

# 기계학습 기반의 상관행렬을 이용한 신호 도래방향 추정 알고리즘 연구

유호근, 송수현, 정욱, 이재훈  
고려대학교

hogeunyoo@korea.ac.kr, ssh6328@korea.ac.kr, oc0110@korea.ac.kr, ejhoon@koera.ac.kr

## Direction of Arrival Estimation Algorithm Using Machine Learning-Based Correlation Matrix

Yoo Hogeun, Song Suhyoun, Chung Ook, Lee Jaehoon  
Korea Univ.

### 요약

본 연구는 기계학습 기반의 Fully connected Neural Network(FNN) 모델을 이용하여 저차원의 상관행렬을 고차원의 상관행렬로 추정하는 알고리즘을 제안하고, 이를 통해 신호 도래방향 추정의 분해능을 개선하였다. 실험 결과, 제안된 방법이 기존 방법보다 높은 분해능을 제공함을 확인하였다.

### I. 서론

신호 도래방향 추정 알고리즘은 무선 통신 시스템, 레이더 시스템, 음향 및 음성 처리 등 다양한 응용 분야에서 중요한 기능을 제공한다. 신호 도래방향 추정을 위해 많은 기술이 연구되었으며 그 중 MUSIC(Multiple Signal Classification) 및 ESPRIT(Estimation of Signal Parameters via Rotational Invariance Techniques)와 같은 부분공간 기반 추정 방법이 높은 분해능을 갖는 것으로 알려져 있다. 또한, ANN(Artificial Neural Network)을 기반으로 하는 기계 학습 방식도 연구되어 왔으며 기존 신호 도래방향 추정 알고리즘 보다 계산 속도가 신속한 것으로 알려져 있다[1]. 본 연구에서는 상관행렬을 이용하는 기계학습 기반의 신호 도래 방향 추정을 통해 분해능을 향상시켰다.

### II. 본론

#### 1. 신호 모델

본 논문에서는 그림 1 과 같이 ULA(Uniform Linear Array) 안테나 환경을 가정하였으며, M 개의 간격 d 를 갖는 무지향성 안테나 배열에,  $\{\theta_1, \theta_2, \dots, \theta_L\}$  방향에서 L 개의 far-field uncorrelated narrowband line-of-sight 신호가 도달할 때, M 개의 안테나에 수신된 기저대역 신호를 다음과 같이 표현할 수 있다.

$\mathbf{y}(t) = \sum_{l=1}^L \mathbf{a}(\theta_l) s_l(t) + \mathbf{n}(t)$   $s_l(t)$  는 각 신호원의 신호 파형이고,  $\mathbf{a}(\theta_l), \mathbf{n}(t)$  는 아래와 같다.

$$\mathbf{a}(\theta_l) = \left[ 1, e^{-j\frac{2\pi}{\lambda}d \sin \theta_l}, \dots, e^{-j\frac{2\pi}{\lambda}(M-1)d \sin \theta_l} \right]^T$$

$\mathbf{n}(t)$ : identically distributed complex AWGN




그림 1. M 개의 안테나를 갖는 ULA 구조

#### 2. 희소 공간 스펙트럼

신호 도래방향 추정을 위해 희소 공간 스펙트럼을 활용한다. 잠재적인 신호 도래 방향을 일정한 간격으로 샘플링하여 얻은 이산 방향 집합  $\Phi = [\phi_1, \phi_2, \dots, \phi_K]^T$  에서 K 가 충분히 크면 실제 신호 도래방향이 포함된다. 이 때, 안테나 배열의 수신 신호를 다음과 같이 다시 표현할 수 있다.

$$\mathbf{y}(t) = \sum_{k=1}^K \mathbf{a}(\phi_k) \bar{\mathbf{s}}_k(t) + \mathbf{n}(t)$$

여기서,  $\bar{\mathbf{s}}_k(t)$  는 아래와 같다.

$$\bar{\mathbf{s}}_k(t) = \begin{cases} s_l(t), & \text{if } \phi_k = \theta_l \\ 0, & \text{otherwise} \end{cases}$$

수신 신호에 대한 공간 상관행렬 R 은 다음과 같다.

$$\begin{aligned} \mathbf{R} &= E[\mathbf{y}(t)\mathbf{y}^H(t)] \\ &= \sum_{k=1}^K \eta_k \mathbf{a}(\phi_k) \mathbf{a}^H(\phi_k) + \sigma_n^2 \mathbf{I}_M \end{aligned}$$

여기서,  $\eta_k = E[\bar{\mathbf{s}}_k(t)\bar{\mathbf{s}}_k^H(t)]$  는  $\phi_k$  에서의 신호의 세기이며, 신호의 도래방향에서 0 이 아닌 값을 갖는다. R 의 m 번째 열  $c_m$  은 아래와 같이 정의하면,

$$c_m = \sum_{k=1}^K \eta_k \mathbf{a}(\phi_k) \mathbf{a}^H(\phi_k) \mathbf{e}_m + \sigma_n^2 \mathbf{I}_M \mathbf{e}_m$$

$$= [\mathbf{a}(\phi_1) \mathbf{a}^H(\phi_1) \mathbf{e}_m, \dots, \mathbf{a}(\phi_K) \mathbf{a}^H(\phi_K) \mathbf{e}_m] \boldsymbol{\eta} + \sigma_n^2 \mathbf{e}_m$$

$$= \mathbf{A}_m \boldsymbol{\eta} + \sigma_n^2 \mathbf{e}_m$$

$$\mathbf{c} = \text{vec}(\mathbf{R}) = [c_1^T, c_2^T, \dots, c_M^T]^T$$

$$= [\mathbf{A}_1; \mathbf{A}_2; \dots; \mathbf{A}_M] \boldsymbol{\eta} + \sigma_n^2 [\mathbf{e}_1; \mathbf{e}_2; \dots; \mathbf{e}_M] = \tilde{\mathbf{A}} \boldsymbol{\eta} + \sigma_n^2 \tilde{\mathbf{I}}_n$$

여기서  $\tilde{\mathbf{A}}, \tilde{\mathbf{I}}_n$ 는 아래와 같다.

$$\tilde{\mathbf{A}} = [\mathbf{a}_1^* \otimes \mathbf{a}_1, \mathbf{a}_2^* \otimes \mathbf{a}_2, \dots, \mathbf{a}_K^* \otimes \mathbf{a}_K]$$

$$\tilde{\mathbf{I}}_n = \text{vec}(\mathbf{I}_M) = [\mathbf{e}_1; \mathbf{e}_2; \dots; \mathbf{e}_M]$$

따라서, 최소 공간 스펙트럼을 아래와 같이 구할 수 있다[2].

$$\boldsymbol{\eta} \approx \tilde{\mathbf{A}}^H \mathbf{c}$$

### 3. 기계학습 기반의 신호 도래방향 추정 알고리즘

기존 전통적인 알고리즘의 경우 저차원의 상관행렬에서 다수의 신호 도래방향을 추정하는 것에 어려움이 있다. 본 논문에서는 기계학습 기반으로 저차원의 상관행렬을 DNN(Deep Neural Network) 모델을 적용하여 비선형적으로 고차원의 상관행렬로 추정하였다.

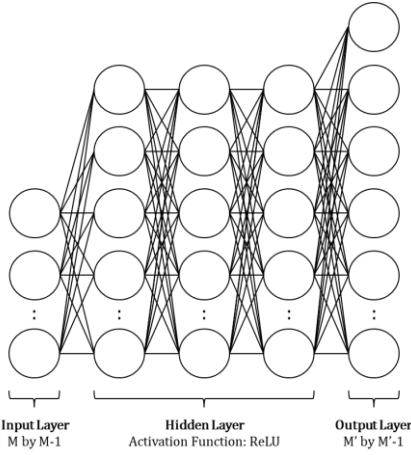



그림 2. 제안하는 FNN 모델 구조

본 논문에서 DNN 모델로 FNN(Fully connected Neural Network) 모델을 그림 2와 같이 제안하였다. 모델은 M 개 안테나에서 계산된 상관행렬  $\mathbf{R}$ 의 상부 삼각행렬에 대한 실수부와 허수부를 입력으로 갖는다. 출력으로는 확장된  $M'$  개 안테나에서 계산된 상관행렬의 상부 삼각행렬  $\mathbf{R}'$ 에 대한 실수부와 허수부를 출력으로 갖는다. 히든 레이어는  $N(N-1) (M \leq N \leq M')$  개의 노드를 갖는 선형 변환 Affine 레이어와, 각 히든 레이어 간의 비선형 활성화 함수로 ReLU(Rectified Linear Unit)를 연결하여 3 계층으로 적용하였다.


### 3. 실험 및 결과

제안한 모델을 다음의 조건으로 실험하였다. 특정 하이퍼파라미터는 베이지안 옵티마이저로 최적화하였다( $N=60$ , Epoch=50, mini batch size=256, Initial learn rate = 0.001). 모델에 대한 입력 및 출력 데이터로 다음의 조건을 고려하였다. 8 개와 64 개의 간격  $d = 0.5$  m의 ULA 안테나 배열에 SNR = 5 dB의 4 개의 무작위 도래방향을 갖는 신호가 도달하며, 각 안테나는 200 개의 스냅샷을 수집한다. 잡재 신호 도래 방향을  $0.1^\circ$  간격으로 샘플링 하고, 수신 신호에 대한 상관행렬  $\mathbf{R}$ 을 각각 입력과 출력으로 사용하여 지도학습을 수행하였으며, 학습을 위한 100,000 개의 데이터와,

검증을 위한 1,000 개의 데이터를 사용하였다. 학습된 모델을 바탕으로 신호 도래방향 추정 결과는 그림 3과 같다.



(a)



(b)

그림 3. (a) 입출력 상관행렬을 이용한 스펙트럼 (b) 제안된 모델로 추정한 상관행렬을 이용한 스펙트럼.

그림 3의 (a) 붉은 실선의 경우, 8 개의 안테나 배열에서 얻어진 상관행렬을 이용하여 최소 공간 스펙트럼을 구한 것으로, 각 신호의 도래방향을 추정하지 못하였다. 반면, 파란 실선의 경우, 64 개의 안테나 배열에서 얻어진 상관행렬을 이용한 최소 공간 스펙트럼을 보여주고 있다. 그림 3의 (b)는 8 개의 안테나 배열의 상관행렬로부터 FNN을 통해 확장된 상관행렬을 예측하고 이를 통해 구한 최소 공간 스펙트럼을 보여주고 있으며, 분해능이 향상되는 것을 보였다.

## III. 결론

본 논문에서는 FNN 모델을 적용한 신호 도래방향 추정 알고리즘을 제안하였다. 기존의 방법은 물리적인 안테나 개수로 인해 분해능이 제한되는 반면, 제안하는 방법은 기계 학습 기반으로 저차원의 상관행렬을 고차원의 상관행렬로 추정하여 분해능을 개선할 수 있음을 보였다. 향후 본 연구를 NSB(Null Steering Beamforming)에 적용하여 특정 방향으로부터의 간섭 신호를 제거하는 연구와, CNN, RNN 모델에 대한 성능 분석 및 각각의 모델에 대해 최적화를 수행하여 정확도 향상 및 계산 복잡도를 감소시키는 방법에 대한 추가 연구를 진행하고자 한다.

## 참고 문헌

- [1] N. J. G. Fonseca, M. Coudyser, J. -J. Laurin and J. -J. Brault, "On the Design of a Compact Neural Network-Based DOA Estimation System," in IEEE Transactions on Antennas and Propagation, vol. 58, no. 2, pp. 357-366, Feb. 2010
- [2] D. Malioutov, M. Cetin and A. S. Willsky, "A sparse signal reconstruction perspective for source localization with sensor arrays", IEEE Trans. Signal Process., vol. 53, no. 8, pp. 3010-3022, Aug. 2005.