

전장 환경에서의 경량 DNN 기반 DoA 추정 성능 비교

박성열, 김한빛, 김선우
한양대학교 융합전자공학과

{c18006, dante0813, remero}@hanyang.ac.kr

DoA Estimation in Battlefield Environments : A Comparison of Lightweight DNN Approaches

Seongyeol Park, Hanvit Kim, and Sunwoo Kim

Department of Electronic Engineering, Hanyang University

요약

본 논문은 전장 환경에서 적 신호원의 도래 각 (direction-of-arrival, DoA) 추정을 위해 경량 딥러닝 모델 중 회귀 기반 R-DNN (regression-deep neural network)와 분류 기반 DAE-DNN (denoising autoencoder-deep neural network)의 성능을 비교한다. 전장 환경에서 적 신호원을 추정하기 위해서는 정확성과 빠른 추론 능력이 요구되기 때문에 본 연구는 연산 효율이 높은 경량 딥러닝 모델을 채택한다. 실험은 가상 전장 환경을 구성하고, 성능 평가는 RMSE (root mean square error), 추론 시간 (inference time), 파라미터 수를 기준으로 실시한다. 이에 따라 본 논문은 환경 조건에 따라 적합한 모델 선택의 타당성을 입증하고, 구현한 모델의 실시간 전장 배치에 위한 실용적 방향을 제시한다.

I. 서론

도래 각 (direction-of-arrival, DoA) 추정은 레이더, 무선 통신, 신호원의 위치 추정 등에 중추적인 기술이다 [1]. 고전기법인 MUSIC (multiple signal classification) 등의 알고리즘은 고 SNR 환경에서 우수한 성능을 보이지만 저 SNR, 간섭, 실시간 처리와 같은 환경에서는 정확성이 크게 저하된다 [2]. 최근 CNN (convolutional neural network), DeepMUSIC 등 고도화된 딥러닝 구조도 제안되었으나, 높은 연산량과 복잡한 네트워크 구조로 임베디드 시스템에 사용하기에는 부적절하다. 이에 따라 본 연구에서는 경량 DNN 모델인 R-DNN (regression-deep neural network)와 DAE-DNN (denoising autoencoder-deep neural network)을 비교하며, 전장 환경에서 두 모델의 실용성을 평가한다.

II. 경량 딥러닝 기반 도래 각 추정을 위한 시스템 모델

딥러닝 모델은 입력, 은닉, 출력층으로 구성되며, 본 연구의 R-DNN과 DAE-DNN은 동일한 입력 벡터를 사용한다. 입력은 배열 안테나로부터 수집된 신호 데이터를 기반으로 계산된 공분산 행렬 \mathbf{R} 의 상삼각 비대각 성분을 벡터화한 복소 벡터 \mathbf{b} 이며, 다음과 같이 정의된다 [2].

$$\mathbf{b} = [R_{12}, R_{13}, \dots, R_{1M}, R_{23}, \dots, R_{(M-1)M}]^T, \quad (1)$$

이후 실수부와 허수부를 각각 분리하고 결합한 뒤, 2-노름으로 정규화하여 실수 입력 벡터 \mathbf{z} 를 구성한다.

$$\mathbf{z} = [\text{Real}(\mathbf{b})^T, \text{Imag}(\mathbf{b})^T]^T / \|\mathbf{b}\|_2. \quad (2)$$

이때, 동일한 입력 벡터 \mathbf{z} 를 사용하더라도, R-DNN과 DAE-DNN은 은닉층의 구성 방식과 출력 형태에서 서로 다른 구조적 특성을 가진다.

R-DNN은 회귀 (regression) 방식을 적용하여, 입력 벡터 \mathbf{z} 를 받아 총 L 개의 층을 통해 도래 각을 추정한다. 각 은닉층에서는 다음과 같은 연산이 수행된다.

$$\mathbf{net}_l = \mathbf{W}_l \mathbf{h}_{l-1} + \mathbf{b}_l, \quad \mathbf{h}_l = \tanh(\mathbf{net}_l), \quad (3)$$

여기서 \mathbf{h}_l , \mathbf{W}_l , \mathbf{b}_l 는 각각 l 번째 은닉층의 출력벡터, 가중치 그리고 편향을 의미하며, \tanh 는 비선형성을 제공하는 활성화 함수이다.

이후, 출력층에서는 마지막 은닉층의 출력을 선형 결합하여, 도래 각을 실숫값으로 직접 예측한 추정 벡터 $\hat{\theta}$ 를 생성한다.

$$\hat{\theta} = \mathbf{net}_L = \mathbf{W}_L \mathbf{h}_{L-1} + \mathbf{b}_L. \quad (4)$$

DAE-DNN은 분류 (classification) 방식을 적용하여, 입력 벡터 \mathbf{z} 를 받아 잡음을 제거하고 각도 공간을 구간별로 나누어 도래 각을 추정한다. 전체 모델은 DAE (denoising autoencoder)와 병렬 다중 분류기로 구성되며, 각 서브 영역 (sub-area) 내에서 신호 존재 확률을 출력한 뒤, 이를 기반으로 연속적인 추정값을 산출한다.

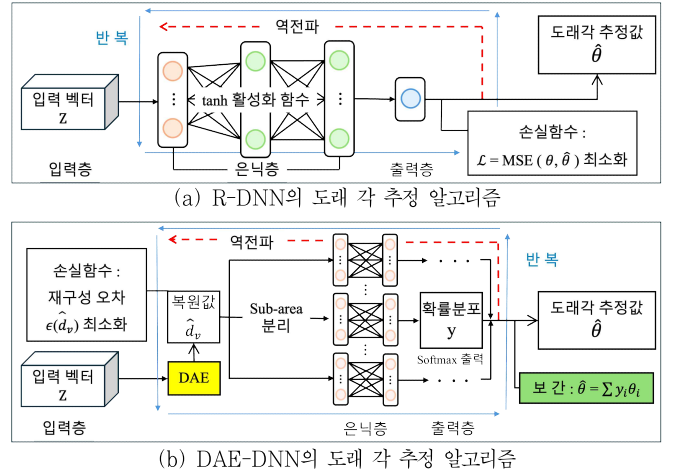


그림 2. 경량 딥러닝 시스템 모델의 도래각 추정 알고리즘

입력 벡터 \mathbf{z} 는 먼저 DAE를 통과하여, 잡음에 강인한 신호 표현으로 변환된다. 이는 분류기의 도래 각 예측 성능 향상을 위한 전처리 과정이다. 구조와 학습 방식은 [3]의 Section III-A를 참고하면 된다. DAE 출력을 입력으로 받는 분류기는 전체 각도 공간을 고정된 구간으로 나누어 병렬적으로 구성된다. 각 분류기의 은닉층은 입력값을 비선형적으로 변환하며, 출력층에서는 해당 구간 내 후보 각도들에 대한 존재 확률을 확률 분포 기반인 Softmax 함수로 계산한다.

$$\mathbf{y} = \text{Softmax}(\mathbf{W}_e \mathbf{d} + \mathbf{b}_e), \quad (5)$$

여기서 \mathbf{d} 는 DAE의 출력 벡터, \mathbf{W}_e , \mathbf{b}_e 는 각각 추정 분류기 출력층의 가중치와 편향이다. \mathbf{y} 는 각도 구간 내 세분화된 각도 지점 (grid)에 대한 신호 존재 확률 벡터이며, 각 후보 각도에 대한 탐지 (detection)를 수행한다. 이후 각 grid의 중심 각도 θ_i 와 확률 y_i 의 가중합을 통해 연속적인 추정 (estimation)을 수행하여 추정 벡터 $\hat{\theta}$ 를 생성한다.

$$\hat{\theta} = \sum_i y_i \theta_i. \quad (6)$$

III. 경량 딥러닝 시스템 모델의 도래 각 추정 알고리즘

R-DNN은 도래 각 추정 시, 그림 1의 (a)와 같이 실제 도래 각 θ 와 모델 출력값 $\hat{\theta}$ 사이의 MSE (mean squared error)를 줄여나가며 반복적으로 학습된다. 이때 최적 파라미터 Ω 는 다음과 같이 정의된다.

$$\Omega = \arg \min_{\Omega} \frac{1}{D} \sum_{i=1}^D \|\hat{\theta}_i - \theta_i\|_2^2. \quad (7)$$

여기서 D 는 학습 샘플의 개수이며, 학습이 완료된 모델은 새로운 입력에 대해 실숫값 형태의 연속적인 도래 각 $\hat{\theta}$ 를 직접 출력한다.

DAE-DNN 기반 도래 각 추정은 그림 1의 (b)와 같이 입력 벡터 \mathbf{z} 를 DAE에 통과시켜 잡음이 제거된 벡터 \mathbf{d}_v 에 가까운 복원 벡터 $\hat{\mathbf{d}}_v$ 를 생성한다. 이때, 복원 성능의 정량적 평가를 위해 입력과 복원 벡터 간의 재구성 오차 (reconstruction error)를 손실 함수 $\epsilon(\delta_v)$ 로 정의한다.

$$\epsilon(\delta_v) = \frac{1}{2} \|\mathbf{d}(\delta_v) - \hat{\mathbf{d}}(\delta_v)\|_2^2. \quad (8)$$

여기서 δ_v 는 v 번째 입력 샘플로, 학습은 이 손실 함수를 줄여나가는 방향으로 진행된다.

그림 1의 (b)를 보면, 복원된 벡터 $\hat{\mathbf{d}}_v$ 는 Sub-area 분류기에 입력되어 Softmax 함수를 통해 각 후보 각도에 대한 확률 분포 \mathbf{y} 를 출력한다. 이 확률 분포는 수식 (6)과 같이 각 후보 각도에 대해 가중치를 부여하여 보간 (interpolation)을 수행하고, 그 결과로 최종 추정값 $\hat{\theta}$ 가 추론 단계에서 출력된다.

IV. 시뮬레이션 설정 및 결과 분석

본 실험은 단일 위험을 가정하고, ULA (uniform linear array) 구조를 기반으로 협대역 (narrowband) 및 원거리 (far-field) 조건을 전체로 한다. 이때, 저 SNR은 전자전/간섭 환경, 고 SNR은 평시 통신 환경을 모사한다. 두 모델은 동일한 실험 조건 구성을 위해 같은 공분산 행렬 기반의 입력 벡터를 사용하였고, 전체 데이터 세트는 4 : 1 비율로 학습 및 검증용을 분할하며 200 epochs까지 학습하였다. 성능 평가는 각 SNR 조건별로 생성된 테스트 세트를 바탕으로 몬테카를로 시뮬레이션 방식을 사용하였다. 이때, 도래 각 추정 성능 평가 지표로서 RMSE (root mean square error)를 사용하며 그 정의는 아래와 같다.

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{\theta}_i - \theta)^2} \quad (9)$$

여기서 N 은 테스트 샘플의 수로, 본 실험에서는 400개로 설정하였다.

그림 1은 SNR 변화에 따른 두 모델의 추정 정확도를 RMSE를 기준으로 비교한 결과이다. 전반적으로 SNR이 낮아질수록 두 모델 모두 추정 정확도가 낮아졌지만, 성능이 완만하게 감소하는 DAE-DNN에 비해 R-DNN은 -5dB 이하의 잡음 환경에서 뚜렷한 성능 저하를 보였다. 반대로 5dB 이상의 환경에서는 상대적으로 R-DNN이 더 나은 추정 정확도를 나타냈다. 이는 각 모델의 구조 및 출력 방식의 차이에 의한 결과 때문으로 보여진다. 즉, SNR의 수준에 따라 적합한 모델이 달라질 수 있으며, 잡음 및 간섭 환경이 심할 것으로 추정되는 전장 환경에서는 DAE-DNN이 더 적합하다고 판단된다.

표 2는 그림 1에서 각 SNR에 따라 두 모델별로 구한 추론 시간 (inference time)의 평균과 모델 파라미터 수를 비교한 결과이며, 실험은 NVIDIA GeForce RTX 2070 SUPER 환경에서 실행하였다. 표 2의 파라미터 수를 보면 R-DNN이 DAE-DNN에 비해 상대적으로 간결한 구조를 가지며 연산량이 더 적은 경량 모델임을 알 수 있다. 실제 두 모델의 추론 시간에 대한 경향성을 비교해 보면 대체적으로 R-DNN이 DAE-DNN에 비해 더 빠른 추론을 함으로써 높은 연산 효율성을 나타낸다. 이는 실시간성이 중요한 전장 환경에서 R-DNN이 더 적합할 수 있음을 보여준다.

표 1. 실험 조건

구분	값
수신 안테나 수 (M)	8
스냅샷 수 (N)	200
신호 수 (P)	1
SNR	-10 ~ 30dB (5dB 간격)
추정 지표	RMSE, 평균 추론 시간, 파라미터 수
몬테카를로 시행 수	1000




그림 2. SNR 변화에 따른 RMSE 비교

표 2. 평균 추론 시간 및 파라미터 수 비교

모 델	평균 추론 시간 (ms)	파라미터 수 (개)
R-DNN	4.16	6,961
DAE-DNN	6.58	31,624

IV. 결론 및 연구 방향

본 논문은 전장 환경에서 적의 도래 각 추정에 대한 성능을 비교하기 위해, R-DNN과 DAE-DNN을 대상으로 실험을 수행하였다. 실험 결과, 동일한 SNR 조건에서 R-DNN이 상대적으로 더 빠른 추론 속도를 보였지만, 추정 정확성 측면에서 살펴보면 저 SNR 조건에서는 DAE-DNN이 상대적으로 안정적인 성능을 유지하는 것으로 나타났다. 즉, R-DNN은 연산 효율성 측면에서 유리한 특성을 보이며, DAE-DNN은 잡음에 대해 강건한 성능을 나타낸다. 이는 가변적인 전장 환경에서 상황에 따라 상호 보완적으로 두 모델을 운용할 수 있음을 보여준다.

이번 실험을 통해 전장 환경을 모사하기 위해 다양한 SNR으로 구성된 환경에서 R-DNN과 DAE-DNN의 성능을 비교하고, 상황에 따라 두 모델이 보완적으로 운용될 수 있음을 확인하였다. 본 실험에서는 특정 환경에서 두 모델을 동시에 운용하고 그 결과를 통해 각 모델의 성능을 비교했지만, 실제 운용 상황에서는 각 상황에 유리한 단일 추정 방식을 신속하게 선택하여 적용하는 것이 필요하다. 이에 따라서 향후에는 신호 환경의 특성을 자동으로 분석하여 적합한 모델을 선택하거나, 두 구조를 통합하는 적응형 하이브리드 모델에 대해 연구한다면 실시간 전장 대응 능력을 향상할 수 있을 것이다.

ACKNOWLEDGMENT

이 논문은 2024년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. RS-2024-00409492).

참 고 문 헌

- [1] S. Kulkarni, A. Thakur, S. Soni, A. Hiwale, M. H. Belsare, and A. A. Bazil Raj, "A comprehensive review of direction of arrival (DoA) estimation techniques and algorithms," J. Electron. Electr. Eng., vol. 4, pp. 138 - 186, 2025.
- [2] Y. Xiong, A. Liu, X. Gao, and Y. Arnatovich, "DOA estimation using deep neural network with regression," in Proc. 2022 5th Int. Conf. Inf. Commun. Signal Process. (ICICSP), Oct. 2022, pp. 111 - 115.
- [3] D. Chen, S. Shi, X. Gu, and B. Shim, "Robust DoA estimation using denoising autoencoder and deep neural networks," IEEE Access, vol. 10, pp. 52551 - 52569, Apr. 2022.