

CNN을 이용한 합성빔 성능 모의

박철순, 김선교, 장재원, 조성진, 나선필, 조세민*, 강희석*

국방과학연구소, *한화시스템

helione@nate.com

Simulation of beamforming performance using CNN

Cheolsun Park

Agency for Defense Development

요약

본 논문은 고감도로 원거리 신호의 탐지를 위한 분산형 디지털 적응형 범합성 처리기술에 관한 것이다. 대표적인 적응형 범합성 기법인 LCMV는 입력 데이터 공분산 행렬과 제약 행렬의 역행렬 계산이 포함된 높은 계산 부담을 유발한다. 또한 LCMV의 특징으로 적은 스냅샷과 낮은 SNR일 때 열악하다고 알려져 있다. 이러한 LCMV의 단점들을 극복하기 위해 다양한 기법들이 개발되고 있고, 역행렬 계산이 필요없는 신경망(NN)과 심층 신경망(DNN)들도 응답속도 개선을 위한 연구가 진행되고 있다. 본 논문은 CNN 모델을 수신 범합성에 적용하여 합성빔의 지향오차, 부엽레벨, 샘플수 변화에 따른 성능을 분석하였다.

I. 서론

합성빔 생성기술은 레이다, 소나 및 통신 등 다양한 응용 분야에 활발히 연구되고 있다. LCMV(Linearly Constrained Minimum Variance) 기법은 다중 신호원의 경우에서 신호 품질 향상을 위한 일반적이고 강력한 합성빔 생성 기법으로 알려져 있다. LCMV는 MVDR(Minimum Variance Distortion-less Response) 또는 Capon 빔 합성기의 일반화된 형태로서 라그랑지 승수를 직접 사용하여 유도할 수 있고, SOI(Signals Of Interest) 방향에서 일정한 응답을 유지하고 나머지 방향에 대해 배열 출력 파워를 최소화한다.

LCMV 빔 합성기는 입력 데이터 공분산 행렬 \mathbf{R}_{xx} 와 $\mathbf{C}^H \mathbf{C}$ (\mathbf{C} 는 제약 행렬임)의 역행렬 계산을 요구하여 높은 계산 부담을 유발한다. 추가적으로 LCMV의 견실성은 적은 스냅샷과 낮은 SNR일 때 열악하다고 알려져 있다[1]. 이러한 LCMV의 단점들을 극복하기 위해 다양한 기법들이 개발되고 있고, 또한 역행렬 계산이 필요없는 신경망(NN)과 심층 신경망(DNN)들이 응답속도 개선을 위한 연구가 진행되고 있다. 본 논문은 CNN 모델을 수신 범합성에 적용하여 합성빔의 지향오차, 부엽레벨, 샘플수 변화에 따른 성능을 확인하였다.

II. CNN 기반 합성빔 생성 모델

임의의 형태를 가진 M 개 센서로 구성된 배열에서 방위각(AoA) $\theta_1, \theta_2, \dots, \theta_D$ 로 입사하는 D 개(신호 및 간섭 포함) 포인트 신호원을 가정한다면, 배열 빔 합성기의 출력 $y(k)$ 는 다음과 같이 표현할 수 있다.

$$y(k) = \mathbf{w}^H \mathbf{x}(k) \quad (1)$$

최적 가중치 \mathbf{w}_{opt} 를 찾는 문제는 다음과 같이 제약조건형 LMS 문제로 정리할 수 있다[1, 2].

$$\begin{aligned} \text{minimize} \quad & J(\mathbf{w}) = \frac{1}{2} \mathbf{w}^H \mathbf{R}_{xx} \mathbf{w} \\ \text{subject} \quad & \mathbf{C}^H \mathbf{w} = \mathbf{f} \end{aligned} \quad (2)$$

여기서, \mathbf{C} 는 제약 행렬이고, \mathbf{f} 는 제약 벡터이다. 예를 들면, L 개 방위각 θ_i ($i = 1, 2, \dots, L$)에 단위 이득을 생성하고, 다른 방위각들에 대해 널링(nullforming)을 형성할 필요가 있다면, 제약 행렬과 제약 벡터는 다음과 같이 표현할 수 있다.

$$\mathbf{C} = [(\theta_1), \dots, \mathbf{a}(\theta_L), \dots, \mathbf{a}(\theta_D)] \quad (3)$$

그리고

$$\mathbf{f} = \left[\underbrace{1, \dots, 1}_L, \underbrace{0, \dots, 0}_{D-L} \right]^T \quad (4)$$

식 (2), (3), (4)에 기반하여, 라그랑지 승수를 사용하여 다음과 같은 최적 가중치 벡터의 솔루션을 획득할 수 있다[1-3].

$$\mathbf{w}_{\text{opt}} = \mathbf{R}_{xx}^{-1} \mathbf{C} (\mathbf{C}^H \mathbf{R}_{xx}^{-1} \mathbf{C})^{-1} \mathbf{f} \quad (5)$$

식 (5)는 잘 알려진 LCMV 빔합성기의 최적 가중치 벡터이다. 식 (5)의 솔루션은 간섭을 제약할 수 있고 동시에 다중 기대 신호에 대한 응답을 유지시킬 수 있다. 이러한 최적 가중치 벡터는 상관행렬과 제약 행렬의 비선형 함수이다. 그러므로 신경망 또는 심층 신경망과 같은 적절한 신경망 구조를 이용하여 근사화시킬 수 있다.

그림 1은 합성빔 성능 모의를 위한 CNN 모델로서, 입출력층외에 은닉 층은 Conv(Convolutional), ReLU(Rectified Linear Unit), MP(Max Pooling), FC(Fully connected) 층으로 구성하였다. 입력은 수신신호의 자기상관 행렬이고, 출력은 안테나 배열의 가중치 벡터이다[4].

첫 번째 컨볼루션층은 stride 1과 same padding, 3x3 크기의 8 커널로 구성하고, 두 번째와 세 번째 컨볼루션층은 커널 크기만 각각 16와 32 커널로 변경하여 구성한다. 입력층은 성능 비교를 위해 CNN-1D 모델[2, 3]은 $M(M-1) \times 1$ 과 CNN-2D 모델[4]은 $M \times (M-1)$ 로 구성하고, 출력층은 2개 모델 모두 $2M \times 1$ 노드로 구성된다.

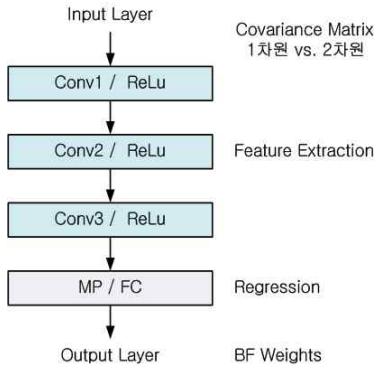


그림 1. CNN(Convolutional Neural Network) 구조

III. 시뮬레이션 및 성능 분석

CNN 모델의 학습 조건의 배열 안테나는 소자 16개로 구성되고, 반파장 ($\lambda/2$) 간격으로 이격, 입력 샘플수 400개, SNR 30dB 조건으로 설정하였다. 탐지각 범위는 -45° ~ $+45^{\circ}$ 로 설정하였고, 0.1° 간격으로 학습 및 실험 시뮬레이션을 진행하였다. 실험항목은 -2dB ~ 30dB 조건에서 합성비 지향오차, 부엽레벨(SLL)과 샘플수 변화에 따른 성능을 측정하였다.

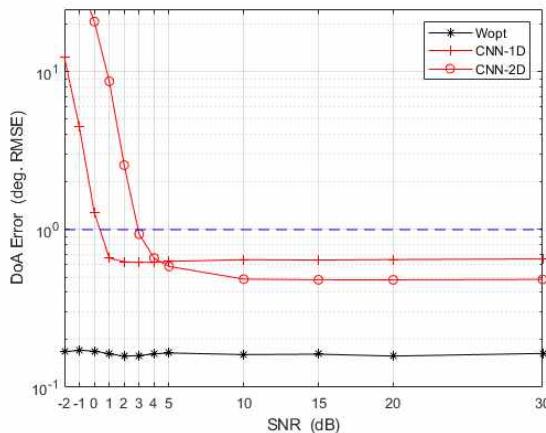


그림 2. SNR 변화에 따른 합성빔 지향 오차 변화

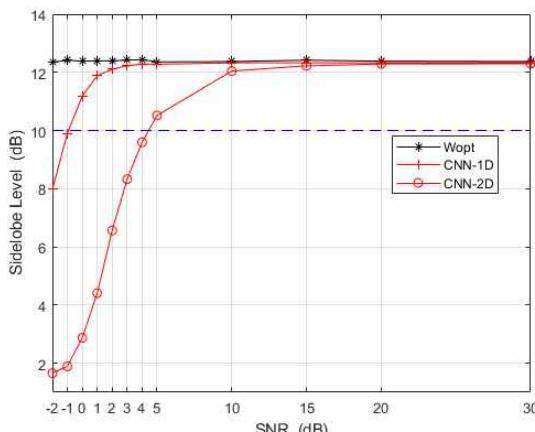


그림 3. SNR 변화에 따른 SLL 변화

먼저, SNR 변화에 따른 합성빔 지향 오차 변화는 그림 2와 같다. 방위 각 지향 오차를 보면 입력 SNR 5dB를 기준으로 CNN-1D와 CNN-2D의 성능이 차이를 보이는 것을 볼 수 있다. SNR 5dB 이하의 경우 CNN-1D가 우수하지만, 5dB 이상의 경우 CNN-2D가 우수한 성능을 보임을 볼 수

있다. SNR 3dB 이상에서 2개 CNN 모델 모두에서 1° RMSE 이하의 성능을 확인할 수 있다. 특히, LCMV 모델(Wopt)의 경우 전체 SNR 범위에서 성능변화 없이 약 0.2° RMSE의 우수한 성능을 보이고 있다.

그림 3은 30dB에서 학습된 CNN-1D와 CNN-2D 모델에서 실험 SNR 변화에 따른 합성빔의 SLL 변화를 나타낸 것이다. SLL 변화 특성은 전체적으로 CNN-1D 모델이 우수하게 나타났고, SNR 5dB 이상인 경우 2개 모델 모두 10dB 이상의 SLL 특성을 보여주고 있다. LCMV인 경우 전체 SNR 범위에 대해 12dB 이상의 SLL 특성을 나타나고 있다.

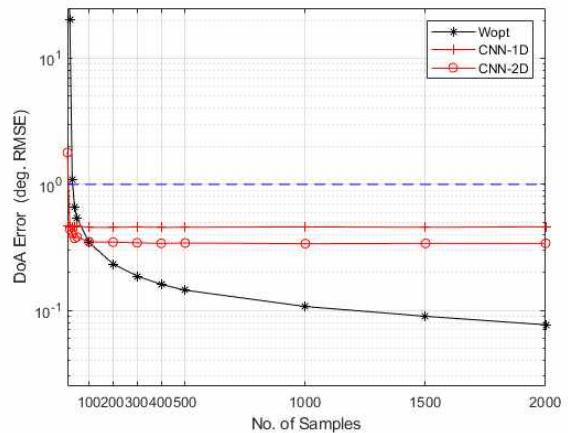


그림 4. 샘플수 변화에 따른 합성빔 지향 오차 변화

그림 4는 30dB와 400샘플에서 학습된 CNN-1D와 CNN-2D 모델에서 실험 샘플수 변화에 따른 지향오차 특성을 나타낸 것이다. LCMV인 경우 샘플수 변화에 따른 성능변화에 민감하지만, 2개 CNN 모델의 경우 성능 변화에 매우 둔감하다. 이 조건에서 50샘플 이상인 경우 전체 3개 모델이 1° RMSE 이하로 나타나고 있고, 특히 CNN 2개 모델의 경우 20 샘플 이상의 경우 1° RMSE 이하이고, 성능변화가 거의 없음을 확인할 수 있다.

IV. 결론

본 논문은 LCMV의 2개의 역행렬 계산을 제거할 수 있는 2종의 CNN 모델을 이용한 빠른 합성 생성기를 설계하고, 시뮬레이션을 통해 SNR 변화에 따른 지향오차와 부엽레벨 변화, 샘플수 변화에 따른 지향 오차 성능 변화를 확인하였다.

ACKNOWLEDGMENT

본 논문은 정부(방위사업청)의 재원으로 미래도전국방기술과제(No. 915087201)를 통해 연구가 수행되었다.

참 고 문 현

- [1] 박철순 외 6인, “심층 비지도 학습을 이용한 합성빔 성능 모의,” 한국 전자과학회 동계종합학술대회, Vol. 7, No. 1, 2025. 2. 12
- [2] Xun Wu, et al, “Fast Wideband Beamforming using Convolutional Neural Network,” MDPI remote sensing, Vol. 15, No. 712, 2023
- [3] Xun Wu, et al, “The Adaptive Wideband Beamforming using Convolutional Neural Network,” IEEE Int'l Conf. Microwave and Millimeter Technology(ICMMT), 2022
- [4] Parham Ramezanpour, et al., “Deep-learning-based beamforming for rejecting interferences,” IET Signal Processing, Vol. 7, Iss. 7, 2020