

Received: 2024/08/16  
Revised: 2024/08/26  
Accepted: 2024/09/25  
Published: 2024/09/30

**\*Corresponding Author:**

**Sunghoon Jung**

Dept. of Mechanical System Engineering,  
Republic of Korea Naval Academy  
1 Jungwon-ro, Jinhae-gu, Changwon-si,  
Gyung-sangnam-do, 51704, Republic of Korea  
Tel: +82-55-907-5320  
E-mail: hun401@navy.ac.kr

# 시를 이용한 레이더 SNR 향상 기법

## An AI-based RADAR SNR Enhancement Method

최혁준<sup>1</sup>, 윤의석<sup>1</sup>, 정성훈<sup>2\*</sup>

<sup>1</sup>해군사관학교 기계시스템공학과 사관생도

<sup>2</sup>해군 소령/해군사관학교 기계시스템공학과 조교수

Hyeokjun Choi<sup>1</sup>, Ui-sok Yun<sup>1</sup>, Sunghoon Jung<sup>2\*</sup>

<sup>1</sup>Midshipmen, Dept. of Mechanical System Engineering, Republic of Korea Naval Academy

<sup>2</sup>LCDR, ROK Navy/Assistant professor, Dept. of Mechanical System Engineering, Republic of Korea Naval Academy

### Abstract

본 논문에서는 합성곱 신경망을 이용하여 레이더의 신호 대 잡음비를 향상할 수 있는 기법을 제안한다. 기존의 pulse integration은 많은 수의 레이더 반사 신호가 필요하므로 그에 따라 레이더 작전 성능이 저하된다. 제안기법은 신경망 학습을 통해 표적 신호와 잡음의 특성을 파악하여 효과적으로 잡음을 제거할 수 있다. 실험을 통해 적은 수의 레이더 반사 신호만으로도 제안기법이 잡음을 효과적으로 제거하고 표적을 정확히 탐지할 수 있음을 확인하였다.

In this paper, we propose a method to improve the signal-to-noise ratio of RADAR using a convolutional neural network. Conventional pulse integration requires a large number of RADAR return signals, thereby deteriorating RADAR operational performance. The proposed method can effectively remove noise by identifying the characteristics of the target signal and noise through neural network learning. Through experiments, the proposed method was confirmed to be superior in effectively removing noise and accurately detecting targets with only a small number of RADAR return signals.

### Keywords

레이더(RADAR), 펄스 적분(Pulse Integration), 오탐(False Alarm), 딥 러닝(Deep Learning), 합성곱 신경망(Convolutional Neural Network)

## 1. 서론

레이더(radio detection and ranging, RADAR)는 민간, 육·해·공을 가리지 않고 사용되는 기술로, 적의 탐지 및 식별, 항해 안전, 전투 수행, 정보 수집 및 전파, 감시 및 정찰, 통신 보조 등 다양한 측면에서 중요한 역할을 한다. 특히 함정 운용에 필수적인 기술로, 레이더를 통해 해군은 해상 작전 능력을 극대화하고 효과적으로 적의 위협에 대응할 수 있다. 또한 주변 표적을 식별·확인하고 기상을 관측하여 지휘관이 해상 상황을 파악하고, 수집한 정보를 토대로 함정의 기동을 결정하도록 하는 중요한 역할을 한다.

한편, 표적에 반사되어 돌아오는 레이더 수신 신호의 크기는 매우 작으므로 주변 잡음이 강할 경우 표적의 탐지가 어렵다. 안전한 항해와 군의 작전 수행을 위해서는 신호 대 잡음비(signal noise ratio, SNR)를 높여 표적의 탐지 확률을 향상시켜야 한다. 기존 레이더는 SNR을 높이기 위해 여러 개의 펄스를 송신하여 수신한 여러 반사 신호를 평균하여 표적 반사 신호의 크기는 높이고 잡음의 크기는 줄이는 pulse integration 기법을 사용한다. 하지만 이 방식은 평균에 이용되는 레이더 반사 신호의 수(hits per scan)에 비례하여 SNR이 높아지므로 이를 위해 레이더는 넓은 빔 폭, 느린 회전수, 높은 펄스반복주파수를 가져야 한다. 그러나 이는 방위해상도, 표적경신율, 최대 비모호 탐지거리 측면에서 손해를 초래해 작전 성능이 저하된다.

본 논문에서는 이러한 문제점을 해결하기 위해 AI를 이용한 레

이더 SNR 향상기법을 제안한다. 제안기법은 표적과 잡음이 혼재된 레이더 반사 신호를 이미지화한 후 미리 학습된 신경망을 통해 표적 신호만 남기고 나머지 잡음을 제거한다. 제안기법의 구현을 위해 표적 반사 신호와 잡음이 무작위로 존재하는 데이터 세트를 생성하고 이를 이용해 합성곱 신경망(convolution neural network, CNN)이 표적은 탐지하고 잡음은 제거하도록 신경망을 학습시켰다. 제안기법은 기존기법과 비교해 훨씬 적은 수의 레이더 반사 신호만으로 표적과 잡음을 정확히 구별해낼 수 있으므로 작전 성능을 유지한 채 레이더의 신호 대 잡음비를 높일 수 있는 장점이 있다.

## 2. 기존기법

레이더의 송·수신 신호는 크기와 위상정보를 동시에 가지고 있는 복소수의 형태로 나타낼 수 있다. 레이더의 신호 대 잡음비를 향상시킬 수 있는 pulse integration은 위상정보의 사용 여부에 따라 coherent, non-coherent 방식으로 나눌 수 있다. 전자는 위상정보를 포함해서 신호 대 잡음비를 향상하는 방법으로, 평균에 사용되는 반사 신호의 수에 비례하여 SNR이 증가하지만 위상정보의 활용을 위해 고속 푸리에 변환(fast Fourier transform, FFT) 분석 등이 추가로 필요하므로 구현이 까다롭다. 반면 후자는 전자에 비해 SNR이 약간 낮으나 위상정보를 이용하지 않으므로 구현이 간편하다는 장점이 있다[1].

두 가지 방식 모두 동일하게 Fig. 1과 같이 여러 개의 레이더 반사 신호들을 합하여 평균하게 되면 표적의 반사 신호는 원래의 크기를 유지하지만 잡음은 통계적으로 랜덤 분포를 가지므로, 평균에 사용하는 반사 신호의 수가 많을수록 잡음 값의 분포는 분산이

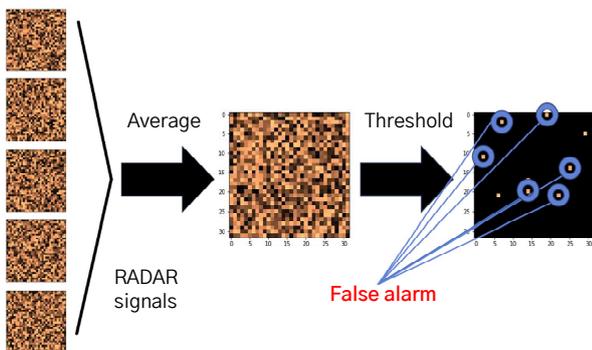
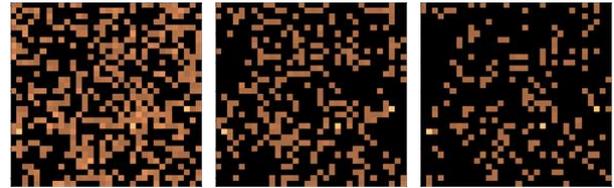


Fig. 1. The pulse integration process

줄어 들고 평균값에 수렴하게 되므로 SNR을 높일 수 있다. Fig. 2는 반사 신호의 개수에 따른 pulse integration의 성능을 나타낸 것으로, 반사 신호의 수가 많을수록 잡음 제거 성능이 높아지지만 잡음의 분산이 클 경우 많은 수의 반사 신호를 사용하더라도 효과적인 잡음 제거가 어렵다. 레이더 반사 신호 수는 식 (1)과 같이 나타낼 수 있다.



(a) 10 signals (b) 50 signals (c) 100 signals

Fig. 2. Comparison of noise reduction performance in pulse integration based on the number of RADAR received signals

$$n = \frac{\theta_b}{\theta_s} \text{PRF} \quad (1)$$

여기서,  $n$ ,  $\theta_b$ ,  $\theta_s$ , PRF는 각각 레이더 반사 신호 수, 빔 폭, 레이더 회전수, 펄스반복주파수를 의미한다.

즉, 레이더의 빔 폭이 넓고 회전속도가 느리며 펄스반복주파수가 높을수록 레이더 반사 신호의 수가 증가하므로 pulse integration을 통해 SNR을 높일 수 있다. 그러나 이에 따라 방위분해능과 표적경신율이 저하되고 최대 비모호거리가 짧아지는 결과를 가져오므로 작전 성능이 저하된다. 따라서 SNR과 작전 성능 간의 trade-off를 고려해 요구되는 작전 성능을 유지할 수 있는 제한된 수의 레이더 반사 신호를 평균한 다음, 잡음의 예상 평균값을 특정 임계값으로 설정하여 그 크기 이상의 신호를 표적 신호로 간주하는 방식을 사용한다.

이러한 방식은 두 가지 문제가 발생한다. 먼저, 잡음이 0과 190 사이의 무작위 값으로 존재하는 상황을 가정한다면, 평균값이 95이므로 이 값 이하의 신호들은 잡음으로 간주하여 제거할 수 있다. 하지만 평균에 사용되는 레이더 반사 신호의 수가 적을수록 잡음의 값이 95보다 커질 수 있어, 잡음을 표적으로 인식하는 false alarm이 발생할 확률이 높아진다[2]. 또한 설정한 임계값의 크기에 따라 성능이 좌우된다. 만약, 설정한 임계값이 지나치게 크면 레이

더반사면적(RADAR cross section, RCS)이 작은 표적의 탐지가 어렵고 또한 너무 작게 설정하면 false alarm 문제가 발생한다.

잡음을 표적으로 탐지하는 false alarm은 레이더 표적 획득 성능의 신뢰도를 떨어뜨리고 다수의 표적에 대응해야 하는 상황에서 운용 요원에게 무기체계의 표적 할당에 대한 부담을 안겨주게 된다. 무기체계의 발전에 따라 표적의 RCS는 계속해서 낮아지므로 탐지를 위해선 높은 레이더 SNR이 요구되지만, RCS가 작은 표적을 먼 거리에서 탐지하기 위해선 레이더가 좁은 빔 폭, 빠른 표적 갱신을, 낮은 펄스반복주파수를 가져야 하므로 기존의 pulse integration으로는 SNR 향상과 작전 성능을 동시에 만족시키는 것이 갈수록 어려워진다.

### 3. 제안기법

본 논문에서 제안하는 기법은 CNN을 이용한 기법으로, 표적 신호와 잡음이 혼재된 레이더 반사 신호를 미리 학습된 신경망에 입력하여 잡음을 제거하고 표적만 존재하는 이미지를 생성한다. 제안기법은 레이더 전시기에 표시되기 직전의 신호를 이용하므로 기존의 non-coherent pulse integration과 방식이 동일하다. 따라서 구현이 간편하다는 non-coherent 방식의 장점을 가지면서도 적은 수의 반사 신호만으로 잡음을 효과적으로 제거할 수 있으므로 해당 방식의 단점을 해결할 수 있다.

#### 3.1 신경망 학습을 위한 데이터셋 구축

제안기법은 이미지 기반 신경망을 이용하여 레이더 신호의 잡음을 제거하므로 이를 학습시킬 수 있는 데이터가 필요하다. 그러나 실제 레이더 데이터의 획득이 제한되어 다음과 같이 가상의 레이더 수신 신호 데이터를 생성하였다. 먼저 32×32 크기의 이미지 내에 3개의 표적을 무작위 위치(픽셀)에 생성하였다. 이때 표적의 반사 신호 값은 180~190 사이의 균등 분포를 갖는 정수로 설정하였다. 이 데이터는 신경망 학습의 정답 데이터로 사용한다. 여기에 표적의 위치를 제외한 나머지 위치에는 0~190 사이의 균등 분포를 갖는 정수를 추가해 잡음을 표현하였다. 같은 방식으로 표적의 위치는 고정된 채 표적의

신호 값과 잡음 값은 처음 생성한 이미지와 다른 4개의 이미지를 추가로 생성하여 총 5개의 레이더 반사 신호 이미지를 하나의 세트로 구성한다. 이는 실제 레이더에서 pulse integration을 위해 사용되는 5개의 레이더 반사 신호와 같으며, 신경망 학습의 입력 데이터로 사용한다. 가상데이터는 표적 반사 신호의 평균값은 185, 잡음의 평균값은 95가 되며 잡음의 평균값을 알고 있다는 가정을 하면 기존 pulse integration에서는 레이더 반사 신호를 평균하여 95 이하의 값은 잡음으로 판단하여 제거한다. 같은 방식으로 세 가지 표적의 위치를 서로 다르게 설정한 총 4,000세트의 이미지를 생성하였다.

이렇게 준비한 학습데이터는 제안기법의 신경망이 표적 신호와 잡음이 혼재된 이미지(입력 데이터)에서 잡음을 제거하고 표적만 선별한 데이터(정답 데이터)를 출력하도록 신경망의 학습에 사용된다. 추가로 신경망의 학습 속도를 빠르게 하고 제안기법의 성능을 향상시키기 위해 데이터값의 범위를 [0, 1] 범위로 제한하는 식 (2)과 같은 Min-Max 정규화를 적용하였다.

$$X_0 = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (2)$$

여기서,  $X_0$ ,  $X$ ,  $X_{\min}$ ,  $X_{\max}$ 는 정규화된 값, 정규화 대상값, 전체 데이터의 최솟값과 최댓값을 의미한다.

#### 3.2 제안기법의 신경망 구조

제안기법은 이미지 인식에 특화된 CNN[3]을 사용한다. CNN은 특정 크기의 커널을 통해 입력 이미지 전체가 아닌 특정 구역별로 이미지를 인식하기 때문에 인접 픽셀 간의 상관관계를 파악하기 쉽고 동시에 입력 이미지의 크기가 다르더라도 이미 학습된 신경망을 적용할 수 있는 장점이 있다. 따라서, 제안기법의 학습은 32×32 크기의 이미지로 이뤄지더라도 이미 학습된 신경망은 다른 크기의 레이더 신호 이미지도 처리할 수 있다. 제안기법의 신경망 구조는 Fig. 3와 같으며  $l$ 번째 층의 출력은 식 (3)으로 표현할 수 있다.

$$X_l = f_l(W_l * X_{l-1} + B_l), l = (1, \dots, L) \quad (3)$$

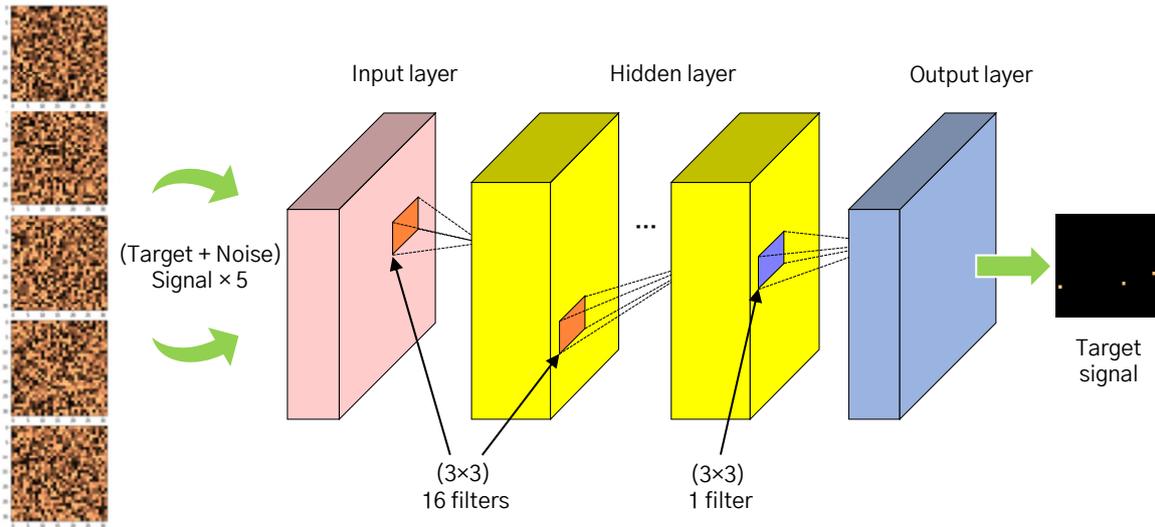


Fig. 3. The neural network architecture of the proposed method

여기서,  $f_l$ ,  $W_l$ ,  $x_{l-1}$ ,  $b_l$ 은 각각  $l$ 번째 층의 활성화 함수, 커널 가중치, 이전 층의 출력, 바이어스를 의미하며 \*은 커널의 이동과 합성곱 연산을 포함한다.

제안기법의 신경망은 총 5장의 이미지가 입력되므로 신경망 입력층은  $32 \times 32$  크기의 5채널 이미지를 입력받도록 설정하였다. 입력층과 은닉층에서 이미지의 특성을 추출하는 커널은 많은 CNN에서 사용하는  $3 \times 3$  크기로 설정하고 층마다 16개를 사용하였다. 마지막 출력층은 레이더 수신 신호와 같은 크기의 이미지를 생성해야 하므로  $3 \times 3$  크기의 커널 1개를 사용하였다. 활성화 함수는 출력층을 제외한 모든 층에 기울기 소실 문제를 방지할 수 있는 ReLU (rectified linear unit)를 적용하였다. 이를 종합해 보면, 제안기법의 신경망은 표적과 잡음의 신호가 혼재된  $32 \times 32$  크기의 5채널 이미지를 입력받아 입력층, 출력층을 거친 다음 최종 출력층에서 잡음이 제거되고 표적만 남은  $32 \times 32$  크기의 1채널 이미지를 생성한다.

#### 4. 실험결과

4,000세트의 이미지 중 3,000세트는 제안기법의 신경망 학습에 사용하였고, 나머지 1,000세트는 학습된 신경망의 성능 측정에만 사용하여 신경망이 지나치게 학습데이터에 편향되는 과적합 현상을 방지하였다. Fig. 4는 기존기법과 제안기법의 잡음 제거 성능을 비교한 결과이다.

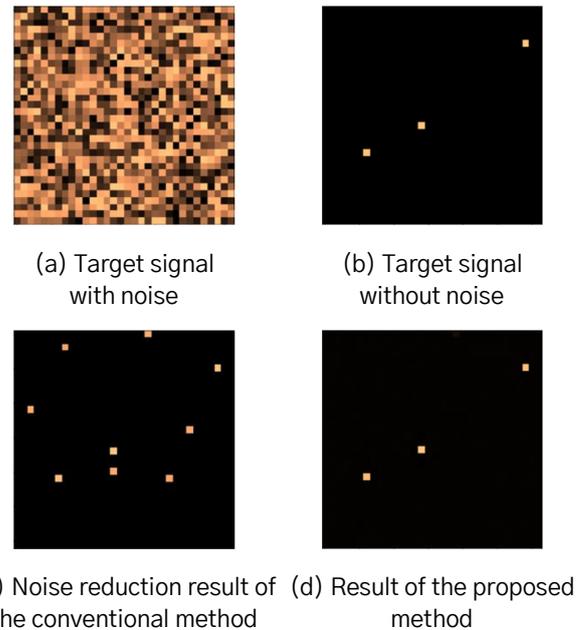


Fig. 4. Comparison of noise reduction performance

여기서 기존기법은 제안기법에 사용된 5개의 레이더 반사 신호 수보다 훨씬 많은 100개의 반사 신호를 사용해 pulse integration을 수행한 결과다. 결과에서 알 수 있듯 제안기법은 기존기법에 비해 적은 수의 레이더 반사 신호를 사용했음에도 불구하고 잡음을 효과적으로 제거하여 표적을 정확히 탐지함을 알 수 있다. 또한, 기존기법은 잡음의 평균값을 알고 있는 상태에서 pulse integration을 수행한 결과이지만 제안기법은 잡음 값의 분포에 대한 사전 정보 없이도 표적 신호와 잡음의 특성을 데이터 학습

으로 파악한 신경망을 이용해 잡음을 효과적으로 제거한 결과이다.

Table 1-2는 1,000개 세트의 데이터에 대해 각 기법의 표적 탐지 결과를 혼동행렬(confusion matrix)로 정리하여 비교한 것이다. 1,000개의 데이터세트 내 총 3,000개의 실제 표적이 존재하는 상황에서 기존기법은 4,276개, 제안기법은 3,087개를 표적으로 탐지하였다. 그중 실제 표적은 각각 2,995개, 2,994개로 식 (4)의 정밀도(precision)와 재현도(recall) 측면에서는 두 기법 모두 0.99 이상의 우수한 성능을 나타냈다.

**Table 1.** Confusion matrix of the conventional method

Predicted value	Actual value	
	Target(positive)	Noise(negative)
Target (positive)	2,995 (true positive)	<b>1,281 (false positive)</b>
Noise (negative)	5 (false negative)	1,019,719 (true negative)

**Table 2.** Confusion matrix of the proposed method

Predicted value	Actual value	
	Target	Noise
Target	2,994	<b>93</b>
Noise	6	1,020,907

$$\text{Precision} = \frac{\text{TruePositive}}{\text{TruePositive} + \text{FalsePositive}} \quad (4a)$$

$$\text{Recall} = \frac{\text{TruePositive}}{\text{TruePositive} + \text{FalseNegative}} \quad (4b)$$

$$\text{F1-score} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (4c)$$

그러나, 잡음의 위치는 표적의 수에 비해 상대적으로 매우 많은 총 1,021,000개로 지나치게 데이터가 불균형한 상태이므로 정밀도와 재현도만으로는 정확한 평가가 어렵다. 따라서 그러나 표적이 아닌 잡음을 표적으로 탐지한 false alarm(false positive) 발생 결과와 정확도와 재현도의 조화평균인 F1 score를

Table 3에 나타냈다. False alarm은 각각 1,221건, 93건이 발생하였으며 탐지한 표적 수 대비 false alarm의 발생 건수인 오탐 확률은 제안기법에서 약 3%로 기존기법에 비해 적은 수의 false alarm이 발생하였다. 또한 F1 score는 제안기법이 0.9837을 기록하였다. 종합해 보면 제안기법은 적은 수의 레이더 반사 신호만으로 표적은 정확히 탐지하고 잡음으로 발생하는 false alarm은 현저하게 줄여 다수의 표적에 대응해야 하는 상황에서 운용자로 하여금 무기체계의 표적 할당에 대한 부담을 줄이고 건전한 판단을 도울 수 있다.

**Table 3.** Comparison of false alarm and F1 score

Method	Predicted positive	False positive	False discovery rate	F1 score
The existing method	4,276	<b>1,281</b>	<b>29.93 %</b>	<b>0.8233</b>
The proposed method	3,087	<b>93</b>	<b>3.01 %</b>	<b>0.9837</b>

## 5. 결론

레이더의 pulse integration은 레이더 수신 신호의 잡음을 제거하여 SNR을 높이는 기법이다. 그러나 이를 위해 다수의 레이더 반사 신호가 필요하며 이는 레이더 작전 성능을 저하하는 요인이 된다. 본 논문에서는 CNN을 이용하여 적은 수의 레이더 수신 신호로 잡음을 제거하여 SNR을 높이는 방법을 제안하였다. 제안기법을 구현하기 위하여 실제 환경을 고려한 학습데이터를 생성하여 신경망을 학습하였다. 실험을 통해 제안기법은 기존기법에 비해 적은 수의 레이더 반사 신호로도 충분한 잡음 제거가 가능한 것을 확인하였다. 제안기법을 활용하면 레이더의 작전 성능을 충족시키면서도 레이더 신호의 잡음을 효과적으로 제거하고 표적을 정확히 탐지하여 운용자로 하여금 다수 표적에 대해 정확한 판단을 도울 것으로 기대된다.

## 참고문헌

- [1] 가관우, 함성민, 이관형, “레이더 시스템에서 목표물 탐지 거리

추정을 위한 코히런트 집적과 비 코히런트 집적의 SNR 성능 비교,”  
한국정보전자통신기술학회 논문지, 7(2), 86–91, 2014.

[2] J. Marcum, “A Statistical Theory of Target Detection by Pulsed Radar,” in IRE Transactions on Information Theory, Vol. 6, No. 2, pp. 59–267, April 1960.

[3] Y. LeCun et al., “Backpropagation Applied to Handwritten Zip Code Recognition,” Neural Computation, Vol. 1, No. 4, pp. 541–551, Dec. 1989.