

도래각 추정을 위한 3단계 인공신경망 알고리즘

Three Stage Neural Networks for Direction of Arrival Estimation

박선배 · 유도식*

홍익대학교 전자전기공학과

Sun-bae Park · Do-sik Yoo*

Department of Electronic and Electrical Engineering, Hongik University, Seoul, 04066, Korea

[요 약]

도래각 추정은 표적으로부터 생성, 혹은 반사된 신호를 분석하여 표적의 방향을 추정하는 것으로 다양한 분야에 활용되고 있다. 인공신경망은 생물의 신경망을 모방한 기계학습의 한 분야로 패턴인식에서 좋은 성능을 보인다. 이러한 인공신경망을 도래각 추정에 활용하는 연구가 진행되어왔으나, 다양한 신호대잡음비 환경에 대응하는데에 제한이 있는 상황이다. 본 논문에서는 도래각 추정을 위한 3단계 인공신경망 알고리즘을 제안한다. 제안하는 알고리즘은 잡음제거과정을 통해 단일 신호대잡음비 환경에서 학습한 모델을 다양한 환경에 적용해도 성능감소를 최소화할 수 있다. 또한 도래각 시프트 과정을 통해 학습 난이도를 낮출 수 있고 효율적인 추정이 가능하다. 우리는, 제안하는 알고리즘과 다른 부공간 기법, Cramer-Rao bound (CRB)와의 성능 비교를 통해 제안하는 알고리즘이 낮은 신호대잡음비 환경, 표적들의 도래각이 가까운 환경 등 특정한 열악한 관측환경에서 타 기법에 비해 좋은 성능을 보이는 것을 확인하였다.

[Abstract]

Direction of arrival (DoA) estimation is a scheme of estimating the directions of targets by analyzing signals generated or reflected from the targets and is used in various fields. Artificial neural networks (ANN) is a field of machine learning that mimics the neural network of living organisms. They show good performance in pattern recognition. Although researches has been using ANNs to estimate the DoAs, there are limitations in dealing with variations of the signal-to-noise ratio (SNR) of the target signals. In this paper, we propose a three-stage ANN algorithm for DoA estimation. The proposed algorithm can minimize the performance reduction by applying the model trained in a single SNR environment to various environments through a ‘noise reduction process’. Furthermore, the scheme reduces the difficulty in learning and maintains efficiency in estimation, by employing a process of DoA shift. We compare the performance of the proposed algorithm with Cramer-Rao bound (CRB) and the performances of existing subspace-based algorithms and show that the proposed scheme exhibits better performance than other schemes in some severe environments such as low SNR environments or situations in which targets are located very close to each other.

Key words : Artificial neural network, DoA estimation, Multi layer perceptron, Signal processing, Subspace-based methods.

<https://doi.org/10.12673/jant.2020.24.1.47>



This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

Received 3 February 2020; Revised 5 February 2020

Accepted (Publication) 25 February 2020 (28 February 2020)

*Corresponding Author ; Do-sik Yoo

Tel : +82-2-320-3048

E-mail: yoodosik@hongik.ac.kr

I. 서론

도래각 (DoA; direction of arrival) 추정[1]은 표적으로부터 생성, 혹은 반사된 신호의 방향을 추정하는 것으로, 통신, 레이더 신호처리 분야 등 다양한 분야에 활용되고 있다. 또한 패턴 인식에서 좋은 성능을 보이는 인공신경망 (artificial neural network)을 도래각 추정에 접목하는 연구가 진행 중이다. 그러나 인공신경망 기반의 방법은 다양한 신호대잡음비 (SNR; signal to noise ratio) 환경에 대응하는데 제한이 있고, 다수 표적의 도래각 배치의 경우의 수가 많아 학습난이도가 높다. 본 논문에서는 이러한 난점들을 해결할 수 있는 도래각 추정을 위한 3단계 인공신경망 알고리즘을 제안한다.

기존의 도래각을 추정하기 위한 기법으로는 빔형성 (beamforming)이나 부공간 기법과 같이 다양한 방법이 있다. 그 중에서도 부공간 기반 기법은 각 해상도 (angular resolution)가 높아 정확한 도래각 추정이 가능하다. MUSIC (multiple signal classification) 알고리즘은 가장 중요한 부공간 기법중 하나로, 특이값 분해를 통해 잡음 부공간을 형성한 후, 이를 이용해 표적의 도래각을 추정한다[2]. MUSIC 알고리즘 외에도 ESPRIT (estimation of signal parameters via rotational invariance techniques), DSPCM (direct signal space construction method) 등의 다양한 부공간 기법들이 연구되어왔다[3]-[6].

인공지능의 한 분야인 인공신경망은 인공신경망은 생물의 신경망을 모방한 기계학습 시스템으로, 기본적으로 퍼셉트론 신경망 (perceptron neural network)을 이용한다. 최근에는 딥러닝 (deep learning)으로 발전하여 합성곱 신경망 (convolutional neural network), 재귀 신경망 (recurrent neural network)으로까지 발전하여 다양한 곳에서 활용이 되고 있는 상황이다[7].

이러한 인공신경망을 도래각 추정 시스템에 접목하는 연구가 진행되고 있는 상황이다[8]. 인공신경망을 이용해 도래각을 추정하는 최근 연구[9]에서는 수신한 신호의 자기상관행렬을 추정하여 이를 입력데이터로 사용한다. 또한 전체 도래각 범위를 구간별로 나눈 뒤 각 구간별로 조향하여 탐지를 하는데, 이 경우 좁은 범위에서 표적을 탐지하기 때문에 학습 난이도를 줄일 수 있다고 한다. 그러나 학습 시 사용한 데이터의 SNR 환경과 다른 환경에서 표적의 도래각을 추정할 경우 성능이 감소하는 문제가 있다.

제안하는 알고리즘은 자기상관행렬에서 잡음성분을 제거하는 과정을 통해 단일 SNR 환경에서 학습을 완료한 시스템을 다양한 SNR 환경에서 관측을 수행해도 성능감소를 최소화 할 수 있다. 또한 첫 번째 단계에서 전체 범위의 표적의 후보 위치들을 산출하고, 두, 세 번째 단계에서 도래각 시프트 과정을 이용해 표적의 후보 위치 근처의 좁은 범위에서만 탐지를 수행하기 때문에 학습 난이도가 더욱 낮고, 정밀한 도래각 추정이 가능하다. 또한 제안하는 알고리즘과 MUSIC, ESPRIT, DSPCM 알고리즘과의 평균제곱근오차 (RMSE; root mean square error)를 비교하고, 도래각 추정에서 RMSE의 이론적 하한인 CRB

(Cramer-Rao bound)와도 비교하여 제안하는 알고리즘의 성능을 보다 객관적으로 검증하였다. 그 결과, 제안하는 알고리즘은 효율적인 학습과 탐지가 가능한 것 뿐만 아니라, 성능 면에서도 SNR이 낮고, 표적간 도래각 차이가 작은 열악한 관측환경 하에서 좋은 성능을 나타낸다.

본 논문의 구성은 다음과 같다. 2장에서는 시스템 모델과 제안하는 알고리즘에 대한 설명을 하고, 3장에서는 제안하는 알고리즘에서 사용하는 퍼셉트론의 수, 활성화함수, 비용함수 등 실제적으로 구현하기 위한 방법을 제시하며, 4장에서는 시뮬레이션을 이용해 다른 부공간 기법들과 CRB와의 성능을 비교하여 검증하며, 5장에서는 본 논문의 결론을 맺는다.

II. 시스템 모델

본 논문에서 우리는 [10]의 II장에서 서술한 unconditional -model assumption을 사용한다. 이 모델은 도래각 추정 연구에서 주로 사용하는 모델이다. 먼저 N 개의 안테나들이 d 간격으로 균일하게 배치되어 있는 균등 선형배열안테나가 있다고 가정하자. 또한 K 개의 표적으로부터 비롯된 파장 λ 의 협대역 원거리장 (far-field) 신호 $s_0(t), \dots, s_k(t)$ 가 배열안테나에 인입된다고 가정하자. 여기서 시간 인덱스 t 는 정수이며, 단위는 샘플링 주기 T_s 이다. 또한 K 개 표적의 도래각들을 $\theta_0, \dots, \theta_K$ 라 하자. 그러면, 시스템 모델은 다음 식 (1)과 같이 표현할 수 있다.

$$\mathbf{x}(t) = \mathbf{A}\mathbf{s}(t) + \mathbf{n}(t) \tag{1}$$

여기서 $\mathbf{x}(t) = [x_0(t), \dots, x_{N-1}(t)]^T$ 는 N 개의 안테나에 받아지는 신호 벡터이며, $\mathbf{s}(t) = [s_0(t), \dots, s_{K-1}(t)]^T$, $\mathbf{n}(t)$ 는 AWGN (additive white gaussian noise) 벡터, \mathbf{A} 는 (n, k) 성분이 $e^{j2\pi(n-1)d\cos(\theta_k)/\lambda}$ 인 $N \times K$ 차원 조향행렬이다. 표적의 수 K 는 알고있다고 가정하며, 안테나간 거리 d 는 $\lambda/2$ 로 설정하자.

또한 벡터 $\mathbf{s}(t)$ 와 $\mathbf{n}(t)$ 는 다음과 같은 성질 (2), (3)을 만족하는 랜덤 프로세스라 하자.

$$E[\mathbf{s}(t)\mathbf{s}(\tau)^H] = \mathbf{P}\delta_{t,\tau}, E[\mathbf{s}(t)\mathbf{s}(\tau)^T] = \mathbf{O} \tag{2}$$

$$E[\mathbf{n}(t)\mathbf{n}(\tau)^H] = \eta\mathbf{I}\delta_{t,\tau}, E[\mathbf{n}(t)\mathbf{n}(\tau)^T] = \mathbf{O} \tag{3}$$

여기서 $\delta_{t,\tau}$ 는 크로네커 델타 함수, \mathbf{P} 는 음이 아닌 실수를 성분으로 갖는 대각행렬, η 는 잡음파워, \mathbf{I} 는 기본행렬, \mathbf{O} 는 영행렬을 나타낸다.

안테나에 인입된 신호들을 도래각 추정 시스템에 입력하기 위하여, 자기상관행렬 \mathbf{R} 을 다음 식(4)와 같이 추정해야 한다.




그림 1. 제안하는 알고리즘의 처리 과정
Fig. 1. process diagram of proposed algorithm.

$$\mathbf{R} \approx \frac{1}{T} \sum_{t=0}^{T-1} \mathbf{x}(t)\mathbf{x}(t)^H \quad (4)$$

여기서 T 는 스냅샷수이다.

III. 3단계 인공신경망 도래각 추정 알고리즘

본 논문에서 제안하는 알고리즘은 3단계의 인공신경망을 이용하여 도래각을 추정한다. 알고리즘의 전체적인 처리과정은 그림 1.과 같다. 우선 자기상관행렬 \mathbf{R} 에 전처리과정을 수행한 후 데이터화하여 인공신경망에 입력할 준비를 한다. 전처리과정에서는 우선 \mathbf{R} 에서 잡음과 위 행렬인 $\eta\mathbf{I}$ 를 제거하여 $\tilde{\mathbf{R}}$ 로 만들어준다. 해당 과정은 식 (5)와 같다.

$$\tilde{\mathbf{R}} = \mathbf{R} - \eta\mathbf{I} \quad (5)$$

여기서 잡음과 위 η 는 표적이 없는 상황에서 관측을 통해 추정할 수 있다.

이렇게 잡음과 위를 제거하면, 자기상관행렬에서 신호성분만 남기 때문에, 다양한 SNR 환경에서도 표적의 위치가 같다면, 자기상관행렬은 같은 형태가 된다. 따라서 잡음과 위를 제거하는 과정을 통해, 단일 SNR 환경에서 학습한 모델을 다양한 SNR 환경의 표적 도래각을 추정하는데 사용할 수 있다. 추가적으로, $\tilde{\mathbf{R}}$ 의 윗대각성분과 대각성분만을 취하여 $N(N+1)/2$ 차원 벡터로 만들어준다. 이 과정은 토폴리츠 (toeplitz) 구조를 가지는 자기상관행렬의 중복된 성분들을 제거하기 위해 필요하다. 마지막으로, 벡터화한 $\tilde{\mathbf{R}}$ 의 실수부와 허수부를 나누어 $N(N+1)$ 차원 벡터 $\tilde{\mathbf{R}}_{vec}$ 로 만들어 인공신경망에 입력하기 위한 데이터로 사용한다.

그림 1.의 좌상단과 같이, 제안하는 알고리즘의 첫 번째 단계는 1개의 은닉층을 가진 퍼셉트론 신경망이다. 이때 (20°, 160°) 범위에서 표적들의 대략적인 도래각을 추정한다. 이 인공신경망은 $\tilde{\mathbf{R}}_{vec}$ 을 입력받아 141차원 출력 벡터 $\mathbf{l}_{out}^{(1)}$ 을 출력한다. 학습에 사용하는 참값 라벨 벡터 $\mathbf{l}_{true}^{(1)}$ 은 (20°, 160°) 범위의 각도를 1°단위로 양자화하고, 표적이 있는 위치에 해당하는

성분은 1, 나머지는 0이다. 예를들어, 두 개의 표적이 각각 [23°, 150°]에 있다고 가정하자. 그러면 $\mathbf{l}_{true}^{(1)}$ 은 4번째와 130번째 성분만 1이고, 나머지 성분은 0인 141차원 벡터가 된다. 마지막으로 1단계에서는 $\mathbf{l}_{out}^{(1)}$ 를 도래각 벡터인 $\tilde{\boldsymbol{\theta}}$ 로 바꿔준다. 이때, 표적의 위치 외에 인접한 위치를 표적이 있다고 인식하는 경우가 있으므로, 표적의 위치 후보를 $2K$ 개만큼 선택한다.

그림 1.의 우상단과 같이, 제안하는 알고리즘의 두 번째 단계는 1개의 은닉층을 가진 퍼셉트론 신경망과 도래각 시프트 과정으로 이루어져 있다. 두 번째 단계에서는 도래각 벡터 $\tilde{\boldsymbol{\theta}}$ 에 표적이 정말 존재하는지 여부를 판단하여 이를 $\hat{\boldsymbol{\theta}}$ 로 개선한다. 우선 첫 번째 단계에서 추정된 $\tilde{\boldsymbol{\theta}}$ 의 각 성분들 $\tilde{\theta}_k$ 가 90°에 위치하도록 도래각 시프트 과정을 거친다. 도래각 시프트는 다음 식 (7)을 이용해 이루어진다.

$$(\tilde{\mathbf{R}}_{vec})_{sft} = \tilde{\mathbf{R}}_{vec} \circ (\mathbf{A}_{sft}\mathbf{A}_{sft}^H)_{vec} \quad (7)$$

여기서 \circ 는 아다마르 곱 (hadamard product) 이며 \mathbf{A}_{sft} 는 N 차원 조향벡터로 n 번째 성분은 $e^{j2\pi(n-1)d\cos(90+\theta_{sft})/\lambda}$ 이다. θ_{sft} 는 시프트하고자 하는 각도이다. 또한 $(\mathbf{A}_{sft}\mathbf{A}_{sft}^H)_{vec}$ 는 $(\mathbf{A}_{sft}\mathbf{A}_{sft}^H)$ 를 전처리과정과 유사하게 중복되는 성분을 제거하고 벡터화한 것이다. 이때, 실수부와 허수부는 나누지 않으며, $\tilde{\mathbf{R}}_{vec}$ 또한 실수부와 허수부를 합친 복소벡터로 만든 뒤, 아다마르 곱을 하고 난 뒤에 실수부와 허수부를 나눈다.

이후 2단계 과정의 인공신경망 부분은 (87.5°, 92.5°) 범위에서 표적의 유무를 판별한다. 학습에 사용하는 참값 라벨 벡터는 2차원 벡터로, (87.5°, 92.5°) 범위에 표적이 없으면 (1, 0), 표적이 있으면 (0, 1)이다. 도래각 시프트 과정은 학습 데이터의 도래각 배치 경우의 수를 줄일 수 있어 상대적으로 적은 데이터로도 시스템을 구축할 수 있으며, 5°라는 제한된 범위에 학습을 집중할 수 있어 모든 범위에서 학습을 하는 것보다 효율적이다.

그림 1.의 하단은 세 번째 단계로 도래각 시프트 과정과 4개의 은닉층을 가진 퍼셉트론 신경망으로 이루어져 있다. 세 번째 단계에서는 두 번째 단계에서 개선한 $\tilde{\boldsymbol{\theta}}$ 를 보다 정밀하게 갱신한 최종 도래각 $\hat{\boldsymbol{\theta}}$ 을 도출한다. 도래각 시프트 과정은 두 번째 단계와 동일하나 θ_{sft} 를 $\tilde{\boldsymbol{\theta}}$ 의 성분들을 바탕으로 만든다. 학습에 사용하는 참값 라벨 벡터 $\mathbf{l}_{true}^{(3)}$ 은 301차원 벡터로 (88.5°, 91.5°)의 3° 범위를 0.01° 단위로 양자화한 벡터이다. 첫 번째 단계의 참값 라벨 벡터 $\mathbf{l}_{true}^{(1)}$ 와 유사하게 해당 위치에 표적이 있으면 해당 자리만 1, 나머지는 0이 된다.

전체적인 알고리즘을 설명하기 위해 K 개의 표적이 $[\theta_0, \theta_1, \dots, \theta_{K-1}]$ 에 있는 상황에서 배열 안테나의 수신 신호벡터 $\mathbf{x}(t), \dots, \mathbf{x}(t+T-1)$ 을 획득하여 자기상관행렬 \mathbf{R} 을 만들었다고 가정하자. 우선 \mathbf{R} 에 전처리과정을 수행하여 $\tilde{\mathbf{R}}_{vec}$ 로

만들어준다. 그 후 첫 번째 단계에 $\tilde{\mathbf{R}}_{vec}$ 을 입력하여 $\mathbf{l}_{out}^{(1)}$ 을 산출한다. 그리고 $\mathbf{l}_{out}^{(1)}$ 벡터의 성분 중 가장 큰 성분들의 인덱스를 표적 위치 후보로 보고 $2K$ 개 선택한다. 이를 바탕으로 $\tilde{\boldsymbol{\theta}}$ 를 만드는데, 이때 인접한 표적 위치 후보들이 2° 내에 있다면 이를 하나로 합친다. 예를들어 표적 위치 후보가 $(45^\circ, 61^\circ, 62^\circ, 134^\circ)$ 라면 이를 $(45^\circ, 61^\circ, 134^\circ)$ 로 만들어주는 것이다. 이는 이후 단계에서 불필요한 연산을 줄이기 위한 것이다. 이후 두 번째 단계에서는 $\tilde{\mathbf{R}}_{vec}$ 에 도래각 시프트 과정을 수행하여 $\tilde{\boldsymbol{\theta}}$ 의 성분들이 각각 90° 에 오도록 시프트 한 뒤, 해당 위치에 표적의 존재여부를 파악한다. 이 과정을 $\tilde{\boldsymbol{\theta}}$ 의 성분 수만큼 반복하여 $\hat{\boldsymbol{\theta}}$ 를 획득한다. 마지막으로 세 번째 단계에서도 마찬가지로 $\hat{\boldsymbol{\theta}}$ 를 이용하여 도래각을 시프트하고, 정밀하게 추정된 도래각 벡터 $\hat{\boldsymbol{\theta}}$ 를 산출한다.

IV. 실제적 구현

4장에서는 제안하는 알고리즘을 실제적으로 구현하기 위해 어떠한 데이터셋이 필요한지, 또한 각 단계별 인공신경망을 구축하기 위한 사항들을 자세히 서술하려 한다.

제안하는 알고리즘을 학습하기 위해, 우리는 각 단계별로 1백만개의 데이터를 사용하였다. 데이터는 시스템 모델을 바탕으로 시뮬레이션을 통해 생성하였으며, SNR을 0dB로 설정하였다. 첫 번째 단계에서는 $(20^\circ, 160^\circ)$ 사이의 범위에 K 개의 물체가 랜덤한 위치에 있는 데이터와 해당 위치만 1이고 나머지는 0을 성분으로 갖는 141차원 참값 라벨 벡터 $\mathbf{l}_{true}^{(1)}$ 를 사용한다. 두 번째 단계에서는 두 종류의 데이터를 사용하는데 그중 하나는 $(87.5^\circ, 92.5^\circ)$ 범위에 하나의 물체가 있고, 나머지 $K-1$ 개의 물체들은 해당 범위 밖에 있는 것이다. 나머지 한 종류는 K 개의 물체들이 모두 해당 범위 밖에 있는 것이다. 이는 해당 범위 내에 표적이 있는지 없는지 여부를 판단하기 위한 데이터이기 때문이다. 참값 라벨 벡터 $\mathbf{l}_{true}^{(2)}$ 는 전자의 경우 $(0, 1)$, 후자의 경우 $(1, 0)$ 을 사용한다. 세 번째 단계에서는 1개의 물체가 $(88.5^\circ, 91.5^\circ)$ 에 있고, $K-1$ 개의 물체들은 해당 범위 밖에 있는 데이터와 해당 범위에 있는 물체의 도래각에 대응되는 위치만 1이고 나머지는 0인 참값 라벨 벡터 $\mathbf{l}_{true}^{(3)}$ 를 사용한다.

제안하는 알고리즘을 구현할 때에는 구글에서 발표한 오픈소스 라이브러리인 텐서플로우 1.9.0 버전[11]를 사용하였다. 첫 번째 단계는 2층 퍼셉트론 신경망으로, 각 층마다 500개의 퍼셉트론으로 설정하였으며, 활성화함수는 시그모이드 함수를 이용하였다. 비용함수는 RMSE로 설정하였다. 또한 모든 학습변수들은 평균이 0이고 표준편차는 0.1로 초기화하였다. 두 번째 단계 역시 2층 퍼셉트론 신경망이며, 각 층마다 500개의 퍼셉트론으로 설정하였다. 활성화함수는 입력 층에서는 시그모이드

함수, 출력 층에서는 소프트맥스 함수를 이용하였다. 비용함수는 교차 엔트로피로 설정하였으며, 모든 학습변수들은 평균 0, 표준편차 0.1로 초기화하였다. 세 번째 단계는 제안하는 알고리즘의 가장 핵심이 되는 부분으로, 퍼셉트론 신경망과 합성곱 신경망 등을 다양하게 조합하여 그 성능을 시험해본 결과 5층 퍼셉트론 신경망의 성능이 가장 우수했다. 따라서 세 번째 단계는 5층 퍼셉트론으로 각 층마다 500개의 퍼셉트론으로 설정하였으며, 활성화함수는 입력층부터 4층까지는 ReLU (rectify linear unit) 함수, 출력층에서는 소프트맥스 함수를 이용하였다. 비용함수는 교차 엔트로피로 설정하였으며 모든 학습변수들은 평균 0, 표준편차 0.1로 초기화하였다. 모든 단계에서 우리는 학습 데이터들을 랜덤하게 섞고, 100개씩 취하여 학습하는 배치학습을 진행하였으며, 학습률은 10^{-3} 으로 설정하였다. 학습 알고리즘으로는 adam optimizer[10]을 사용하였으며, 학습은 5 epoch 진행하였다.

V. 성능 검증

5장에서는 제안하는 알고리즘의 성능을 검증하기 위해 시뮬레이션을 통해 도래각 추정 결과를 도출하고, 다른 도래각 추정 기법들과 비교하여 검증하려 한다.

비교하려는 기법들은 부공간 기반 기법인 MUSIC[2], ESPRIT[3], DSPCM[6]이며 그 외에 도래각 추정 기법의 이론적 하한인 CRB(Cramer-Rao bound; [1]의 Appendix B)와도 비교해보았다. 시뮬레이션에서는 20개의 안테나, -8dB에서 6dB SNR 환경에서 진행하였다. 표적은 2개 표적이 각각 $[85^\circ, 95^\circ]$, $[88^\circ, 94^\circ]$ 에 위치한 것과 4개 표적이 각각 $[75^\circ, 85^\circ, 95^\circ, 105^\circ]$, $[75^\circ, 88^\circ, 94^\circ, 105^\circ]$ 에 위치한 것, 총 4가지 경우를 가정하여 도래각을 추정하였다. 또한 각각의 경우에서 1만개의 데이터를 생성하여 도래각을 추정한 결과를 RMSE로 계산하였다. 제안하는 알고리즘은 2개 표적일 때와 4개 표적일 때 각각 독립적으로 학습하여 도래각을 추정하였으며, 100회의 시스템을 구축한 뒤, 가장 좋은 성능을 보이는 회차의 시스템의 성능을 선택하였다. II 행렬을 도출하여 도래각을 탐색하는 부공간 기법인 MUSIC과 DSPCM 기법에서는 탐색 단위를 0.01°로 설정하였다.

그림 2.에는 제안하는 알고리즘과 MUSIC, ESPRIT, DSPCM의 성능과 CRB를 비교한 그래프이다. 그림 2.의 a, b는 2개 표적인 경우이며, c, d는 4개 표적인 경우를 나타낸다. 표적이 $[85^\circ, 95^\circ]$ 에 위치한 경우 (그림 2.의 a)에는 제안하는 알고리즘과 MUSIC 알고리즘이 CRB에 가까운 우수한 성능을 보인다. SNR 2dB 이상에서는 MUSIC 알고리즘의 RMSE가 약간 더 낮은 우수한 성능을 보이지만, 2dB 미만에서는 제안하는 알고리즘의 성능이 약간 더 우수하다. 표적이 $[88^\circ, 92^\circ]$ 에 위치한 경우 (그림 2.의 b) SNR 2dB 이상에서는 MUSIC 알고리즘의 성능이 더 우수하지만 2dB 미만에서는 제안하는 알고

리듬의 성능이 더 우수하며, 심지어 CRB에 아주 가까운 것을 볼 수 있다. 표적이 $[75^\circ, 85^\circ, 95^\circ, 105^\circ]$ 에 있는 경우(그림 2.의 c) 제안하는 알고리즘과 MUSIC 알고리즘의 RMSE가 매우 가까우며, CRB에도 가깝지만 MUSIC 알고리즘이 약간 더 우수한 성능을 보인다. 표적이 $[75^\circ, 88^\circ, 92^\circ, 105^\circ]$ 에 있는 경우(그림 2.의 d) -3dB 이하에서는 제안하는 알고리즘의 성능이 MUSIC보다 우수한 것을 볼 수 있으며, 그 이상의 SNR에서는 MUSIC의 성능이 더 우수하다. ESPRIT 알고리즘의 경우 SNR이 높은 경우에만 MUSIC과 CRB에 가까운 우수한 성능을 보였으며, DSPCM 알고리즘은 저연산량 알고리즘으로 RMSE는 다른 기법들에 비해 높게 나타났다. 결론적으로, 제안하는 알고리즘은 표적간 거리가 가까거나 SNR이 낮은 열악한 관측환경에서 우수한 성능을 나타낼 수 있다.

계산복잡도 측면에서 각 알고리즘을 살펴보기 위해, 안테나 개수 N , 표적의 개수 K , 그리고 제안하는 알고리즘에서 사용하는 각 신경망 층의 퍼셉트론 수 P 를 고려하자. 또한 MUSIC 알고리즘, DSPCM 알고리즘과 같이 II 행렬을 도출한 뒤 도래각을 탐색하는 알고리즘의 경우 탐색 방법에 따라 연산량이 달라지므로 탐색 시간은 고려하지 않는다고 가정하였고, 연산량은 Big-O 표기법으로 표기하였다. MUSIC 알고리즘과 ESPRIT 알고리즘의 경우 특이값분해, 고유값분해 과정이 있어 계산복잡도는 $O(N^3)$ 와 같다. 다만 ESPRIT 알고리즘은 탐색 과정이 없어 복잡도는 MUSIC보다 낮다고 할 수 있다. DSPCM 알고리즘의 경우 특이값분해와 같은 고비용 연산을 사용하지 않아 계산복잡도는 $O(K^2N)$ 이다. 표적의 개수 K 는 부공간 기반 기법을 사용할 경우 안테나 개수 N 보다 작아야 하므로 계산복잡도 면에서는 다른 알고리즘에 비해 좋다고 할 수 있다. 제안하는 알고리즘의 경우 세 번째 단계 5층 퍼셉트론 신경망에 가장 많은 연산이 필요하며 계산복잡도는 $O(P^2)$ 이다. 본 논문의 시뮬레이션에서 설정한 파라미터 상으로는 $P^2 > N^3$ 이다. 따라서 제안하는 알고리즘은 계산복잡도 측면에서는 우수하다고 할 수는 없지만 연산지수가 제곱과 세제곱으로 시스템의 규모가 커질수록 연산량 격차는 줄어들 것으로 판단된다.

VI. 결론

본 논문에서 우리는 3단계 인공신경망을 이용한 도래각 추정 기법을 제안하였다. 제안하는 알고리즘은 잡음제거 과정을 통해 단일 SNR 환경에서 학습한 시스템을 다양한 SNR 환경에 적용하여도 성능이 크게 감소하지 않으며, 첫 번째 단계에서 전체 범위의 표적의 위치 후보들을 산출한 후, 두, 세 번째 단계에서 도래각 시프트 과정을 이용하여 해당 후보들이 포함된 좁은 범위에서 정밀하게 표적의 도래각을 추정한다. 두, 세 번째 단계는 좁은 범위에서 표적의 도래각을 산출하므로 학습 난이도가 낮으며, 전체 범위를 조항하는 것이 아니라 효율적이다.

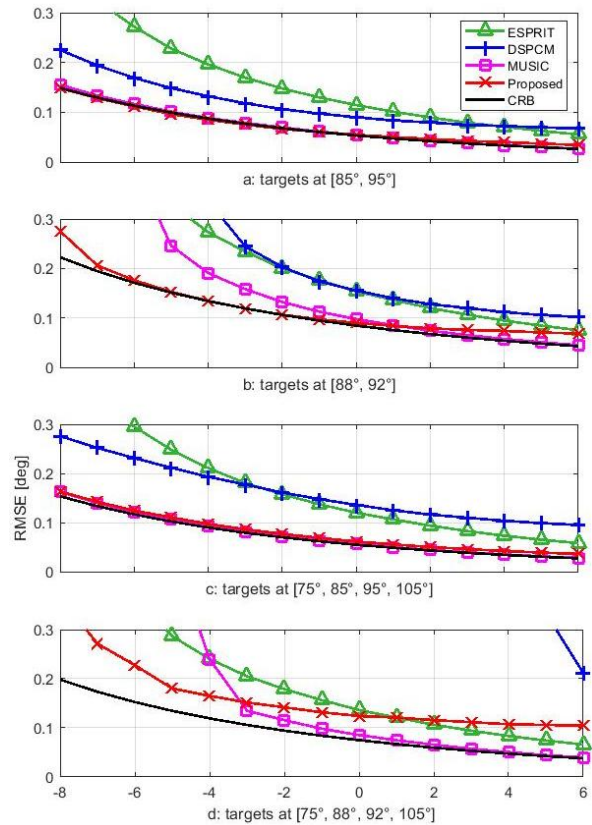


그림 2. 제안하는 알고리즘과 각종 부공간 기반 기법, CRB의 성능 그래프

Fig. 2. performance graphs of proposed algorithm, subspace-based methods and CRB.

또한 제안하는 알고리즘의 성능을 다른 부공간 기법들과 비교하고, 특히 CRB와도 비교하여 보다 객관적으로 검증하였다. 그 결과 제안하는 알고리즘은 학습 및 탐지의 효율성 외에도 표적간 도래각 차이가 작거나 SNR이 낮은 열악한 관측환경에서 좋은 성능을 나타내는 것을 보임으로써, 도래각 추정 분야에서 딥러닝 기반 기법의 활용 가능성을 보였다.

향후 우리는 제안하는 알고리즘의 효율성을 향상시키기 위해 층을 더 쌓아 정밀도를 높일 수 있는지 살펴보고, 퍼셉트론 신경망 외에도 다른 신경망과 결합하여 성능을 높일 수 있는지, 그리고 연산량을 줄이기 위한 방법을 모색하는 등 후속연구를 계속 진행할 계획이다. 추가적으로 클러스터, 간섭 등이 존재하는 환경에서의 관측 성능을 살펴보고 보다 실제적인 환경에서도 딥러닝을 이용한 도래각 추정이 가능한지를 살펴볼 계획이다.

Acknowledgments

본 연구는 2018년도 정부(교육부)의 재원으로 한국연구재단 기본연구지원사업(과제번호: NRF-2018R1D1A1B07045719)의 지원을 받아 수행되었습니다.

References

- [1] P. Stoica, and R. L. Moses, *Spectral Analysis of Signals*, Upper Saddle River, NJ: Prentice-Hall, ch. 6, pp. 263-273, 2005.
- [2] R. Schmidt, "Multiple emitter location and signal parameter estimation," *IEEE Transactions on Antennas and Propagation*, Vol. 34, No. 3, pp. 276-280, Mar. 1986.
- [3] R. Roy, and T. Kailath, "ESPRIT-estimation of signal parameters via rotational invariance techniques," *IEEE Transactions on Acoustics, Speech, and Signal Processing*, Vol. 37, No. 7, pp. 984-995, Jul. 1989.
- [4] J. Xin, and A. Sano, "Computationally efficient subspace-based method for direction-of-arrival estimation without eigendecomposition," *IEEE Transactions on Signal Processing*, Vol. 52, No. 4, pp. 876-893, Apr. 2004.
- [5] B. G. Byun, and D. S. Yoo, "Improved direction of arrival estimation based on coprime array and propagator method by noise power spectral density estimation," *The Journal of Korea Navigation Institute*, Vol. 20, No. 4, pp. 367-373, Aug. 2017.
- [6] D. S. Yoo, "A low complexity subspace-Based DOA estimation algorithm with uniform linear array correlation matrix subsampling," *International Journal of Antennas and Propagation*, Vol. 2015, Article ID. 323545, pp. 1-10, Nov, 2015.
- [7] L. Deng, "A tutorial survey of architectures algorithms and applications for deep learning," *APSIPA Transactions on Signal and Information Processing*, Vol. 3, No. 2, pp. 1-29, Jan. 2014.
- [8] S. Mishra, R. Yadav, and R. Singh, "A survey on applications of multi layer perceptron neural networks in DOA estimation for smart antennas," *International Journal of Computer Applications*, Vol. 83, No. 17, pp. 22-28, Dec. 2013.
- [9] M. K. Cho, D. H. Lee, S. Y. Baek, "Performance evaluation and system implementation of a radio-wave direction finding system based on neural networks," *The Journal of Korean Institute of Communication and Information Science*, Vol. 42, No. 10, pp. 1896-1903, Oct. 2017.
- [10] P. Stoica, and A. Nehorai, "Performance study of conditional and unconditional direction-of-arrival estimation," *IEEE Transactions on Acoustics, Speech, and Signal Processing*, Vol. 38, No. 10, pp. 1783-1795, Oct. 1990.
- [11] M. Abadi, A. Agarwal, B. Paul, et al. (2016, Mar). Tensorflow: large-scale machine learning on heterogeneous distributed systems. Available: <https://arxiv.org/abs/1603.04467>.



박 선 배 (Sun-Bae Park)

2015년 2월 : 홍익대학교 전자·전기공학부 (공학사)
 2015년 3월 ~ 2017년 2월 : 홍익대학교 대학원 전자·정보·통신공학과 (공학석사)
 2017년 3월 ~ 현재 : 홍익대학교 대학원 전자전기공학과 박사과정
 ※관심분야 : 인공지능, 신호처리, 패턴인식, 레이더신호처리, 영상처리 및 필터링 이론



유 도 식 (Do-Sik Yoo)

2002년 2월 : 미시간대학교 전자컴퓨터공학과 (공학박사)
 2006년 9월 ~ 2011년 3월 : 홍익대학교 전자전기공학부 조교수
 2011년 4월 ~ 2016년 3월 : 홍익대학교 전자전기공학부 부교수
 2016년 4월 ~ 현재 : 홍익대학교 전자전기공학부 교수
 ※관심분야 : 통신 및 신호처리, 정보이론, 어레이신호처리, 영상처리 및 필터링, 신호처리, 변환광학 등