

머신러닝 기반 방향탐지 알고리즘 성능 개선 연구

박현우, 김선우

한양대학교 융합전자공학과
{stark95, remero}@hanyang.ac.kr

Research on Performance Improvement of Machine Learning-based Direction Finding Algorithm

Hyunwoo Park and Sunwoo Kim

Department of Electronic Engineering, Hanyang University

요약

본 논문에서는 머신러닝 기반 방향탐지 알고리즘 성능 개선을 위하여 필요한 훈련 데이터 수집 조건을 분석한다. 국방, 인명 구조, 차세대 통신을 위하여 방향탐지 정확도 향상이 필수적이다. 기존 모델 기반 방향탐지 알고리즘은 모델 불일치 시 성능이 저하되며 복잡한 모델을 사용하는 경우 계산 복잡도가 증가하여 실시간 방향탐지가 어렵다. 머신러닝 기반 방향탐지 알고리즘의 경우 방향탐지 환경에서 훈련 데이터 수집 비용이 발생한다. 따라서 본 연구에서는 방향탐지 정확도 개선을 위하여 머신러닝 기반 방향탐지 알고리즘의 목표 방향탐지 정확도에 따라서 필요한 훈련 데이터 수집 조건을 실험을 통하여 분석한다.

I. 서론

방향탐지 기술은 기존 불법 전파 활동과 무선국의 위치 탐지에서 최근 적군 신호원 위치 탐지, 인명 구조, 실내 신호원 위치 탐지 등의 다양한 목적으로 사용성이 확장되었다[1]. 기존 모델 기반 방향탐지 알고리즘은 모델 불일치가 빈번한 실환경에서 성능이 저하되며, 성능 개선을 위하여 복잡한 모델을 사용하는 경우 높은 계산 복잡도로 실시간 방향탐지에 적합하지 않다[2]. 머신러닝 기반 방향탐지 알고리즘은 실시간 운용에 적합하나 훈련 데이터 수집 어려움이 존재한다[3]. 본 논문에서는 실환경 방향탐지 정확도 개선을 위하여 머신러닝 기반 방향탐지 알고리즘의 목표 방향탐지 정확도에 따라서 필요한 훈련데이터 수집 조건 분석 연구를 진행한다.

II. 시스템 모델

본 논문에서는 M 개의 선형 배열 안테나로 구성된 기지국이 1개의 미상 신호원 방향을 탐지하는 환경을 고려한다. 매 방향탐지 시 기지국에서 T 개의 스냅샷을 측정하며 수신신호 \mathbf{X} 는 다음과 같다.

$$\mathbf{X} = \mathbf{a}(\theta)\mathbf{s}^T + \mathbf{N} \in \mathbb{C}^{M \times T}, \quad (1)$$

여기서 $\mathbf{a}(\theta) \in \mathbb{C}^{M \times 1}$ 는 도래각 θ 에서의 안테나 응답 벡터, $\mathbf{s} \in \mathbb{C}^{T \times 1}$ 는 각 원소가 $s_t \sim \mathcal{CN}(0, \sigma_s^2)$ 을 따르는 신호 행렬이며, $\mathbf{N} \in \mathbb{C}^{M \times T}$ 은 각 원소가 $n_{m,t} \sim \mathcal{CN}(0, \sigma_n^2)$ 을 따르는 잡음 행렬이다. 안테나 응답 벡터 $\mathbf{a}(\theta)$ 는 다음과 같다.

$$\mathbf{a}(\theta) = [1, e^{j\pi \cos \theta}, \dots, e^{j\pi (M-1) \cos \theta}]^T. \quad (2)$$

수신신호 공분산 행렬 \mathbf{R} 은 다음과 같다.

$$\begin{aligned} \mathbf{R} &= \sigma_s^2 \mathbf{a}(\theta) \mathbf{a}(\theta)^H + \sigma_n^2 \mathbf{I} \\ &\approx \frac{1}{T} \mathbf{X} \mathbf{X}^H \in \mathbb{C}^{M \times M}. \end{aligned} \quad (3)$$

III. 머신러닝 기반 방향탐지 알고리즘

본 논문에서는 그림 1과 같이 합성곱 신경망을 사용하여 도래각을 추정하는 지도 학습[3]을 머신러닝 기반 방향탐지 대표 알고리즘으로 사용한다. 여기서 네트워크의 입력값으로 전처리 과정을 거친 수신신호 공분산 행렬, 출력값으로 신호원의 도래각을 추정한다. 전처리 과정은

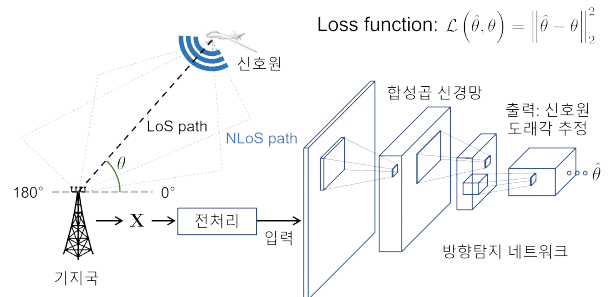


그림 1 합성곱 신경망 기반 방향탐지 모식도

수신신호 공분산 행렬을 정규화 이후 실수, 허수부를 분리하여 네트워크의 입력 모양에 맞도록 행렬화 하며 다음과 같다.

$$\left[\left[\text{real} \left(\frac{\mathbf{R}}{\|\mathbf{R}\|_F} \right) \right]; \left[\text{imag} \left(\frac{\mathbf{R}}{\|\mathbf{R}\|_F} \right) \right] \right] \in \mathbb{R}^{2 \times M \times M} \quad (5)$$

방향탐지 네트워크는 regression을 사용하며 출력으로 신호원의 도래각 θ 이 나오도록 설정한다. 손실 함수는 추정 도래각 $\hat{\theta}$ 과 실제 도래각 θ 의 차이에 대한 함수이며 다음과 같다.

$$\text{Loss}(\hat{\theta}, \theta) = |\hat{\theta} - \theta|^2 \quad (5)$$

네트워크 구조는 표 1과 같다.

표 1. 방향탐지 네트워크 구조

CNN Model					
Input size					2×4×4
Layer 1	Layer type	Conv2d	Layer 3	Layer type	Conv2d
	# Kernel	50		# Kernel	300
	Kernel size	2×2		Kernel size	2×2
	Ouput size	5×3×3		Ouput size	300×1×1
Layer 2	Layer type	Conv2d	Layer 4	Layer type	Dense
	# Kernel	150	# Kernel	300	
	Kernel size	2×2	Layer 5	Kernel size	Dense
	Ouput size	150×2×2	Ouput size	1	
Acivation function					ReLU




그림 2 방향탐지 테스트베드 구성

IV. 훈련 데이터 수집 조건 분석 실험

훈련데이터 수집을 위하여 그림 2와 같이 방향탐지 테스트베드를 구성하였다. 신호원 역할의 송신단은 단일 안테나와 USRP-2954R을 사용, 기지국 역할의 수신단은 4 by 1 선형 배열 안테나와 USRP-2955를 사용하였다. 모든 각도에서의 실환경 데이터 취득이 불가능하기에 일정한 각도 간격으로 자료수집을 진행하며, 여기서 훈련데이터의 신호 수집 각도 간격에 따라서 방향탐지 성능 변화를 분석하였다. 훈련데이터 수집 각도 간격은 2°, 3°, 5°, 6°, 10°, 15°, 30°이며 방향탐지 테스트는 수집하지 않은 각도에서 실시한다. 실험 환경은 실외 공터에서 진행하였으며 송수신기 간 거리는 10m, 수신 SNR은 5.5dB로 측정되었다.

그림 3은 각 방향탐지 네트워크의 각도에 따른 방향탐지 테스트 결과이다. 여기서 Net_n 은 훈련데이터 수집 각도 간격 n° 에 대하여 학습한 방향탐지 네트워크이다. 실환경 데이터로 훈련 및 테스트를 진행한 경우(그림 3 (좌)), 훈련 하지 않은 각도에서의 방향탐지 root mean squared error (RMSE)가 증가하며, 이는 수집 각도 간격이 높아질수록 ($Net_2 \rightarrow Net_5 \rightarrow Net_{15}$) 더욱 분명하게 나타난다. 실환경 데이터의 경우 수집 단계에서 생기는 도래각 측정 오차가 발생하기에 수집 각도 간격과 방향탐지 성능의 정확한 비교를 위하여 시뮬레이션 상에서 동일한 실험을 진행하였다 (그림 3 (우)). 시뮬레이션 결과 수집한 각도와 차이가 높은 방향에서의 RMSE가 증가함을 확인 가능하다. Net_2 의 경우 훈련하지 않은 각도에서의 RMSE가 수집 각도에서의 RMSE와 큰 차이를 보이지 않으며, 이는 훈련 데이터 수집 시 2° 간격 이하 수집 필요성이 낮음을 확인 가능하다.

그림 4는 훈련데이터 수집 각도 간격에 따른 방향탐지 정확도이다. 실환경 데이터와 시뮬레이션 모두 수집 각도 간격이 넓어짐에 따라서 방향탐지 RMSE가 증가함을 확인 가능하다. 시뮬레이션의 경우 수집 각도 간격이 10° 이하인 경우 1° 이하의 방향탐지 RMSE를 보이며 이는 이상적인 free space 공간에서 방향탐지 시 훈련데이터의 수집 각도 간격을 10° 이하로 설정하는 것이 효과적임을 확인 가능하다. 실환경

표 2. 시뮬레이션 매개변수

매개변수	값
안테나 원소 개수 M	4
스냅샷 수 T	256
송신 신호 세기 σ_s	1
신호 대 잡음 비	5.5 [dB]
각도 별 수집 데이터 수	500
총 데이터 수	15,500
훈련데이터 비율	80%
테스트 데이터 비율	20%




그림 3 방향탐지 테스트 결과 (좌: 실측 데이터, 우: 시뮬레이션 데이터)




그림 4 훈련데이터 수집 각도 간격에 따른 방향탐지 정확도

데이터의 경우 훈련데이터 수집 각도 간격이 6° 이하인 경우 2°이내의 방향탐지 RMSE를 보이며 이는 각도 간격이 더 좁혀지더라도 큰 차이를 보이지 않는다. 따라서 실환경에서 방향탐지 훈련데이터 취득 시 6° 정도의 각도 간격에서 데이터를 수집하는 것이 효과적이며, 더 높은 성능을 목표로 하는 경우, 데이터 수집 측정 오차를 줄이는 것이 중요해짐을 확인 가능하다.

V. 결론

본 논문에서는 머신러닝 기반 방향탐지 성능 개선을 위하여 훈련데이터 수집 조건을 분석한다. 기존 모델 기반 방향탐지 알고리즘은 실상에서 사용 시 모델 불일치가 발생하며 머신러닝 기반 알고리즘은 데이터 취득 비용을 고려해야 한다. 실환경 방향탐지 정확도 개선을 위하여 실측 데이터를 수집하고, 수집 각도 조건에 따라서 머신러닝 기반 방향탐지 알고리즘의 성능을 분석하였다. 실험 결과 수집 각도 간격이 좁아질수록 방향탐지 정확도가 높아지며, 더 높은 정확도를 목표하는 경우 데이터 취득 오차를 줄이는 것이 중요함을 확인하였다.

ACKNOWLEDGMENT

이 논문은 2023년도 4단계 두뇌한국21 사업(4단계 BK21 사업)에 의하여 지원되었음

참 고 문 헌

- [1] N. H. Lehmann et al., "Evaluation of Transmit Diversity in MIMO-Radar Direction Finding," *IEEE Trans. Sig. Process.*, vol. 55, no. 5, pp. 2215-2225, May 2007.
- [2] Y. Gu et al., "Optimized compressive sensing-based direction-of-arrival estimation in massive MIMO," in *Proc. IEEE Int. Conf. Acoust. Speech Signal Process (ICASSP)*, pp. 3181-3185, Mar. 2017.
- [3] Chung, H., et al., "Leveraging Deep Learning for Practical DoA Estimation: Experiments with Real Data Collected via USRP," *Sensors*, vol. 22, no. 19, pp. 7578, Oct. 2022.