

인지 무선 통신에서 전이 학습을 이용한 딥러닝 기반 변조 신호 센싱 기법

박지연*, 최유경*, 서동호*,
안준일**, 남해운^o

Deep Learning-Based Modulation Signal Detection Scheme Via Transfer Learning for Cognitive Radio Network

Jiyeon Park*, Yukyung Choi*, Dongho Seo*,
Junil Ahn**, Haewoon Nam^o

요약

인지 무선 통신 네트워크에서 우수한 성능의 딥러닝 기반 신호 센싱 모델을 구현하기 위해서는 양질의 학습데이터가 필요하다. 하지만 실제 환경에서는 변조 방식에 따른 서로 다른 양질의 학습데이터를 충분하게 확보하지 못하는 경우가 많다. 본 논문에서는 인지 무선 통신에서 적은 학습데이터로 주 사용자의 신호를 효과적으로 센싱하기 위해 동적 시간 굽힘을 통한 변조 신호 간 유사성을 이용한 전이학습 기반의 합성곱 신경망 모델 구현 방식을 제안한다.

Key Words : Signal detection, Cognitive radio, Deep learning, Transfer Learning, Dynamic time warping

ABSTRACT

A significant amount of labeled training data is required to implement a superior deep learning-based

signal detector for cognitive radio network. In general, however, training data is often not sufficiently guaranteed depending on modulation. In this paper, we propose the deep learning-based modulation signal detection scheme via transfer learning to effectively detect a signal of the primary user with less training data in a cognitive radio network. The proposed scheme also takes into account a convolutional neural network model using the similarity between modulation signals through dynamic time warping.

1. 서론

인지 무선 통신 (cognitive radio) 방식은 주 사용자 (PU; primary user)에게 할당된 특정 주파수 대역의 사용 여부를 확인하여 부 사용자 (SU; secondary user)가 기회적으로 사용함으로써 네트워크의 주파수 사용 효율을 증가시킨다. 여기서 신호 검출 기술은 인지 무선 통신의 시작을 위한 출발점이고 스펙트럼 감지에 매우 중요한 역할을 한다.

최근 이미지, 영상 및 자연어 처리 그리고 음성 인식 분야에서 딥러닝(deep learning)이 매우 우수한 성능을 입증하였으며, 최근에는 다양한 기술 분야에서 이를 응용한 활발한 연구가 진행되고 있다^{1,2}. 특히, 합성곱 신경망(CNN; convolutional neural network)은 영상 및 이미지 인식 분야에서 우수한 성능으로 두각을 나타냄에 따라 최근엔 이를 이용하여 다양한 분야에서 적용 및 연구되고 있다³.

인지 무선 통신 네트워크 (CRN; cognitive radio network)에서 딥러닝 기반의 협력적 스펙트럼 감지 기법^{4,5} 및 RF 수신 신호의 자동 변조 분류 (automatic modulation classification)⁶에 관한 다양한 연구가 이루어지고 있다. 스펙트럼 감지 기법은 스펙트럼을 측정하여 채널의 이용 여부나 채널 사용자를 식별하는 기술이다. 기존의 방식들과 딥러닝을 이용한 스펙트럼 센싱을 비교한 결과, 딥러닝을 이용한 방식의 검출 성능이 더 뛰어났다^{7,8}. 하지만 딥러닝

※ 본 연구는 방위사업청 및 국방과학연구소의 재원에 의해 설립된 신호정보 특화연구센터 사업의 지원을 받아 수행되었음

• First Author : (ORCID:0000-0001-7620-1499) Dept. of Elec. and Comm. Eng., Hanyang University, bji0914@hanyang.ac.kr, 학생(학사), 학생회원

° Corresponding Author : (ORCID:0000-0001-9847-7023) Dept. of Elec. and Comm. Eng., Hanyang University, hnam@hanyang.ac.kr, 정교수, 정회원

* Dept. of Elec. and Comm. Eng., Hanyang University, yugyonn@hanyang.ac.kr 학생(학사), johnseo@hanyang.ac.kr, 학생(박사)

** (ORCID: 0000-0003-3192-1315) Agency for Defense Development, jun@add.re.kr, 정회원

논문번호 : 202006-115-B-LU, Received May 29, 2020; Revised July 13, 2020; Accepted July 14, 2020

기반의 접근 방식은 모델 학습을 위한 양질의 학습데이터가 받쳐주지 못한다면 우수한 성능을 보장하지 못한다. 이러한 문제점을 전이 학습 (transfer learning)을 통해 해결할 수 있다.

전이 학습이란 사전학습 모델 (pre-trained model)의 일부 혹은 전체를 원하는 데이터를 이용하여 목적에 맞게 재학습 시키는 방식이다. 전이 학습은 학습이 완료된 딥러닝 모델의 가중치를 이용하여 새로운 모델을 학습시킬 수 있기 때문에 적은 양의 학습데이터로도 상대적으로 적은 시간과 자원을 투자하여 원하는 성능의 모델을 만들어낼 수 있다는 이점을 갖는다. 또한, 사전에 습득된 정보를 이용해 새로운 목적에 맞는 모델을 디자인하는 것이 용이하여 딥러닝을 다양한 분야에 응용하고 적용하는 것을 가능케 한다^{9,10}.

본 논문에서는 CRN에서 유휴 주파수 대역을 활용하기 위해 특정 변조 신호로 학습된 CNN 기반의 수신기를 통해 주 사용자의 신호 존재 유무를 센싱하며, 다양한 변조 신호에 대해 사전 학습된 모델을 적용할 수 있도록 동적 시간 굽힘 (DTW; dynamic time warping)을 통해 변조 신호 간의 유사성을 계산하고, 서로 다른 변조 신호를 사전 학습 데이터와 대상 데이터로 사용한다. 이를 통하여 딥러닝 기반의 전이 학습을 통해 신호 검출 모델 구현 방식을 제안한다.

II. DTW 알고리즘

DTW는 관측 시점과 상관없이 샘플링 속도가 다른 데이터나 혹은 종류가 서로 다른 두 개의 시계열 데이터 간에 시간적 패턴의 유사성을 비교하는 알고리즘이다^{11,12}. 즉, 시간적 비틀림을 교정해 시계열 데이터 간의 최소 거리 및 최적 경로를 도출함으로써 데이터 간의 유사성을 계산한다¹³.

그림 1은 DTW를 이용하여 계산한 변조 신호 간의 유사성을 나타내며 행 라벨은 사전학습 데이터 (source data)를 의미하고 열의 라벨은 대상 데이터 (target data)를 의미한다. 이때 셀 값은 0에 가까울수록 데이터 간의 유사도가 높음을 의미하며, 반대로 1에 가까울수록 유사도가 낮음을 의미한다.

본 논문에서는 BPSK, QPSK, QAM16 그리고 QAM64를 이용한 4개의 변조 신호에 대해 고려한다. 그림 1에서 알 수 있듯이 QPSK와 8PSK 신호는 QAM16 신호와의 유사도가 가장 높게 나타나며, QAM16은 QPSK 신호와 유사도가 가장 높다. 다만 BPSK 신호는 전체적으로 다른 변조 신호들과의 유사성이 상대적으로 매우 낮다. 표 1은 사전학습 데이터

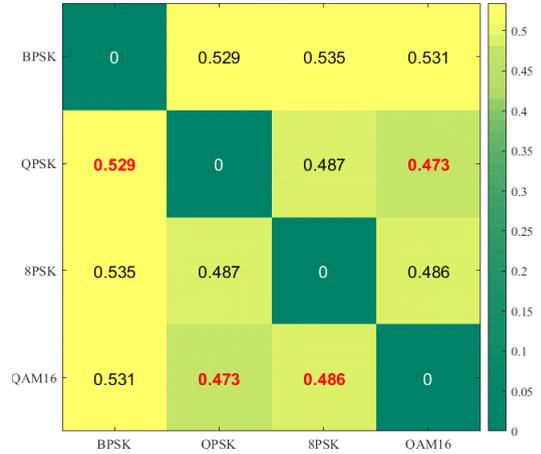


그림 1. DTW를 이용한 변조 신호 간 유사성.
Fig. 1. The similarity between the modulated signal using DTW.

표 1. DTW 값에 따른 사전학습 데이터와 대상 데이터
Table 1. Source data and target data according to modulation scheme using DTW

Source data	Target data
QPSK	BPSK
QAM16	QPSK
QAM16	8PSK
QPSK	QAM16

와 대상 데이터 간의 유사도 계산 결과를 통해 유사도가 가장 높은 사전학습 데이터와 대상 데이터 조합을 나타낸다.

III. 합성곱 신경망 기반 전이 학습

일반적으로 CNN 모델의 경우 학습해야 할 파라미터의 수가 매우 많으며, 우수한 성능을 가지는 모델을 도출하기 위해서는 학습 과정에서 충분한 양의 데이터가 필요하다는 문제점이 존재한다. 이를 해결하기 위해 다양한 방법이 연구되고 있으며 특히 전이 학습은 적은 데이터의 양으로도 높은 학습 효율성과 우수한 성능을 입증하여 다양한 분야에서 사용되고 있다. 또한 전이학습을 이용한 CNN 모델은 시계열 데이터 분류에서도 잠재력을 보인다¹⁴.

전이 학습은 사전학습 데이터를 이용해 학습된 모델의 신경망 가중치의 전이(transfer parameter)를 통해 목적에 따라 대상 데이터를 통한 해당 모델의 부분적 학습으로 가중치를 미세조정(fine-tuning)하는 기법이다¹⁴. 따라서 전이 학습을 이용하면 상대적으로 적

표 2. 신호 센싱을 위한 합성곱 신경망 구조
Table 2. Convolutional neural network structure to detect a signal

Layer	Output dimension
Input	2×1024
Conv2D(256×1×9)+stride(1×1) +padding+ReLU+dropout(0.5)	2×1024×256
Conv2D(80×1×9)+stride(1×1) +padding+ReLU+dropout(0.5)	2×1024×80
Dense+ReLU	256
Dense+Softmax	2

은 양의 데이터만으로도 원하는 목적에 맞도록 모델을 효율적으로 학습하여 얻을 수 있다.

표 2는 본 논문에서 사용된 CNN 모델의 상세 구조를 나타낸다^[5]. 두 개의 합성곱 계층과 두 개의 완전 결합 계층으로 구성된 네트워크 구조를 사용하고, 활성화 함수로는 ReLU(rectified linear unit)를 사용한다. 또한, pooling 계층에서 발생할 수 있는 특징 손실을 방지하기 위해 drop out을 이용한다.

IV. 모의실험 및 결과

본 논문에서는 SNR을 -10dB부터 2dB 단위로 0dB까지의 통신환경을 고려하였으며, SNR에 따라 서로 다른 변조 방식을 이용한 송신 데이터를 각각 10,000개씩 생성하였다. 데이터는 In-phase와 quadrature 성분으로 구성된 2×1024 형태이다. 이때 사전학습과 전이 학습을 위해 전체 데이터 셋을 4:1 비율로 8,000개와 2,000개로 나누었으며, 각각의 데이터 셋은 학습과 검증을 위해 4:1의 비율로 사용되었

다. 전이 학습을 위해 먼저 사전 학습데이터로 CNN 모델을 학습시킨 후 사전학습 모델의 합성곱 계층은 학습률을 0으로 조정 하고 마지막 두 개의 완전결합 층에 대해서만 대상 데이터의 학습을 통해 가중치를 미세 조정하였다. 그림 2는 SNR에 따라 전이학습을 이용한 신호 센싱 성능을 나타낸다. 그림 2-(a)와 (b)에서 “QPSK to BPSK”는 QPSK 데이터를 이용해 사전학습을 진행하여 BPSK 데이터로 전이학습을 진행한 경우를 의미하며 “QPSK”는 QPSK 대상 데이터를 이용하여 end-to-end 학습을 진행한 경우를 나타낸다.

그림 2-(a)와 (b)는 각각 검출 확률 및 오류 확률 성능을 나타내며 이를 통해 BPSK를 제외하고는 모든 변조 방식에 대해서 전이 학습을 적용한 것이 기존의 end-to-end 학습을 진행한 것보다 검출 확률도 높고 더 낮은 오류 확률 성능을 나타냄을 확인할 수 있다. BPSK의 경우에는 오히려 end-to-end 학습 방식의 성능이 뛰어난데 그 이유는 그림 1에서 볼 수 있듯이 다른 변조 방식과의 유사도가 전체적으로 매우 낮아서 전이 학습의 성능이 떨어지기 때문이다. 그림 2-(c)와 (d)는 QPSK와 QAM16 방식에 대해 가장 유사도가 높은 데이터와(Best TL to) 유사도가 가장 낮은 데이터(Worst TL to)를 이용하여 전이 학습을 진행한 모델의 신호 센싱 성능을 나타낸다. QPSK의 경우 유사도가 가장 높은 데이터로 전이 학습을 진행한 경우 기존의 end-to-end 방식보다 경보 확률이 72%에서 95%로 크게 증가하였으며 여러 확률 또한 크게 낮아졌다. QAM16의 경우엔 검출 확률의 증가 폭이 크진 않지만 오류 확률의 경우 35%에서 17%로 절반 이상 줄어들었음을 확인할 수 있다.

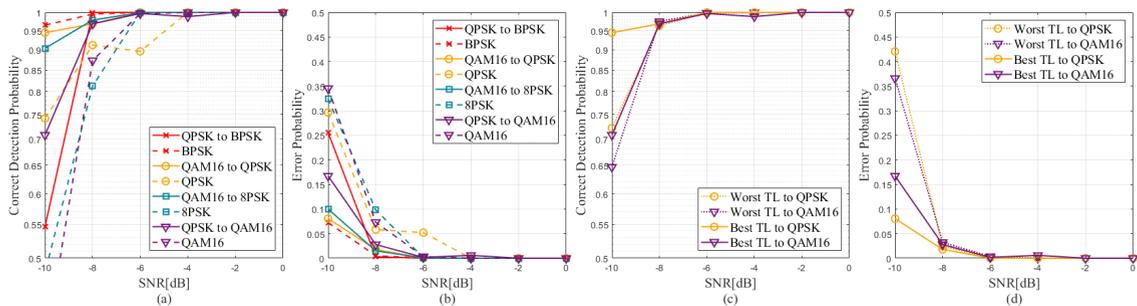


그림 2. SNR에 따른 전이학습을 이용한 신호 센싱 성능: (a) 높은 유사도 기반의 전이학습의 검출확률; (b) 높은 유사도 기반의 오류확률; (c) 유사도의 차이에 따른 전이학습 검출확률; (d) 유사도의 차이에 따른 전이학습 오류확률
Fig. 2. The signal detection performance via transfer learning at the various SNR: (a) detection probability of transfer learning based on high similarity; (b) error probability of transfer learning based on high similarity; (c) detection probability of transfer learning according to the difference in similarity; (d) error probability of transfer learning according to the difference in similarity

V. 결 론

실제 환경에서는 변조 방식에 따른 서로 다른 양질의 학습데이터를 충분히 확보하기 어렵다. 때문에 본 논문에서는 동적 시간 굽힘을 이용하여 변조 방식이 다른 데이터 간의 유사도를 측정하고 전이학습을 기반으로 CNN 모델 구현 방식을 제안한다. 사전 데이터와 대상 데이터의 유사도가 높은 경우 end-to-end 학습 방식의 성능보다 전이 학습을 이용했을 때 더 좋은 센싱 성능을 보였다. 반면에 데이터 간의 유사도가 낮은 경우에는 end-to-end 학습 방식이 더 높은 성능을 보임을 확인하였다. 향후 연구 과제로는 다양한 변조 방식을 고려한 신호 분류에 대한 연구가 필요하다.

References

- [1] Y. LeCun, Y. Bengio, A. Courville, and G. Hinton, *Deep Learning*, Cambridge: MIT Press, 2016
- [2] C. Robert, *Machine learning, a probabilistic perspective*, Taylor & Francis, 2014.
- [3] J. Chae, H. Ko, B. Lee, and N. Kim, "A study on the pipe position estimation in gpr images using deep learning based convolutional neural network," *JICS*, vol. 20, no. 4, pp. 39-46, Aug. 2019.
- [4] W. Lee, M. Kim, and D. Cho, "Deep cooperative sensing: Cooperative spectrum sensing based on convolutional neural networks," *IEEE Trans. Veh. Technol.*, vol. 68, no. 3, pp. 3005-3009, Mar. 2019.
- [5] Z. Ye, A. Gilman, Q. Peng, K. Levick, P. Cosman, and L. Milstein, "Comparison of neural network architectures for spectrum sensing," *IEEE Globecom Workshops 2019 (GC Wkshps 2019)*, Waikoloa, HI, USA, December 2019.
- [6] T. J. O'Shea, T. Roy, and T. C. Clancy, "Over-the-air deep learning based radio signal classification," *IEEE J. Sel. Topics Signal Process.*, vol. 12, no. 1, pp. 168-179, Feb. 2018.
- [7] S. Zheng, S. Chen, P. Qi, H. Zhou, and X. Yang, "Spectrum sensing based on deep learning classification for cognitive radios," in *China Commun.*, vol. 17, no. 2, pp. 138-148, Feb. 2020.
- [8] C. Liu, J. Wang, X. Liu, and Y. Liang, "Deep CM-CNN for spectrum sensing in cognitive radio," *IEEE J. Sel. Areas in Commun.*, vol. 37, no. 10, pp. 2306-2321, Oct. 2019.
- [9] H. Lee, J. Kim, J. Yu, Y. Jeong and S. Kim, "Multi-class classification using transfer learning based convolutional neural network," *JKIIS*, vol. 28, no. 6, pp. 531-537, Dec. 2018.
- [10] S. Chung and M. Chung, "Pedestrian classification using CNN's deep features and transfer learning," *JICS*, vol. 20, no. 4, pp. 91-102, Aug. 2019.
- [11] S. Kim and M. Park, "A study on time-series clustering analysis based on dynamic time warping," *JKDAS*, vol. 20, no. 5, pp. 2319-2332, Oct. 2018.
- [12] C. Hwang, Y. Kim, C. Kim, and J. Kim, "Fault detection and diagnosis of induction motors using LPC and DTW methods," *JKSCI*, vol. 16, no. 3, pp. 141-147, Mar. 2011.
- [13] D. Jeong, "Enhancing classification performance of temporal keyword data by using moving average-based dynamic time warping methods," *JKOSIM*, vol. 36, no. 4, pp. 83-105, Dec. 2019.
- [14] H. I. Fawaz, G. Forestier, J. Weber, L. Idoumghar, and P. A. Muller, "Transfer learnig for time series classification," in *Proc. IEEE Int. Conf. Big Data 2018*, pp. 1367-1376, Seattle, WA, USA, December 2018.
- [15] Q. Peng, A. Gilman, N. Vasconcelos, P. C. Cosman, and L. B. Milstein, "Robust deep sensing through transfer learning in cognitive radio," *IEEE Wireless Commun. Lett.* vol. 9, no. 1, pp. 38-41, Jan. 2020.