사용되는 입력 데이터를 시간영역 데이터, 주파수영역

데이터, 시간-주파수영역 복합 데이터의 3가지로 방법으로 구분하여 학습 및 실험을 수행하고 그 결과를 비교 분석하였다.

최근 기계학습 분야에 GPU를 적용하여 학습 및 연산 속도가 향상되었지만[14], 실제 시스템 구현 관점에서는 대상 신호의 대역폭이 수십 MHz 이상 높은 신호들이 다수 존재하므로 RF 데이터를 실시간으로 처리하기에는 한계가 있다. 그러므로 수백 MHz 이상의 고속으로 동작하는 ADC 및 FPGA를 이용하여 수신되는 신호를 실시간으로 처리할 수 있는 딥러닝 시스템의 개발이 필요하며, 대량의 데이터를 효율적으로 빠르게 학습시킬 수 있도록 모델의 최적화가 필요하다.

References

- [1] O. A. Dobre, A. Abdi, Y. Bar-Ness, and W. Su, "A survey of automatic modulation classification techniques: classical approaches and new trends," *IET Communications*, vol. 1, pp. 137-156, Apr. 2007.
- [2] S. H. Seo, Y. J. Yoon, Y. H. Jin, Y. J. Seo, S. M. Lim, J. M. Ahn, C. S. Eun, W. Jang, and S. P. Nah, "Automatic Recognition of Analog and Digital Modulation Signals," *The Journal of Korean Institute of Communications and Information Sciences*, vol. 30, no. 1C, pp. 73-81, Jan. 2005.
- [3] J. K. Kim, B. D. Kim, D. W. Yoon, and J. W. Choi, "Deep Neural Network-based Automatic Modulation Classification Technique," *The Journal of Korean Institute of Information Technology*, vol. 14, no. 12, pp. 107-115, Dec. 2016.
- [4] H. J. Kim, H. J. Kim, J. H. Je, and K. S. Kim, "A deep learning method for the automatic modulation recognition of received radio signals," *Journal of the Korea Institute of Information and Communication Engineering*, vol. 23, no. 10, pp. 1275-1281, Oct. 2019.
- [5] T. J. O'Shea, J. Corgan, and T. C. Clancy, "Convolutional Radio Modulation Recognition Networks," Preprint, submitted, Jun. 2016. <https://arxiv.org/abs/1602.04105>.
- [6] N. E. West and T. J. O'Shea, "Deep architectures for modulation recognition," in *IEEE International Symposium on Dynamic Spectrum Access Networks (DySPAN)*, pp. 1-6, 2017.
- [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, 2018.

- [8] I. S. Choi, S. J. Jang, and S. J. Yoo, "Feature-Based Automatic Modulation Classification Using Deep Learning in Cognitive Radio," *The Journal of Korean Institute of Communications and Information Sciences*, vol. 43, no. 6, pp. 930-944, Jun. 2018.
- [9] S. H. Kim, C. Y. Kim, S. H. Yoo, and D. S. Kim, "Design of Deep Learning Model for Automatic Modulation Classification in Cognitive Radio Network," *The Journal of Korean Institute of Communications and Information Sciences*, vol. 45, no. 8, pp. 1364-1372, Aug. 2020.
- [10] M. Ettus and M. Braun, "The universal software radio peripheral (usrp) family of low-cost sdrs," *Opportunistic Spectrum Sharing and White Space Access: The Practical Reality*, pp. 3-23, 2015.
- [11] T. J. O'Shea and N. West, "Radio machine learning dataset generation with GNU radio," in *Proceedings of the GNU Radio Conference*, vol. 1, no. 1, 2016.
- [12] N. Srivastava, G. E. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov, "Dropout: A simple way to prevent neural networks from overfitting," *Journal of Machine Learning Research*, vol. 15, no. 1, pp. 1929-1958, 2014.
- [13] J. J. Kang, S. K. Park, and J. H. Roh, "Performance Analysis on Digital Phase Difference Measurement Techniques for Interferometer Direction Finder," *Journal of the Korea Institute of Information and Communication Engineering*, vol. 22, no. 8, pp. 1076-1082, Aug. 2018.
- [14] A. Thompson, Deep Learning on RF Data [Internet]. Available: <https://on-demand.gputechconf.com/gtc/2018/presentation/s8826-deep-learning-applications-for-radio-frequency-rf-data.pdf>.



강종진(Jong-Jin Kang)

아주대학교 국방디지털융합학과 박사과정
현재 한화시스템(주) C4 연구소 전문연구원
※ 관심분야 : 자동변조인식, 방향탐지, 전자전



김재현(Jae-Hyun Kim)

한양대학교 전산과 공학박사
현재 아주대학교 전자공학부 교수
※ 관심분야 : B5G 통신 시스템, 국방 전송네트워크, 위성시스템