

순전파 계산을 이용한 FFNN 모델 기반 도래각 추정 알고리즘

양예승, 민기홍, 이현수, 김선우

한양대학교

{yangys0511, khmin705, geniusoo, remero}@hanyang.ac.kr

FFNN Model-based Angle-of-arrival Estimation Algorithm Using Forward Propagation

Yeseung Yang, Kihong Min, Hyunsoo Lee, Sunwoo Kim

Department of Electronic Engineering, Hanyang University

요약

본 논문에서는 feed-forward neural network 기반 방향탐지 알고리즘 모델을 제안한다. 기존 ESPRIT (Estimation of Signal Parameters via Rotational Invariance Techniques) 알고리즘은 잡음이 많은 환경에서 도래각 추정 성능이 급격히 하락하며, 많은 안테나 요소를 사용하는 ultra massive multiple input multiple output와 같은 시나리오에서 계산량이 높아져 실환경 적용에 어려움이 존재한다. 제안 알고리즘은 signal-to-noise ratio가 0, 5, 10, 15인 autocovariance matrix와 도래각 사이의 데이터들을 학습하여 도래각 추정 성능을 높였고, 기존 알고리즘의 singular value decomposition 과정을 생략하여 계산량을 낮췄다. 도래각 추정의 root mean square error를 계산하여 제안 알고리즘과 기존 알고리즘의 성능을 비교하였으며, 시뮬레이션 결과 제안 알고리즘이 기존 ESPRIT 알고리즘에 비해 추정 결과가 더 정확함을 확인하였다.

I. 서론

도래각 추정은 radar, sonar, navigation, wireless communications 등 다양한 실제 응용 분야에서 필수적이기 때문에 현재까지 연구되고 있는 주제이다 [1]. 수신 신호의 도래각을 추정하는 방법으로 ESPRIT (Estimation of Signal Parameters via Rotational Invariance Techniques) 알고리즘이 있다. 위와 같은 알고리즘은 잡음이 많은 환경에서 도래각 추정 성능이 급격히 하락하며 [2], 많은 안테나 요소를 사용하는 ultra massive multiple input multiple output와 같은 시나리오에서 계산량이 높아져 실환경 적용에 어려움이 존재한다 [3]. 본 논문에서는 잡음이 많은 환경에서도 원활히 작동하며 계산량을 줄인 FFNN (Feed-forward Neural Network) 기반 알고리즘을 제안하고, 그에 따른 성능을 기존의 ESPRIT 알고리즘과 비교하여 분석한다.

II. 시스템 모델

본 논문에서는 그림 1과 같이 K 개의 신호원과 M 개의 안테나를 고려하여 도래각 θ 를 추정한다. \mathbf{x} 를 수집된 데이터 벡터라고 한다면 \mathbf{x} 는 다음과 같다 [4].

$$\mathbf{x} = \sum_{k=1}^K \mathbf{a}(\theta_k) s_k + \mathbf{n} = \mathbf{A} \mathbf{s} + \mathbf{n} \in \mathbb{C}^{M \times 1}, \quad (1)$$

여기서 방향모드행렬 \mathbf{A} , 신호원의 신호벡터 \mathbf{s} , k 번째 신호원에 해당하는 array manifold vector $\mathbf{a}(\theta_k)$ 는 다음과 같다.

$$\mathbf{A} = [\mathbf{a}(\theta_1), \dots, \mathbf{a}(\theta_K)] \in \mathbb{C}^{M \times K}, \quad (2)$$

$$\mathbf{s} = [s_1, \dots, s_K]^T \in \mathbb{C}^{K \times 1}, \quad (3)$$

$$\mathbf{a}(\theta_k) = [1, e^{j2\pi d \sin \theta_k / \lambda}, \dots, e^{j2\pi (M-1)d \sin \theta_k / \lambda}]^T \in \mathbb{C}^{M \times 1}, \quad (4)$$

이때 λ 는 전파 파장, D 는 snapshot의 수, \mathbf{n} 은 분산이 σ_n^2 인 additive white gaussian noise, $[\cdot]^T$ 는 행렬의 transpose를 나타내는 연산자를 의미한다. 이 때 \mathbf{x} 의 autocovariance matrix \mathbf{R}_x 는 다음과 같다.

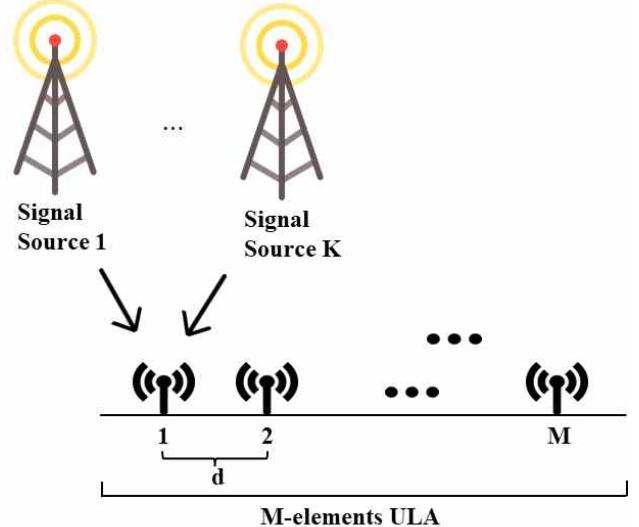


그림 1 수신단이 미상 신호의 방향을 탐지하는 시나리오

$$\mathbf{R}_x = \mathbf{A} \mathbf{S} \mathbf{A}^H + \sigma_n^2 \mathbf{I} \in \mathbb{C}^{M \times M}, \quad (5)$$

여기서 $(\cdot)^H$ 는 행렬의 hermitian을 나타내는 연산자, \mathbf{S} 는 rank D 의 $E\{\mathbf{s}\mathbf{s}^H\}$, $\mathbf{I} \in \mathbb{C}^{M \times M}$ 는 identity matrix이다.

III. 머신러닝 기반 방향탐지 알고리즘

본 논문에서 제안하는 도래각 추정 모델을 그림 2에 나타내었다. 여기서 모델의 입력값으로 실수부와 허수부를 분리하는 과정을 거친 χ , 출력값으로 도래각을 지정하였다. \mathbf{R}_x 를 실수부와 허수부로 분리시킨 χ 는 제안 모델의 입력 데이터로 사용되고 다음과 같다.

$$\chi = [[real(\mathbf{R}_x)]; [imag(\mathbf{R}_x)]] \in \mathbb{C}^{M \times M}, \quad (6)$$

손실 함수는 RMSE(Root Mean Square Error)로 추정 도래각 $\hat{\theta}$ 과 실제 도래각 θ 의 차이에 대한 평균의 합수이며 다음과 같다.

$$Loss(\hat{\theta}, \theta) = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{\theta} - \theta)^2}, \quad (7)$$

여기서 n 은 도래각을 추정한 횟수이다. 모델 구조는 표 1과 같다.

IV. 시뮬레이션 결과

시뮬레이션 파라미터는 표 2와 같다. 그림 3은 40° 로 입사하는 신호원에 대해 SNR(Signal-to-Noise Ratio)에 따라 ESPRIT 알고리즘과 제안 알고리즘 기반 도래각 추정의 RMSE를 비교한 것이다. 제안 알고리즘의 경우, SNR이 0이면 0.9° 이하의 RMSE를 보이고, ESPRIT 알고리즘의 경우, SNR이 0이면 1° 이하의 RMSE를 보인다. 이는 SNR이 0, 5, 10, 15로 주어진 상황에서 FFNN 모델의 도래각 추정 성능이 ESPRIT 알고리즘의 도래각 추정 성능보다 효과적임을 보여준다.

V. 결론

본 논문에서는 순전파 계산을 이용한 FFNN 모델 기반 방향탐지 알고리즘을 제안한다. 기존 ESPRIT 알고리즘은 낮은 SNR에서 도래각 추정 성능이 저하되므로 새로운 알고리즘의 도입이 필수적이다. 본 논문에서는 제안 알고리즘의 학습을 위해 autocovariance matrix와 도래각 사이의 데이터들을 생성하였다. 생성된 데이터들을 이용해 도래각 추정 모델을 훈련하였고, 이를 기반으로 제안 알고리즘이 순전파 계산을 통해 도래각을 추정한다. 시뮬레이션 결과, 각각의 주어진 SNR에 대해 제안 알고리즘의 도래각 추정 성능이 기존 ESPRIT 알고리즘의 도래각 추정 성능보다 더 우수함을 확인하였다.

표 1 도래각 추정 모델 구조

FFNN 모델		
Input size		$4 \times 4 \times 2$
Layer 1	Layer type	Complex Input
	Output size	$4 \times 4 \times 2$
	Activation function	-
Layer 2	Layer type	Flatten
	Output size	32
	Activation function	-
Layer 3	Layer type	Linear
	Output size	128
	Activation function	ReLU
Layer 4	Layer type	Linear
	Output size	64
	Activation function	ReLU
Layer 5	Layer type	Linear
	Output size	32
	Activation function	ReLU
Layer 6	Layer type	Linear
	Output size	1
	Activation function	-

표 2 시뮬레이션 파라미터

파라미터	값	단위
훈련 epoch 수	300	-
Learning rate	0.000615	-
Batch size	1	-
θ	40°	$^\circ$
M	4	-
D	20	-

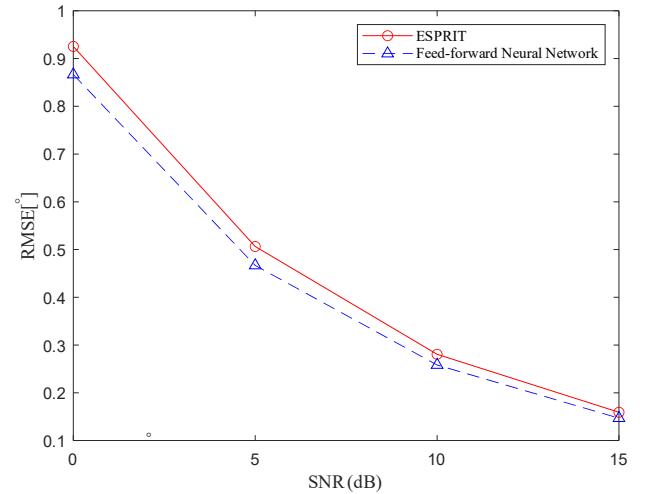


그림 2 SNR에 따른 도래각 추정 RMSE 비교

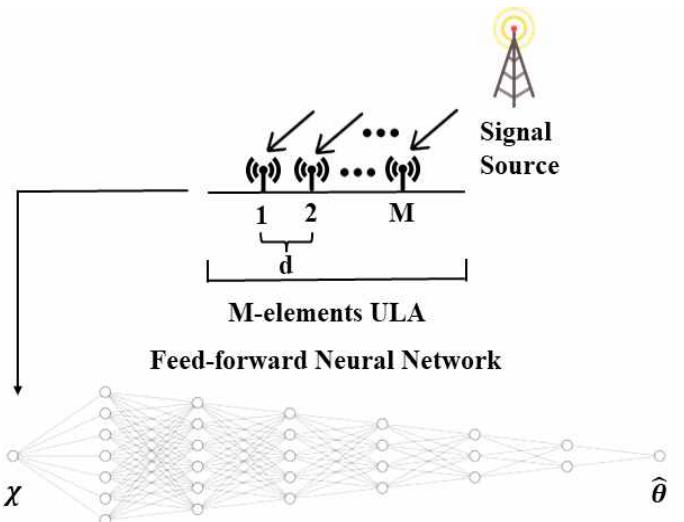


그림 3 FFNN 기반 방향탐지 모식도

참 고 문 헌

- [1] S. Luan *et al*, “Generalized covariance-based ESPRIT-like solution to direction of arrival estimation for strictly non-circular signals under alpha-stable distributed noise,” *Dissertation*, Nov, 2021.
- [2] 정연서, 박현우, 김선우, “다중경로 환경에서 머신러닝 기반 방향탐지 알고리즘” 2023년도 한국통신학회 학계종합학술발표회 논문집, Jun. 2023.
- [3] A. RAJANI *et al*, “Direction of Arrival Estimation by Using Artificial Neural Networks” *Third International Conference on Intelligent Communication Technologies and Virtual Mobile Networks*, Feb. 2021.
- [4] G. Xu *et al*, “Beamspace ESPRIT” *IEEE TRANSACTIONS ON SIGNAL PROCESSING*, Feb, 1994.