

딥러닝 기반 CFAR 알고리즘의 오경보 확률 조절을 위한 손실함수 설계

이현희, 이승환, 신동준
한양대학교 융합전자공학과

fly4hyun@hanyang.ac.kr, kr3951@hanyang.ac.kr, djshin@hanyang.ac.kr

Design of Loss Function for False Alarm Control of Deep Learning-Based CFAR Detector

Hyunhee Lee, Seunghwan Lee, Dong-Joon Shin
Hanyang University

요 약

본 논문은 딥러닝(deep learning) 기반 레이더용 CFAR(constant false alarm rate) 검출 기법에서 오경보 확률(false alarm probability)을 조절할 수 있는 조정 계수(scale factor)를 포함하는 정규화 항을 도입한 새로운 손실 함수(loss function)를 제안한다. 제안된 손실 함수를 사용하여 다양한 딥러닝 기반 CFAR 검출 기법의 오경보 확률을 조절할 수 있음을 확인하고, 딥러닝 기반 CFAR 검출 기법이 SNR(signal-to-noise)의 변화에 상관없이 오경보 확률이 거의 일정하게 유지되는 CFAR의 기본 특성을 만족시키는 것을 확인하였다.

I. 서 론

4 차 산업 혁명이 급속도로 진행됨에 따라 자율주행 차량(autonomous vehicle) 기술이 고도화되고, 현재는 상용화되어 시범 운행하는 단계가 되었다. 자율주행에서는 레이더, Lidar 및 카메라 등의 다양한 센서들이 조합되어 사용되고 있으며, 이러한 센서로부터 주변 사물들의 위치 및 속도 등을 실시간으로 추정한다. 이중 레이더의 대표적인 기법으로 주변 잡음 및 간섭 정보를 통해 타겟(target)의 존재 유무를 결정하는 CFAR(constant false alarm rate) 검출 기법이 있다[1]. 최근에는 딥러닝(deep learning) 기법을 이용하여 CFAR 검출 기법을 대체하는 연구가 진행되고 있으며, 기존 CFAR 검출 기법보다 타겟 탐지 확률(detection probability)이 향상된 딥러닝 기법들이 개발되고 있다. 하지만 주변 환경에 맞추어 검출 기법의 오경보 확률(false alarm probability)을 일정값 이하로 조절할 수 있어야 하는데, 이러한 딥러닝 기반 CFAR 검출 기법은 원하는 오경보 확률을 만족시키도록 모델을 쉽게 학습하지 못한다.

본 논문에서는 딥러닝 기반 CFAR 검출 기법의 오경보 확률을 쉽게 조절할 수 있는 손실함수(loss function)를 제안한다. 딥러닝의 대표적인 신경망으로 구성된 CFAR 검출 기법들에 대해서 본 논문에서 설계한 손실함수가 잘 동작함을 확인한다.

II. 딥러닝 기반 CFAR 알고리즘

(1) 기존 딥러닝 기반 CFAR 알고리즘의 한계

레이더 신호처리 과정에서 생성된 range-Doppler spectrum을 학습 데이터(training data)로 하여 그림 1의 첫 번째 그림과 같이 합성곱 신경망(convolutional neural network, CNN)으로 구성된 딥러닝 모델을 학습시켜 기존 CFAR 검출 기법보다 탐지 성능을 향상시켰다[2]. 표 1은 SNR(signal-to-noise)의 변화에 따른 기존 합성곱 신경망 CFAR 검출기의 탐지 및

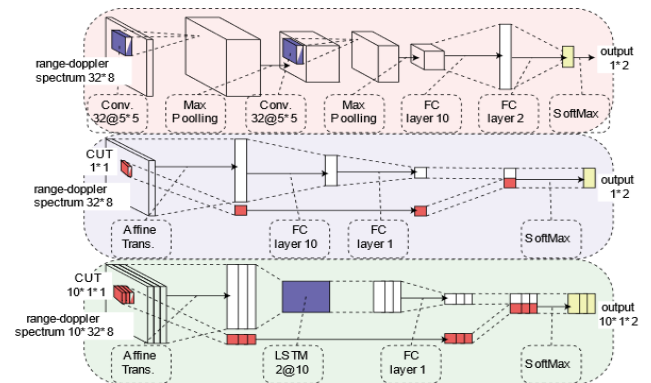


그림 1. 위에서부터 합성곱 신경망, 완전 연결 신경망, 순환 신경망 CFAR 검출기 구조도

표 1. 기존 합성곱 신경망 CFAR 검출기의 SNR에 따른 탐지 확률(probability of detection, PD) 및 오경보 확률(probability of false alarm, PF)

SNR(dB)	4	6	9	11	13
PD	0.5422	0.732	0.8809	0.9654	0.9951
PF	0.0348	0.0261	0.0141	0.0038	0.0006

오경보 확률을 나타낸다. 여기서 오경보 확률이 SNR에 따라 크게 변하며 원하는 오경보 확률을 가지는 모델을 학습할 수 없다. 본 논문에서는 합성곱 신경망 CFAR 검출기뿐만 아니라 딥러닝의 대표적인 신경망인 완전 연결 신경망(fully-connected neural network, FCNN) 및 순환 신경망(recurrent neural network, RNN)에서 원하는 오경보 확률을 가지도록 동작하는 손실 함수를 제안한다. 순환 신경망의 경우 순환 신경망의 일종인 LSTM(Long Short-Term Memory models)을 사용하였다. 실험에 사용되는 신경망 CFAR 검출기 구조는 그림 1과 같이 구성되어 있다.

(2) 오경보 확률 피드백을 이용한 딥러닝 기법

딥러닝 모델의 매 학습마다 오경보 확률을 측정하여 다음 타겟이 있는 데이터와 타겟이 없는 데이터 사이의

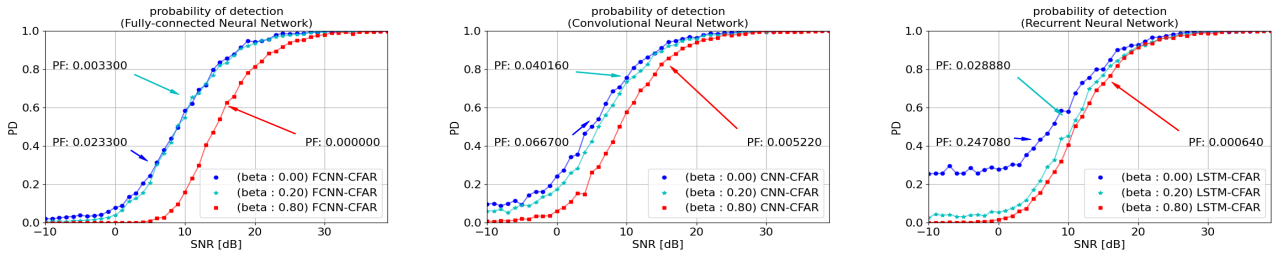


그림 2. 왼쪽에서부터 완전 연결 신경망, 합성곱 신경망, 순환 신경망 CFAR 검출기의 고정된 오경보 확률값들에 대한 탐지 확률

비율을 조절해가면서 딥러닝 모델의 오경보 확률을 조절할 수 있다[3]. 목표 오경보 확률보다 더 큰 오경보 확률을 가지면 타겟이 있는 데이터의 비율을 줄여서 오경보 확률을 낮추고, 반대로 더 작은 오경보 확률을 가지면 타겟이 없는 데이터의 비율을 줄여서 오경보 확률을 증가시켜 오경보 확률을 조절할 수 있다. 그러나 원하는 오경보 확률을 쉽게 학습시키기 어렵고 데이터의 비율을 조절해야 하기 때문에 학습에 사용되는 데이터양이 감소하는 문제점이 있다.

III. 오경보 조절을 위한 손실함수 설계

본 논문에서는 손실함수로 주로 사용되는 크로스 엔트로피 손실 함수(cross-entropy loss function)에 다음과 같은 조정 계수 β 를 포함한 정규화 항을 추가하여 오경보 확률을 조절한다.

$$L = CE(f(x), t) + \beta \times CE(f(x), 0). \quad (1)$$

여기서 L 은 본 논문에서 제안하는 손실함수, $CE(\cdot)$ 는 크로스 엔트로피 함수, $f(\cdot)$ 는 모델의 출력값, x 는 입력 데이터, t 는 입력 데이터에 대한 정답값, β 는 오경보 확률을 조절해주는 조정 계수이다. 정답값 t 는 타겟이 있는 경우 1, 타겟이 없는 경우 0이다. 크로스 엔트로피 함수 $CE(\cdot)$ 는 다음과 같다.

$$CE(f(x), t) = -t \times \log(f(x)) - (1-t) \times \log(1-f(x)) > 0. \quad (2)$$

식(2)를 식(1)에 대입하여 정리하면 본 논문에서 제안하는 손실함수는 다음과 같다.

$$L = -t \times \log(f(x)) - (1-t-\beta) \times \log(1-f(x)) > 0. \quad (3)$$

데이터의 정답값 t 에 따라 식(3)을 나눠서 정리하면 다음과 같다.

$$L = \begin{cases} -\log(f(x)) - \beta \times \log(1-f(x)), & t = 1 \\ -\log(1-f(x)) - \beta \times \log(1-f(x)), & t = 0. \end{cases} \quad (4)$$

첫 번째 항은 기존 크로스 엔트로피 함수로 $t=1$ 일 때 타겟이 있고, $t=0$ 일 때 타겟이 없다고 모델을 학습시킨다. 두 번째 항은 정답값에 상관없이 항상 조정 계수 β 만큼 타겟이 없다고 모델을 학습시킨다. β 를 증가시키면 모델은 β 를 증가시키기 전보다 더 타겟이 없다고 판단하도록 학습된다. 그러므로 타겟이 없다고 판단하는 확률인 오경보 확률을 감소시키는 효과를 나타낸다.

IV. 실험결과

본 논문에서는 완전 연결 신경망, 합성곱 신경망, 순환 신경망의 조정 계수의 변화에 따른 오경보 확률 변화를 확인한다. 타겟이 있거나 없는 32×8 크기의 range-Doppler spectrum을 각각 20,000개 생성하여 신경망 모델에 대한 학습을 진행했다. 타겟이 있는 데이터는 SNR이 0dB, 4dB, 7dB, 10dB, 13dB, 16dB, 19dB, 22dB,

표 2. 조정 계수가 0.2인 신경망 모델들의 SNR에 따른 오경보 확률

SNR(dB)	-10	2	15	24	36
FCNN	0.002	0.003	0.001	0.002	0.003
CNN	0.041	0.035	0.040	0.041	0.041
LSTM	0.033	0.022	0.022	0.035	0.02

25dB, 29dB인 경우 각각 2,000개 생성하였으며, 노이즈는 exponential 분포에서 i.i.d.하게 생성하였다.

학습된 모델들은 50,000개의 타겟이 없는 데이터를 통해 오경보 확률을 측정한 다음, SNR이 -10dB부터 40dB까지 1dB 간격으로 타겟이 있는 1,000개 데이터를 생성하여 각 SNR에 따른 모델의 탐지 확률을 측정하였다. 오경보 확률을 조절하기 위해 조정 계수 β 값을 변경해가면서 측정을 반복하였다.

그림 2는 각 모델마다 SNR에 따른 탐지 확률을 나타낸다. 세 모델 모두 조정 계수가 증가할수록 오경보 확률이 감소하는 것을 알 수 있다. 각 모델들의 SNR에 따른 오경보 확률을 측정해보면 표 2와 같이 SNR의 변화에 큰 영향이 없이 비교적 일정한 오경보 확률을 유지하는 것을 알 수 있다.

V. 결론

본 논문에서는 딥러닝 기반 CFAR 검출 기법의 오경보 확률을 쉽게 조절할 수 있는 손실함수를 제안하였다. 실험을 통해 제안된 기법이 딥러닝의 대표적인 모델들에서 잘 동작함을 확인하였다. 추후 연구로는 오경보 확률의 피드백을 이용하여 원하는 오경보 확률을 달성할 수 있는 조정 계수에 관한 연구를 고려할 수 있다.

ACKNOWLEDGMENT

이 논문은 2021년도 정부(산업통상자원부)의 재원으로 한국산업기술진흥원의 지원을 받아 수행된 연구임 (P0017011, 2021년 산업혁신인재성장지원사업)

참고 문헌

- [1] M. A. Richards, Fundamentals of Radar Signal Processing, McGraw-Hill Education, 2014.
- [2] L. Wang, J. Tang, and Q. Liao, "A study on radar target detection based on deep neural networks," IEEE Sensors Lett., Vol. 3, no. 3, pp. 1-4, Mar. 2019.
- [3] 김지호, 이승환, 신동준, "오경보 확률의 피드백을 이용하여 학습한 DNN 기반 CFAR 검출기," 한국통신학회 동계종합학술발표회 논문집, Vol. 68, no. 1, pp. 784-785, Jan. 2019.