

OFDM 레이다를 위한 딥러닝 기반 표적의 거리 및 속도 추정 기법

최재웅¹ · 정의림^{2*}

Deep learning-based target distance and velocity estimation technique for OFDM radars

Jae-Woong Choi¹ · Eui-Rim Jeong^{2*}

¹Graduate Student, Department of Mobile Convergence and Engineering, Hanbat National University, Daejeon, 34158 Korea

^{2*}Professor, Department of Information and Communication Engineering, Hanbat National University, Daejeon, 34158 Korea

요 약

본 논문에서는 OFDM 레이다를 위한 딥러닝 기반 표적의 거리 및 속도 추정 기법을 제안한다. 제안하는 기법은 표적으로부터 반사된 수신 신호를 받아 변조신호 제거 후 2차원 FFT를 통해 2차원 주기도를 얻는다. 주기도는 기존 및 제안 방법에서 표적의 거리 및 속도를 추정하는 입력신호이다. 주기도에서 정점은 표적의 위치를 나타내는데 표적의 거리 및 속도 추정을 위해 널리 사용되는 기존 기법은 CFAR (Constant False Alarm Rate) 알고리즘이다. 반면 제안하는 기법은 다중 출력 CNN (Convolutional Neural Network)을 이용하여 거리 및 속도를 추정한다. 기존 기법과 달리 제안 기법은 주기도 이외에 잡음 전력과 같이 추가적인 정보가 필요하지 않아 사용하기 편리하다. 컴퓨터 시뮬레이션 결과에 따르면 제안 추정 기법은 기존 기법보다 거리 및 속도 추정 MSE (Mean Square Error) 오차 성능을 5배 이상 개선하며 송신 OFDM 심볼 개수가 증가할수록 정확도가 향상되는 특성을 보인다.

ABSTRACT

In this paper, we propose deep learning-based target distance and velocity estimation technique for OFDM radar systems. In the proposed technique, the 2D periodogram is obtained via 2D fast Fourier transform (FFT) from the reflected signal after removing the modulation effect. The periodogram is the input to the conventional and proposed estimators. The peak of the 2D periodogram represents the target, and the constant false alarm rate (CFAR) algorithm is the most popular conventional technique for the target's distance and speed estimation. In contrast, the proposed method is designed using the multiple output convolutional neural network (CNN). Unlike the conventional CFAR, the proposed estimator is easier to use because it does not require any additional information such as noise power. According to the simulation results, the proposed CNN improves the mean square error (MSE) by more than 5 times compared with the conventional CFAR, and the proposed estimator becomes more accurate as the number of transmitted OFDM symbols increases.

키워드 : OFDM 레이다, 다중 출력 CNN, 거리 및 속도 추정, 딥러닝

Keywords : OFDM radar, Multiple output CNN, Distance and velocity estimation, Deep learning

Received 4 November 2021, Revised 11 November 2021, Accepted 22 November 2021

* Corresponding Author Eui-Rim Jeong(erjeong@hanbat.ac.kr, Tel:+82-42-821-1752)

Professor, Department of Information and Communication Engineering, Hanbat National University, Daejeon, 34158 Korea

Open Access <http://doi.org/10.6109/jkiice.2022.26.1.104>

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

최근 상업, 산업, 군사와 항공 분야에서 다양한 데이터 전송과 높은 전송속도가 요구되고 있으며 이에 따른 대역폭 수요가 증가하고 있다[1]. 이러한 요구로 인해 주파수 스펙트럼이 과밀화되고 스펙트럼 자원이 부족해져 주파수를 공유 또는 재사용 하는 것에 관심이 높아지고 있다[2]. 주파수 자원 공유를 위해서는 간섭을 줄여야 하는데 빔포밍(Beamforming) 기법은 원하는 사용자 방향으로만 신호를 전송하고 다른 방향으로 전송되지 않도록 하여 간섭을 줄이고 주파수 공유를 쉽게 하는 중요한 기술로 인식되고 있다[3]. 하지만, 상대방이 이동하는 상황에서 빔포밍을 위한 실시간 위치 추적은 해결해야 하는 어려운 문제로 알려져 있다. 한 가지 해결방안으로 통신시스템이 레이더 기능을 탑재하여 상대(표적)와의 거리, 속도, 방향 정보를 얻을 수 있다면 추적이 용이할 것이다.

레이더 기술 중, 최근 관심을 받고 있는 직교 주파수 분할 다중화(Orthogonal Frequency Division Multiplexing, OFDM) 레이더는 통신신호를 이용하여 레이더 신호처리를 수행하므로, 데이터 전송과 동시에 레이더 기능을 수행할 수 있어 추가 주파수 자원 할당 없이 통신과 레이더 기능을 동시에 지원할 수 있는 기술로 알려져 있다[4]. OFDM 신호는 다중 경로 페이딩 환경에 견고하며 자원 관리에 높은 유연성을 가져 오늘날 대부분의 통신 시스템에 적용되고 있다. 뿐만 아니라, 광대역 OFDM 신호는 미세한 거리(Range)와 도플러 주파수(Doppler Frequency) 분해능을 위한 신호로써도 적합한 것으로 알려져 있다. 통신신호를 활용한 OFDM 레이더 관련 연구는 최근 많이 진행되고 있다. SDR (Software Defined Radio) 플랫폼을 이용한 실험 및 가능성 검증이 [5]에서 이루어졌으며, LTE와 5G NR 전송신호에 기반한 이동통신과 레이더 시스템의 융합 문제는 [6]과 [7]에서 언급하였다. 이러한 기존 연구들은 시뮬레이션과 실험을 통해 OFDM 레이더의 타당성을 검증하였으나 움직이는 표적의 거리와 속도를 추정하기 위한 새로운 기술은 제시하지 않았다.

또 다른 연구분야로, 기존 레이더 문제에 딥러닝(Deep Learning)을 적용하여 해결하는 연구도 최근 많이 진행되고 있다. 저전력 FMCW (Frequency Modulated Continuous Wave) 레이더에 합성곱 신경망(Convolutional

Neural Network, CNN)을 이용하여 손동작을 인식하는 방법이 제안되었으며[8], HFSW (High Frequency Surface Wave) 레이더에 Faster R-CNN을 적용하여 클러터(Clutter)와 간섭(Interference) 신호를 자동으로 검출하는 방법에 대해 [9]에서 연구하였다. [10]에서는 Range - Azimuth - Doppler 레이더 신호에서 딥러닝을 이용한 차량 검출 연구가 진행되었다. 하지만 현재까지 발표된 문헌 중 OFDM 레이더 시스템에서 딥러닝을 이용한 표적의 거리 및 속도 추정 문제는 다루어지지 않았다.

본 논문에서는 OFDM 레이더를 위한 다중 출력 CNN (Multiple Output CNN) 기반 표적의 거리 및 속도 추정 기법을 제안한다. 제안하는 기법의 절차는 다음과 같다. 표적으로부터 반사된 신호를 수신하여 변조효과를 제거하고, 이 과정을 연달아 송신되는 OFDM 심볼에 대해서 수행하고 쌓아서 2차원 신호를 생성한다. 이렇게 쌓은 신호에 2D Fast Fourier Transform (FFT)를 취하고 절대값 제곱을 취하여 2차원 주기도(2D Periodogram)를 얻는다. 일반적으로 주기도의 국부적 정점(Peak)은 표적을 가리키며, 이 정점의 x축 및 y축은 각각 거리와 속도를 나타낸다. 국부적 정점을 찾기 위해 가장 널리 사용되는 기존 기술은 CFAR (constant false alarm rate) 알고리즘이다. 물론 OFDM 레이더에서도 CFAR 알고리즘을 사용할 수 있으나 나중에 모의실험 결과에서 확인할 수 있듯이 추정 성능이 떨어진다. CFAR 기법에서는 주기도에서 특정 임계값(Threshold)보다 큰 값들을 검출한 후 이들 중 도플러 주파수가 0에 가까운 성분을 클러터로 간주하여 제거한 후 남은 값을 표적으로 판단한다. 클러터는 지형, 고정된 물체 등과 같이 원치 않은 후방 산란 신호 또는 에코(Echo)를 의미한다[11]. 이 때 최적의 임계값을 얻기 위해 주기도 외에 신호 대 잡음비(Signal to Noise Ratio, SNR) 및 잡음 전력 등에 대한 추정이 필요한데, 이 추정 값의 정확도는 표적 인식 정확도에 큰 영향을 미친다. 반면, 제안하는 기법은 딥러닝 기법 중 하나인 다중 출력 CNN을 통해 표적의 거리와 속도를 곧바로 추정한다. 일반적인 CNN은 출력이 1개이지만 본 논문에서 설계하는 CNN은 2개의 출력을 가지며 이를 통해 거리와 속도를 동시에 추정한다. 레이더 성능 평가 지표로는 평균 절대 오차(Mean Absolute Error, MAE)를 선택하였으며, MAE는 표적의 실제 값과 예측 값의 평균 절대값 차이를 나타낸다. 성능평가는 컴퓨터 시뮬레이션을 통하여 수행하는데, 그 결과에 따

르면 제안하는 표적 추정기가 -20 dB에서 +22 dB의 SNR 영역에서 거리, 속도 모두에 대해 기존 CFAR (Constant False Alarm Rate) 방식에 비해 정확도가 5배 이상 개선된 결과를 보인다. 또한 추정 정확도는 SNR이 증가하고 전송 OFDM 심볼 개수가 증가할수록 향상됨을 확인할 수 있다.

본 논문의 구성은 다음과 같다. 2장에서는 입력 주기도 신호 생성과정에 관해 설명하고, 3장에서는 기존 및 제안 거리 및 속도 추정 기법을 기술한다. 그리고 4장에서 컴퓨터 시뮬레이션 결과를 통해 두 기법의 추정 성능을 비교하고 마지막으로 5장에서 결론을 맺는다.

II. OFDM 레이다 시스템 모델

그림 1은 제안하는 OFDM 레이다 시스템 모델을 보인다. 송신기에서 데이터를 변조한 후 직렬에서 병렬로 변환한다. m 번째 전송신호 벡터는 $\mathbf{x}_m = [x_{0,m}, x_{1,m}, \dots, x_{N-1,m}]^T$ 로 정의하며 N 은 IFFT (Inverse FFT) 크기를 나타낸다. $x_{n,m}$ 은 디지털 변조를 통해 생성된 복소수이다. 신호벡터 \mathbf{x}'_m 는 IFFT 수행 후의 시간 영역 신호이며 $\mathbf{x}'_m = [x'_{0,m}, x'_{1,m}, \dots, x'_{N-1,m}]^T$ 로 정의한다. 이후 병렬신호를 직렬로 변환한 후, CP (Cyclic Prefix)를 맨 앞부분에 삽입한다. CP가 삽입된 OFDM 심볼은 $\mathbf{x}''_m = [x'_{N-L_c,m}, \dots, x'_{N-1,m}, x'_{0,m}, \dots, x'_{N-1,m}]$ 와 같이 나타낼 수 있으며 L_c 는 CP의 길이이다. 송신 신호 \mathbf{x}''_m 는 송신 안테나를 통해 전송되고 표적으로부터 반사된 수신 OFDM 심볼은 $\mathbf{y}'_m = [y'_{N-L_c,m}, \dots, y'_{N-1,m}, y'_{0,m}, \dots, y'_{N-1,m}]$ 로 정의한다. 수신신호 \mathbf{y}''_m 는 반사

체 (표적)와의 거리에 따른 시간 지연, 반사체의 이동 속도에 의한 도플러 주파수 및 신호 감쇠로 인해 송신 \mathbf{x}''_m 과 다르게 나타난다. \mathbf{y}''_m 의 CP를 제거한 후 병렬 형태로 변환된 신호는 $\mathbf{y}'_m = [y'_{0,m}, y'_{1,m}, \dots, y'_{N-1,m}]^T$ 이고, FFT를 통해 주파수 영역 신호 $\mathbf{y}_m = [y_{0,m}, y_{1,m}, \dots, y_{N-1,m}]^T$ 를 얻는다. 송신신호 \mathbf{x}_m 와 수신신호 \mathbf{y}_m 를 비교하여 표적의 거리와 속도를 추정하는 것이 OFDM 레이다의 원리이다. 송신기에서 M 개의 OFDM 심볼을 연속해서 전송한다고 가정하고 이렇게 전송하는 신호 묶음을 프레임이라고 정의한다. 연속해서 수신된 M 개의 OFDM 심볼에 대해 위의 절차를 반복하고 쌓아 2차원 신호를 생성한다. 송신과 수신된 2차원 신호는 각각 (1), (2)와 같다.

$$\mathbf{X} = \begin{bmatrix} x_{0,0} & x_{0,1} & \dots & x_{0,M-1} \\ x_{1,0} & x_{1,1} & \dots & x_{1,M-1} \\ \vdots & \vdots & \ddots & \vdots \\ x_{N-1,0} & x_{N-1,1} & \dots & x_{N-1,M-1} \end{bmatrix} \quad (1)$$

$$\mathbf{Y} = \begin{bmatrix} y_{0,0} & y_{0,1} & \dots & y_{0,M-1} \\ y_{1,0} & y_{1,1} & \dots & y_{1,M-1} \\ \vdots & \vdots & \ddots & \vdots \\ y_{N-1,0} & y_{N-1,1} & \dots & y_{N-1,M-1} \end{bmatrix} \quad (2)$$

(1)과 (2)에서 각 행은 부반송파, 각 열은 OFDM 심볼의 인덱스를 나타낸다. 예를 들어, $x_{k,l}$ 은 $l+1$ 번째 OFDM 심볼에서 $k+1$ 번째 부반송파를 가리킨다. 송신기의 최종 샘플링 주파수를 f_s , 반송파 주파수는 f_c , 부반송파 간격은 $\Delta f (= f_s/N)$ 라고 정의하자. 이 정의에 따라 OFDM 심볼 길이는 $T (= 1/\Delta f)$ 이며 보호 구간의 길이는 $T_c (= L_c/f_s)$ 이다. 따라서, CP를 포함한 OFDM

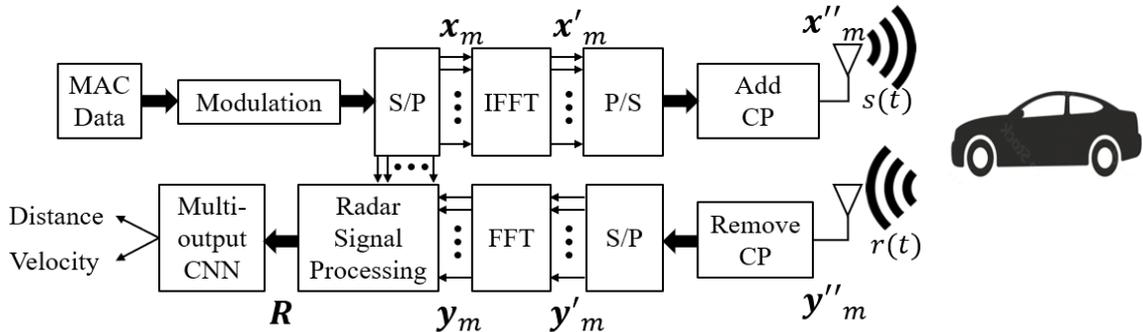


Fig. 1 OFDM radar system model

심볼의 시간 길이는 $T_O (= T + T_G)$ 이다.

\mathbf{Y} 가 \mathbf{X} 와 정확히 어떤 차이가 발생하는지 살펴보자. 안테나에서 송신하는 아날로그 신호를 $s(t)$, 표적에서 반사되어 수신하는 신호를 $r(t)$ 라고 정의하자. 수신 신호 $r(t)$ 는 표적들에 의해 반사된 송신 신호 $s(t)$ 의 중첩과 잡음 등으로 구성될 것이다. 또한 고정된 지형지물에 의해 반사된 클러터 성분도 수신된다. 이러한 환경을 고려하면 수신 신호 $r(t)$ 는 (3)과 같이 나타낼 수 있다.

$$r(t) = \sum_{h=0}^{H_t-1} b_h s(t - \tau_h) e^{j2\pi f_{D,h} t} e^{j\phi_h} + \sum_{i=0}^{H_c-1} b_i s(t - \tau_i) e^{j\phi_i} + \tilde{\mathbf{z}}(t) \quad (3)$$

여기에서 H_t 는 표적의 개수, H_c 는 클러터 개수를 의미한다. τ_h 은 반사된 신호의 시간지연을 나타내며 이 지연은 결과적으로 위상 변이를 발생한다. 위상 변이 값은 주파수의 함수이므로 부반송파마다 다르게 나타나며, 이러한 영향을 고려했을 때, (2)의 $y_{k,l}$ 원소를 $x_{k,l}$ 의 합수로 나타내면 다음과 같다.

$$y_{k,l} = \sum_{h=0}^{H_t-1} b_h x_{k,l} e^{j2\pi T_{ofD,h} l} e^{-j2\pi \tau_h \Delta f k} e^{j\phi_h} + \sum_{i=0}^{H_c-1} b_i x_{k,l} e^{-j2\pi \tau_i \Delta f k} e^{j\phi_i} + \tilde{z}_{k,l} \quad (4)$$

시간 지연 τ_h 은 거리에 의해 발생하며 $2 \times d_h / c_0$ 와 같이 계산된다. 도플러 주파수는 $f_{D,h} = (2 \times v_{rel,h} / c_0)$ 이며 $v_{rel,h}$ 와 c_0 는 각각 표적의 상대 속도와 광속도를 가리킨다. ϕ_h 는 미상의 위상 편차이며 b_h 는 반사된 신호의 크기이다. 신호 감쇠값인 b_h 는 일반적으로 다음과 같이 주어진다.

$$b_h = \sqrt{\frac{c_0 \sigma_{RCS,h}}{(4\pi)^3 d_h^4 f_c^2}} \quad (5)$$

여기에서 $\sigma_{RCS,h}$ 는 레이더 단면적(Radar Cross Section)으로 표적에서 반사된 에너지의 척도로써 표적의 크기를 나타낸다. 앞서 언급했듯이 클러터는 특정 표적이 아닌 지형 또는 고정물체에 의한 반사 신호를 의미하며 클러터 성분의 도플러 주파수는 0에 가깝다. 본 논문에서

는 H_c 개의 클러터들이 존재하며 각각의 거리 d_c 는 베이블 분포(Weibull Distribution)를 따르는 무작위 값으로 생성한다.

$$f(d_c; \eta; \beta) = \frac{\beta}{\eta} \left(\frac{d_c}{\eta}\right)^{\beta-1} e^{-(d_c/\eta)^\beta} \quad (6)$$

여기에서 η 와 β 는 각각 크기(Scale)와 형상(Shape) 모수이다.

다음 단계로 \mathbf{Y} 에서 변조효과를 제거한다. 이를 위해 \mathbf{Y} 의 각 원소를 \mathbf{X} 의 각 원소로 나눈다.

$$\begin{aligned} \bar{y}_{k,l} &\triangleq y_{k,l} / x_{k,l} \\ &= \sum_{h=0}^{H_t-1} b_h e^{j2\pi T_{ofD,h} l} e^{-j2\pi \tau_h \Delta f k} e^{j\phi_h} \\ &\quad + \sum_{i=0}^{H_c-1} b_i e^{-j2\pi \tau_i \Delta f k} e^{j\phi_i} + z_{k,l} \end{aligned} \quad (7)$$

식 (7)에서, $\bar{y}_{k,l}$ 는 변조효과 제거 후의 원소를 가리키며 제거 후 2차원 행렬은 $\bar{\mathbf{Y}}$ 로 표시한다. $z_{k,l} (= \tilde{z}_{k,l} / c_{k,l})$ 는 가우시안 잡음이다. 첫 번째 유한 합(Summation)을 관찰하면 두 개의 지수함수의 곱으로 이루어진 것을 알 수 있다. 첫 번째 지수함수(Exponential Function)는 도플러 주파수($f_{D,h}$)를 포함하고 있으며, 두 번째 지수함수는 시간 지연(τ_h)을 포함하고 있다. 레이더 단면적은 수신 신호의 크기로부터 찾을 수 있다. 즉, 첫 번째 지수함수로부터 속도를 추정할 수 있고, 두 번째 지수함수로부터 거리를 추정할 수 있다. 두 개의 복소 지수함수를 분리하고 거리, 속도를 추정하기 위해 2차원 이산 푸리에 변환(Discrete Fourier Transform, DFT)을 취하며 각 원소의 크기를 제공하여 2차원 주기를 구한다.

$$\begin{aligned} R_{n,m} & \\ &= \frac{1}{NM} \left| \sum_{k=0}^{N-1} \sum_{l=0}^{M-1} \bar{y}_{k,l} w_k w_l' T e^{-j2\pi \left(\frac{kn}{N_{FFT}} + \frac{lm}{M_{FFT}} \right)} \right|^2 \end{aligned} \quad (8)$$

$R_{n,m}$ 은 $\bar{\mathbf{Y}}$ 의 2차원 주기를 나타낸다. 주기를 구하기 위한 2차원 DFT 크기는 $N_{FFT} \times M_{FFT}$ 이며 N_{FFT} 및 M_{FFT} 을 각각 N 과 M 의 정수배로 설정하면 거리, 속도 추정 분해능을 향상할 수 있다. (8)에서 w_k 와 w_l 은 1차원 윈도우 벡터를 나타내며 각각 $w_N = [w_0, w_1, \dots,$

$w_{N-1}]^T$ 과 $w_M = [w'_0, w'_1, \dots, w'_{M-1}]^T$ 의 성분이다. w_N 과 w_M 으로 구성된 윈도우 행렬은 다음과 같은 수식으로 표현한다.

$$W = w_N w_M^T \in \mathbb{R}^{N \times 1}, w_M \in \mathbb{R}^{M \times 1} \quad (9)$$

윈도우를 사용하는 목적은 DFT에 의한 리플을 줄이기 위함이다. 만약, 표적의 거리와 도플러 주파수가 특정 범위 내에서 제한된다면 주기도 행렬 R 의 일부 영역만 관찰하여도 표적 탐지를 할 수 있다. 표적 검출 및 식별은 주기도의 정점을 검출하는 것으로 수행한다. 만약, (\hat{n}, \hat{m}) 원소에서 정점이 검출되었다면, 해당 표적의 거리는 (10), 속도는 (11)과 같이 계산된다.

$$d = \frac{c_0 \hat{n}}{2\Delta f N_{FFT}} \quad (10)$$

$$v = \frac{c_0 \hat{m}}{2f_c T_O M_{FFT}} \quad (11)$$

부반송파 간격은 Δf 이고 전체 OFDM 심볼 구간은 T_O 이므로, 최대 비모호(unambiguous) 거리와 상대 속도는 각각 (12)와 (13)으로 나타낼 수 있다.

$$\left| d_{\max} \parallel \frac{c_0}{2\Delta f} \right| \quad (12)$$

$$\left| v_{\max} \parallel \frac{c_0}{2f_c T_O} \right| \quad (13)$$

부반송파 간격과 전체 OFDM 심볼 구간을 작게 설계할수록 최대 비모호 거리(d_{\max}) 및 비모호 속도(v_{\max})가 증가하게 된다.

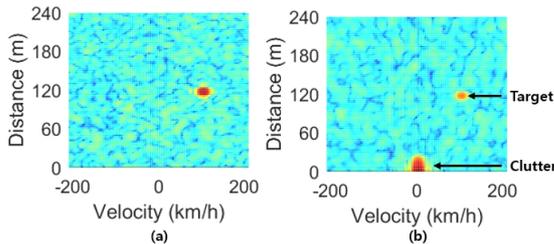


Fig. 2 Examples of 2D periodogram (R) for clutter-absence (a) and clutter-presence (b) cases

그림 2는 표적의 거리와 속도가 각각 120 m, 100 km/h일 때의 2차원 주기도, R 의 예시를 보인다. 그림 2의 (a)는 클러터가 없는(Clutter-absence, $H_c = 0$) 환경에서의 주기도, (b)는 클러터가 있는(Clutter-presence $H_c = 20$) 환경에서의 주기도를 나타낸다. 클러터는 상대 속도가 0에 가까운 지점에서 관찰되며, 속도의 방향 (-)는 표적이 멀어지는 경우, (+)는 표적이 가까워지는 경우를 나타낸다.

III. 표적 추정 기법

본 절에서는 표적의 거리와 속도를 추정하는 기존 및 제안 기법에 대해 기술한다. 기존 추정 기법은 일정 오경보율(CFAR) 알고리즘을 사용하고, 제안 추정 기법은 다중 출력 CNN을 사용한다. 본 논문에서는 두 기법 모두 표적 개수가 1개($H_t = 1$)인 경우만 다룬다.

3.1. 기존 추정 기법 (CFAR)

기존기법은 그림 2와 같은 주기도 신호에서 임계값을 설정하여 이 임계값을 넘는 영역을 관찰하여 표적의 거리 및 속도를 추정한다. 그런데 임계값은 잡음 전력의 함수로 결정되기 때문에 잡음 추정이 선행되어야 한다. 잘 알려진 기존기법으로 주변 잡음 신호에 따라 임계값을 자동으로 설정하는 CFAR 알고리즘이 널리 사용된다. 그중에서도 본 논문은 CA-CFAR (Cell Average CFAR)을 사용한다.

먼저, 훈련 셀(Training Cell)은 테스트 셀(Cell Under Test)에 대한 임계값을 결정해주는 샘플들이며, 보호 셀(Guard Cell)은 테스트 셀 주변에 인접한 셀들로서 임계값 결정에 영향을 주지 않도록 지정한 보호영역이다. 각 테스트 셀 지점의 임계값 TH 는 다음과 같이 결정된다.

$$TH = \alpha P_n \quad (14)$$

여기에서 α 는 크기 계수를 나타내며 P_n 는 훈련 셀들에 의해 얻어진 잡음 전력 추정값을 나타낸다. P_n 은 (15)와 같이 결정된다.

$$P_n = \frac{1}{N_t} \sum_{i=1}^{N_t} T_i \quad (15)$$

여기서 T_i 는 훈련 셀의 해당 신호 값, N_i 는 훈련 셀의 개수를 나타낸다. (14)의 α 는 아래의 식과 같이 N_i 와 오경보율 P_{fa} 에 대한 함수로 주어진다.

$$\alpha = N_i(P_{fa}^{-1/N_i} - 1) \quad (16)$$

그림 3은 2차원 CA-CFAR 윈도우 예시를 보인다.

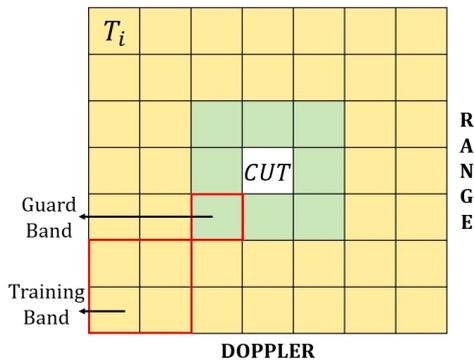


Fig. 3 Example of CA-CFAR window

그림 3에서 보호 셀의 크기 및 훈련 셀의 크기는 각각 1×1 및 2×2 이다.

그림 4는 CA-CFAR 검출기의 추정 절차를 보인다. 먼저, 2차원 주기도를 검출기에 입력한 후 결정된 임계값을 초과하는 샘플을 표적으로 인식하여 검출한다. 이때의 출력값은 명시한 보호 및 훈련 셀의 크기와 오경보율에 따라 달라진다. 클러스터 성분을 제거하기 위해 제로 도플러 필터링(Zero Doppler Filtering)을 수행하고 입력 신호와 마스킹(Masking)을 수행한 뒤, 최종 신호로부터 정점을 찾아 표적으로 결정한다. 이 기법은 제로 도플러 필터링 단계에서 상대 속도가 0에 가까운 실제 표적이 삭제되는 문제가 발생할 수 있다.

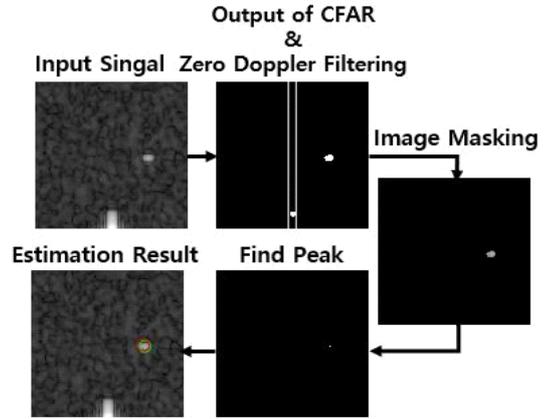


Fig. 4 Estimation procedure of CA-CFAR detector

3.2. 제안 추정 기법

제안하는 다중 출력 CNN 추정기는 2차원 주기로 부터 표적의 거리와 속도를 곧바로 예측한다. 딥러닝 기법의 하나인 CNN은 이미지 분류에서 특히 뛰어난 성능을 보여준다[12, 13]. 그림 4와 같이, 주기도는 일종의 흑백 이미지로 볼 수 있으므로 본 문제에 CNN을 활용하는 것은 적합하다고 볼 수 있다. 일반적인 CNN은 1개의 출력 구조를 가지지만, 제안하는 다중 출력 CNN은 2개의 출력을 가진다. 표적 1개에 대해 거리와 속도를 추정하기 위해 보편적인 CNN은 2개의 신경망 필요하지만 제안하는 CNN은 1개의 신경망으로부터 동시에 거리와 속도 추정을 수행한다. 그림 5는 제안하는 다중 출력 CNN의 구조를 보인다. 이 모델은 ResNet-50의 기본 구조[14]를 따르지만, 입력과 출력 구조를 본 문제에 맞게 변형하였다. 주기도는 입력 계층(Input Layer), 합성곱 계층(Convolutional Layer), 풀링 계층(Pooling Layer)을 지난다. 마지막 풀링 계층의 출력이 서로 다른 완전 연결 계층(Fully Connected Layer, fc)에 입력되며 각각의

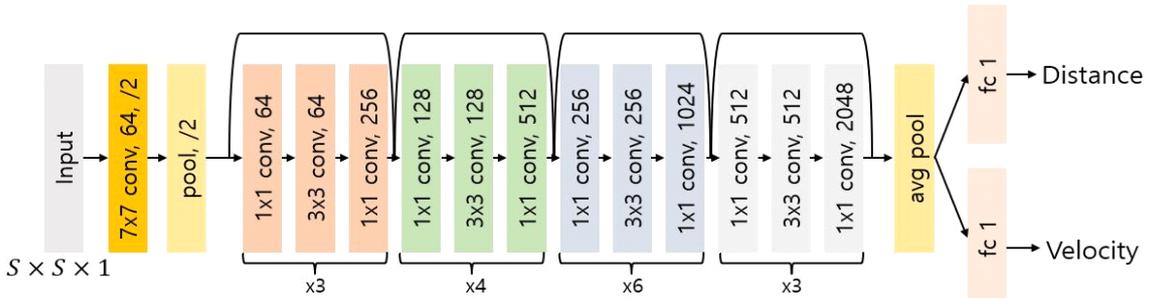


Fig. 5 Proposed multiple output CNN structure

완전연결계층은 표적의 거리와 속도를 예측한다. 서론에서 언급한 것처럼 CNN의 입력 신호는 2가지이다. 첫째는 클러터가 없는 환경, 둘째는 클러터가 있는 환경에서의 주기도이다. 입력 신호는 전체 주기도에서 일정한 영역을 잘라낸 행렬이며 크기는 $S \times S$ 이다. CNN의 입력 크기는 2차원 FFT 및 잘린 영역의 크기에 따라 변한다. 주기도로부터 거리와 속도를 예측하므로 본 문제는 회귀 문제이다. 기존 기법과 달리, 제안 기법은 주기도 외에 아무런 추가정보가 필요 없다.

IV. 시뮬레이션 결과

4.1. 시뮬레이션 환경

학습 및 테스트 데이터 생성과 CA-CFAR 검출기의 성능 검증은 Matlab, 다중 출력 CNN의 성능은 딥러닝 프레임워크인 Tensorflow를 통해 검증하였다. 시뮬레이션 환경에서 주기도 생성을 위한 레이더 신호처리 관련 환경 파라미터는 표 1에서 정리하였다.

Table. 1 Simulation environments

Parameter	Symbol	Value
Sampling frequency	f_s	122.88 MHz
IFFT(FFT) size	N	4096
Num. of OFDM symbol	M	16, 32, 64, 128
2D FFT size	$N_{FFT} \times M_{FFT}$	2048×128
Length of CP	L_c	296
Center frequency	f_c	28 GHz
Scale and shape factor	α, β	1, 1
Cropped region size	S	100
Num. of targets	H_t	1
Num. of clutter components	H_c	0, 20

전체 OFDM 심볼 구간 T_O 는 35.74 us, 부반송파 간격 Δf 는 30 KHz이다. 전체 4,096개의 부반송파 중 1,284개가 사용되어 신호의 대역폭은 약 40 MHz이다. 윈도우 함수는 Hanning을 사용하였다. 학습 데이터의 경우, 표적으로부터 반사된 신호의 SNR은 -14~22 dB 범위에서 무작위 선택된다. 전체주기도에서 크롭된 영역의 크기는 100×100 으로 탐지 가능한 거리와 속도는 각각 0~244 m, -211~211 km/h에 해당한다. 기존 추정

기법에서의 파라미터는 보호 셀 크기는 1×1 , 훈련 셀 크기는 5×5 이다. 그림 6은 OFDM 심볼 개수(M) 64일 때, 송신 OFDM 신호의 스펙트럼을 보인다.

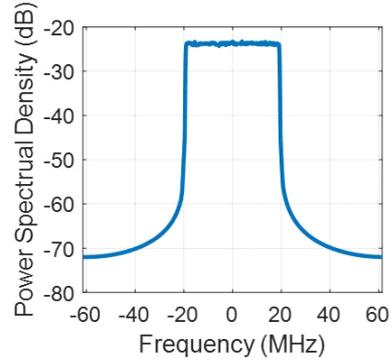


Fig. 6 Spectrum of transmitted OFDM signal

4.2. 다중 출력 CNN 학습

제안하는 다중 출력 CNN 추정기는 2차원 주기도 신호(학습 데이터)와 거리 및 속도 레이블(label)을 입력받아 학습을 진행한다. CNN의 입력 신호는 2가지로 클러터의 유무에 따라 나뉜다. 2가지 학습 데이터의 개수는 각각 110,000개이며 학습에 사용된 하이퍼파라미터 정보는 다음과 같다. 미니 배치 크기는 100, 최대 에폭은 클러터가 없을 때 200, 있을 때는 800이다. 매 에폭마다 1,100번 파라미터가 갱신된다. 총 파라미터 갱신 횟수는 주기도가 없을 때는 220,000번, 있을 때는 880,000번이다. 최적화 기법은 Adam을 사용하며 학습률(Learning Rate)은 0.001이다. 총 학습 가능한 파라미터 개수는 23,536,516개이다. 손실함수(Loss Function)는 평균 제곱 오차(Mean Squared Error, MSE)를 사용하며 아래의 식과 같이 나타낼 수 있다.

$$Loss = \frac{1}{N_{train}} \sum_{i=1}^{N_{train}} (\hat{d}_i - d_i)^2 + (\hat{v}_i - v_i)^2 \quad (17)$$

N_{train} 는 학습 데이터 개수, \hat{d}_i 는 i 번째 학습 데이터에서 표적에 대한 CNN의 거리 예측값, \hat{v}_i 는 속도 예측값을 나타낸다. d_i 는 거리 레이블(정답)이며 v_i 는 속도 레이블을 나타낸다. 즉, 손실은 표적에 대한 거리 및 속도의 예측값과 실제값의 차이에 제곱을 취해 이 둘을 더한 값을 사용한다.

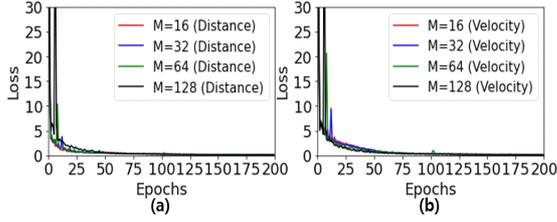


Fig. 7 Learning curves for clutter absence periodogram: (a) distance MSE, (b) velocity MSE

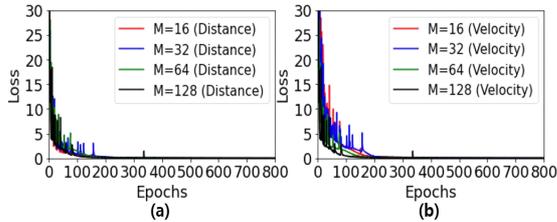


Fig. 8 Learning curves for clutter presence periodogram: (a) distance MSE, (b) velocity MSE

그림 7은 클러터가 없을 때($H_c = 0$), 그림 8은 클러터가 있을 때($H_c = 20$)의 주기도에 대한 학습 곡선을 보인다. 그림 7과 8에서 (a)는 거리에 대한 손실, (b)는 속도에 대한 손실값을 나타낸다. 클러터 유무에 상관없이 학습 단계 초기에는 불안정하지만, 학습이 진행되면서 점차 안정화되어 결국 손실은 0에 가깝게 수렴한다.

4.3. 성능 비교

기존 CFAR 기법과 제안하는 CNN 기법의 성능 평가를 위해 테스트 데이터를 새로 생성한다. 각각의 테스트 데이터는 학습 데이터와 마찬가지로 식별 가능한 거리와 속도 내에서 랜덤하게 생성한다. 테스트 데이터는 학습 데이터와 달리 표적 신호의 SNR은 $-20 \sim 22$ dB 범위에서 3 dB 간격으로 생성하며 각각의 SNR 마다 10,000 개를 생성한다. 테스트 시 성능지표는 평균 절대 오차 (Mean Absolute Error, MAE)를 사용한다. 거리 및 속도에 대한 평균 절대 오차는 다음과 같이 주어진다.

$$MAE_d = \frac{1}{N_{test}} \sum_{n=1}^{N_{test}} |\hat{d}_i - d_i| \quad (18)$$

$$MAE_v = \frac{1}{N_{test}} \sum_{n=1}^{N_{test}} |\hat{v}_i - v_i| \quad (19)$$

(18)은 거리에 대한 MAE, (19)는 속도에 대한 MAE

를 나타낸다. 두 식에서 N_{test} 는 테스트 데이터의 개수, \hat{d}_i 은 i 번째 테스트 데이터에 대한 다중 출력 CNN의 거리 예측값, \hat{v}_i 은 속도 예측값이다. d_i 와 v_i 은 각각 표적의 실제 거리와 속도 레이블을 나타낸다. MAE는 표적에 대한 거리 및 속도 예측값과 실제값의 차이에 절대값을 취한 후 평균을 낸 값이다.

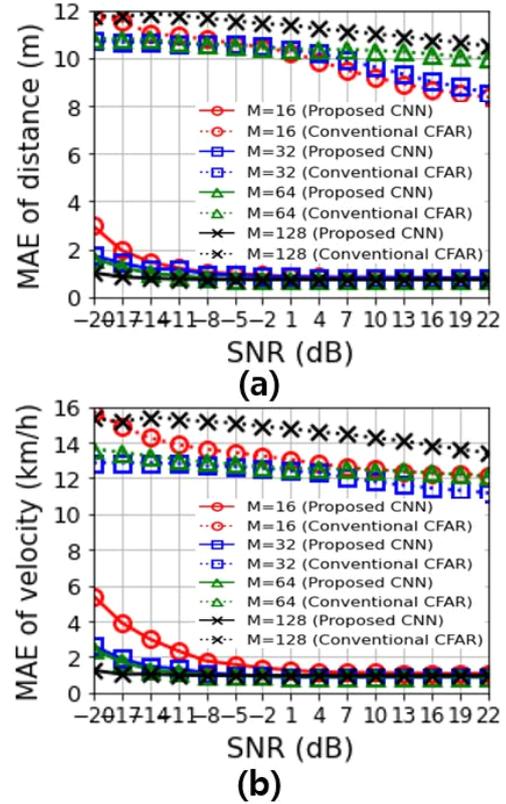


Fig. 9 MAE performances for conventional and proposed method for clutter presence case: (a) MAE of distance, (b) MAE of velocity

그림 9는 클러터가 있는 환경에서 기존 및 제안 추정 기법의 MAE 성능을 보인다. 그림 9 (a)는 거리에 대한 MAE, (b)는 속도에 대한 MAE 성능이다. 심볼 개수에 따라 선의 색상 및 마커의 종류로 구분한다. 빨강(\circ), 파랑(\square), 초록(\triangle), 검정(\times)은 각각 OFDM 심볼 개수 16, 32, 64, 128개를 나타낸다. 선의 종류에 따라 추정 기법을 분류하며 점선은 기존 CFAR 기법, 실선은 제안하는 다중 출력 CNN을 나타낸다. 두 기법 모두 SNR이 증

가하면서 오차도 줄어든다. CFAR의 경우 모든 심볼을 통틀어 거리 MAE 8.2 m, 속도 MAE 10.6 km/h가 가장 좋은 경우에 해당한다. 반면에, 제안하는 다중 출력 CNN은 SNR 22 dB 및 심볼 개수 128일 때, 거리 및 속도 오차는 각각 0.72 m, 0.95 km/h로 기존기법보다 훨씬 우수하다.

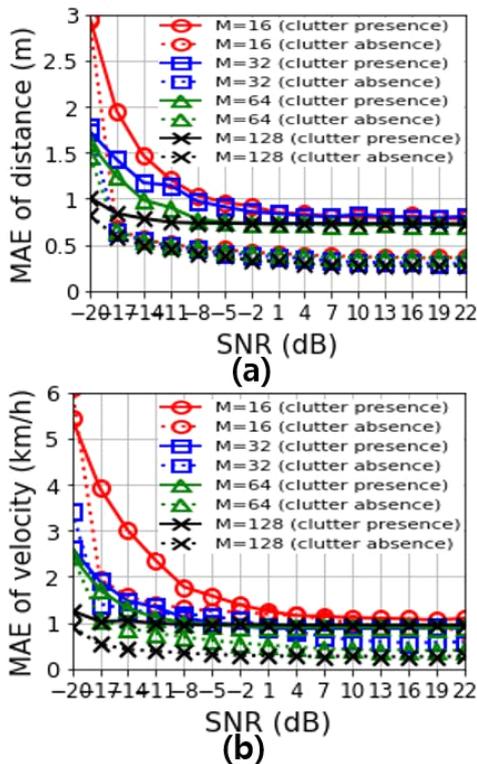


Fig. 10 MAE performances for proposed CNN method for clutter absence and presence cases: (a) MAE of distance, (b) MAE of velocity

그림 10은 제안 하는 다중 출력 CNN의 클러터 유무에 따른 MAE 성능 비교를 보인다. 그림 10 (a)는 거리에 대한 MAE, (b)는 속도에 대한 MAE 성능이다. 그림 9와 같이 선의 색상 및 마커의 종류에 따라 OFDM 심볼 개수를 구분한다. 또한 선의 종류에 따라 클러터의 유무를 결정하는데 실선은 클러터가 있는 환경, 점선은 클러터가 없는 환경을 나타낸다. 그림 10 (a)와 (b) 둘 다, SNR이 증가할수록 오차가 줄어들고 심볼 개수가 증가하면서 낮은 SNR 구간에서 성능이 향상된다. 같은 심볼 개수에서 비교했을 때, 클러터가 없는 환경에서의 거리 및

속도 추정 성능이 클러터가 있는 환경보다 우수하다. 또한, SNR 22 dB 및 심볼 개수 128일 때 가장 낮은 오차를 갖는다. 이때 클러터가 없는 경우, 거리 및 속도 MAE는 각각 0.27 m, 0.27 km/h의 정확도를 보인다.

시뮬레이션을 통해 클러터 성분이 거리 및 속도 추정에 있어 오차를 유발하는 요인으로 작용하는 것을 알 수 있으며 심볼 개수를 적절히 늘리면 낮은 SNR 구간에서 거리와 속도 추정 오류를 줄일 수 있다는 것을 알 수 있다. 또한 높은 SNR 구간에서는 전송 심볼개수와 상관없이 오차 성능이 비슷해 적은 심볼 개수를 사용하는 것이 효율적이다.

V. 결론

본 논문에서는 OFDM 레이다 시스템을 위한 새로운 표적 추정 기법에 대해 제안하였다. 제안한 추정기는 표적으로부터 반사된 OFDM 신호로부터 2차원 주기도를 얻어 다중 출력 CNN에 입력해 거리와 속도를 동시에 추정한다. 시뮬레이션을 통해 제안 기법을 기존 CFAR 기법과 비교, 검증하였다. 시뮬레이션 결과에 따르면, SNR -20~22 dB에서 제안하는 추정 기법이 기존 기법보다 추정 성능이 우수하다. 제안한 기술을 5G 혹은 6G 이동 통신에 적용한다면 기지국과 이동국 사이에서 통신과 동시에 레이다 신호처리를 수행함으로써 실시간 빔포밍과 빔 추적을 구현할 수 있을 것으로 기대된다. 뿐만 아니라 밀리미터파를 사용하는 군 통신시스템에도 활용될 수 있을 것으로 기대된다.

ACKNOWLEDGEMENT

This work has been supported by the UAV Intelligence Systems Research Laboratory program of Defense Acquisition Program Administration and Agency for Defense Development. (UD200027ED)

REFERENCES

- [1] W. Na, S. Jang, Y. Lee, L. Park, N. Dao, and S. Cho, "Frequency resource allocation and interference management

in mobile edge computing for an Internet of Things system,” *IEEE Internet of Things Journal*, vol. 6, no. 3, pp. 4910-4920, Jun. 2019.

[2] Y. Kawamoto, H. Takagi, H. Nishiyama, and N. Kato, “Efficient resource allocation utilizing Q-Learning in multiple UA communications,” in *IEEE Transactions on Network Science and Engineering*, vol. 6, no. 3, pp. 293-302, Mar. 2019.

[3] K. Satyanarayana, M. El-Hajjar, P. H. Kuo, and L. Hanzo, “Hybrid beamforming design for full-duplex millimeter wave communication,” *IEEE Transactions on Vehicular Technology*, vol. 68, no. 2, pp. 1394-1404, Jun. 2017.

[4] T. Wild, V. Braun, and H. Viswanathan, “Joint design of communication and sensing for beyond 5G and 6G systems,” *IEEE Access*, vol. 9, pp. 30845-30857, Feb. 2021.

[5] M. Braun, M. Muller, M. Fuhr, and F. K. Jondral, “A USRP-based testbed for OFDM-based radar and communication systems,” in *Proceedings of 22nd Virginia Tech. Symposium on Wireless Communications*, Blacksburg: VA, Jun. 2012.

[6] C. B. Barneto, T. Riihonen, M. Turunen, L. Anttila, M. Fleischer, K. Stadius, and M. Valkama, “Full-duplex OFDM radar with LTE and 5G NR waveforms: Challenges, solutions, and measurements,” *IEEE Transactions on Microwave Theory and Techniques*, vol. 67, no. 10, pp. 4042-4054, Oct. 2019.

[7] A. Evers and J. A. Jackson, “Analysis of an LTE waveform for radar applications,” in *2014 IEEE Radar Conference*, Cincinnati: OH, pp. 0200-0205, May. 2014.

[8] B. Dekker, S. Jacobs, A. S. Kossen, M. C. Kruithof, A. G. Huizing, and M. Geurts, “Gesture recognition with a low power FMCW radar and a deep convolutional neural network,” in *2017 European Radar Conference (EURAD)*, Nuremberg: DE, pp. 163-166, Oct. 2017.

[9] L. Zhang, W. You, Q. Wu, S. Qi, and Y. Ji, “Deep learning-based automatic clutter/interference detection for HFSWR,” *Remote Sensing*, vol. 10, no. 10, pp. 1517, Sep. 2018.

[10] B. Major, D. Fontijne, A. Ansari, R. T. Sukhvasi, P. Gowaikar, M. Hamilton, S. Lee, S. Grechnik, and S. Subramanian, “Vehicle detection with automotive radar using deep learning on range-azimuth-doppler tensors,” in *Proceedings of the IEEE/CVF International Conference on Computer Vision Workshops*, Seoul: KR, pp. 924-932, Oct. 2019.

[11] S. Mercier, S. Bidon, D. Roque, and C. Enderli, “Comparison of correlation-based OFDM radar receivers,” *IEEE Transactions on Aerospace and Electronic Systems*, vol. 56, no. 6, pp. 4796-4813, Dec. 2020.

[12] J. Joung, S. Jung, S. Chung, and E. R. Jeong, “CNN based Tx - Rx distance estimation for UWB system localisation,” *Electronics Letters*, vol. 55, no. 17, pp. 938-940, Aug. 2019.

[13] G. M. Nam, T. Y. Jung, S. H. Jung, and E. R. Jeong, “Distance estimation using convolutional neural network in UWB systems,” *Institute of Information and Communication Engineering*, vol. 23, no. 10, pp. 640-651, Oct. 2019.

[14] K. He, X. Zhang, S. Ren, and J. Sun, “Deep residual learning for image recognition,” in *Proceedings of the IEEE conference on computer vision and pattern recognition*, Las Vegas: LV, pp. 770-778, Jun. 2016.



최재웅(Jae-Woong Choi)

한밭대학교 정보통신공학과 학사 (2020)
 한밭대학교 모바일융합공학과 석사과정 (현재)
 ※관심분야: 디지털 신호처리, 딥러닝



정의림(Eui-Rim Jeong)

한국과학기술원 전기 및 전자 공학과 학사 (1995)
 한국과학기술원 전기 및 전자 공학과 석사 (1997)
 한국과학기술원 전자 전산학과 박사 (2001)
 한밭대학교 정보통신공학과 교수 (현재)
 ※관심분야: 모델설계, 통신신호처리, 딥러닝