

# 신경망 전파방향탐지 성능 시험 및 실 시스템 구현

조민경<sup>◊</sup>, 이대헌<sup>\*</sup>, 백선엽<sup>\*\*</sup>, 김웅희<sup>\*\*\*</sup>, 김종규<sup>\*\*\*\*</sup>

## Performance Evaluation and System Implementation of a Radio-Wave Direction Finding System Based on Neural Networks

Minkyung Cho<sup>◊</sup>, Dae Heon Lee<sup>\*</sup>, Seon Yeob Baek<sup>\*\*</sup>, Woong Hee Kim<sup>\*\*\*</sup>, Jong-Kyu Kim<sup>\*\*\*\*</sup>

### 요약

초연결 기반 Internet of Things(IoT) 시대가 도래함에 따라 우리 실생활에 직접적으로 연결된 공간에서 다양한 무선 IoT기기들이 활용되고 있다. IoT 기기들은 오프라인 환경의 센싱, 원격 조작 등 다양한 응용분야로 확장 가능한 이점도 있지만, 반대로 몰카나 도청장치로 이용되거나, 전파 혼선을 유도하는 간섭신호 발신 등 악의적인 목적으로 사용될 수 있어, 전파기기 위치를 식별·탐지하는 기술은 IoT시대에 중요한 기술 중 하나로 여겨지고 있다. 기존 전파발신원 방향탐지 알고리즘은 MUSIC<sup>[1,2]</sup>, RootMUSIC<sup>[3]</sup>, ESPRIT<sup>[4]</sup> 등의 수학적, 통계적 모델링을 이용한 방향탐지가 주를 이루었으나, 많은 계산을 요구하여 신경망 방향탐지기<sup>[5-8]</sup> 대안으로 연구되어 왔다. 본 논문에서는 기존 신경망을 통한 방향탐지 모델에 대해 살펴보고, 안테나의 개수, 학습 노이즈 레벨 등에 따른 신경망의 성능을 측정해 보았다. 또한, SDR 장비를 이용한 실 시스템 구축을 통해 신경망을 통한 방향탐지의 실제 적용가능성을 검증하였다.

**Key Words** : direction of arrival estimation, multiple signal classification, signal processing, artificial neural network, radical basis function, software defined radio

### ABSTRACT

Various IoT(Internet of Things) devices are being used directly in our daily life. However, these wireless devices can be abused as the purpose of wiretapping, hidden cameras, or radio interference. Therefore, a direction finding technique is one of important techniques in IoT era. The previous direction finding algorithms such as MUSIC, RootMUSIC, and ESPRIT are wildly used because of their robustness and high accuracy based on mathematical/statistical models. However, these techniques are required computational intensive operations(i.e. eigenvalue decomposition). Researchers, alternatively, have studied new direction finding algorithms based on neural networks. In this paper, we describe a neural network direction finding algorithm based on RBF and test the performance of the algorithm according to the number of antennas and noise levels. Finally, we have built a direction finding platform with SDR(software defined radio) equipment, and show that it works as well in real environment.

◊ First and Author : The Affiliated Institute of ETRI, mcho@nsr.re.kr, 정회원

\* The Affiliated Institute of ETRI, leedh@nsr.re.kr

\*\* The Affiliated Institute of ETRI, sybaek@nsr.re.kr

\*\*\* The Affiliated Institute of ETRI, whkim@nsr.re.kr

\*\*\*\* The Affiliated Institute of ETRI, contai@nsr.re.kr

논문번호 : KICS2017-04-131, Received April 30, 2017; Revised July 30, 2017; Accepted August 2, 2017

## I. 서 론

초연결 기반 Internet of Things(IoT) 시대가 도래함에 따라 우리 실생활에 직접적으로 연결된 공간에서 다양한 무선 IoT기기들이 활용되고 있다. IoT 기기들은 오프라인 환경의 센싱, 원격 조작 등 다양한 응용분야<sup>9,10</sup>로 확장 가능한 이점도 있지만, 반대로 몰카나 도청장치로 이용되거나, 전파 혼신을 유도하는 간섭신호 발신 등 악의적인 목적으로 사용될 수 있어, 전파기기 위치를 식별·탐지하는 기술은 IoT시대에 중요한 기술 중 하나이다.

기존 방향탐지 연구는 MUSIC(Multiple Signal Classification), Root-MUSIC, ESPRIT(Estimation of Signal Parameters via Rotational Invariance Techniques) 등 수학적 모델링 기반으로 다양하게 이루어져왔다<sup>11-14</sup>. 다만, 이러한 알고리즘들은 고유값분해(eigenvalue decomposition)와 같이 복잡한 연산을 요구하고, 정밀도(resolution)를 향상시키기 위해서 계산량을 늘려야 한다는 단점이 있다. 이로 인해 실시간 응용에는 적용이 힘들었다.

연구자들은 방향탐지에 대한 실시간성 요구가 증대됨에 따라 실시간 처리가 가능한 인공신경망(앞으로는 신경망) 방향탐지기법을 고려하기 시작하였다. 신경망방향탐지는 학습 시에는 많은 시간이 소요되지만, 학습이 완료된 후에는 실시간 방향탐지가 가능하여, 기존 기법 대비 효과적이다.<sup>15-18</sup>

본 논문은 신경망 방향탐지 성능 시험 및 실 시스템 구현에 관한 논문으로, 신경망 방향탐지 알고리즘 구현부터 안테나 개수, 노이즈레벨에 따른 성능을 테스트하였으며, 실제로 SDR(Software Defined Radio) 시스템 구축을 통해 실용가능성을 검증하였다. II장에서는 기존 방향탐지 연구동향, III장에서는 학습데이터 확보를 위한 신호 시뮬레이터 구성, IV장에서는 다양한 환경에서 신경망 방향탐지 성능을 테스트하고, 마지막으로 신경망 방향탐지의 실 시스템 적용 가능성을 타진하였다.

## II. 기존 연구

MUSIC알고리즘<sup>12</sup>은 Multiple Singal Classification의 약자로, 다중신호 방향탐지가 가능한 알고리즘이다. 특히 통계적으로 안정적이고 방향탐지 결과가 Optimal하다는 것이 증명되어 가장 범용적으로 사용되고 있다.

MUSIC알고리즘은 신호 부공간(signal subspace)

과 노이즈 부공간(noise subspace)이 서로 직교한다는 성질을 이용하여 신호의 입사 방향을 계산한다. 수식으로 표현하면,  $s(t)$ 를 송신 신호,  $n(t)$ 는 노이즈,  $x(t)$ 는 수신 신호, 안테나 개수를  $M$ , 실제 송신신호 개수를  $K$ 라 하고,  $A$ 는 각 안테나간 수신신호 위상차를 나타내는 지향행렬이라고 하면, 수신 신호는

$$x(t) = A s(t) + n(t) \quad (1)$$

로 나타낼 수 있고, 수신신호 공분산  $R$ 은

$$R = x(t) x(t)^H = A s(t) s(t)^H A^H + \delta^2 I \quad (2)$$

공분산 행렬을 고유분해(eigenvalue decomposition)하여 고유값(eigenvalue)을 계산하면, 잡음 대비 신호 크기 차이를 이용하여 고유값 분포로부터 다음과 같이 실제 신호 개수  $K$ 를 유추할 수 있다.

$$\lambda_1 > \lambda_2 > \dots \gg \lambda_{K+1} = \lambda_{K+2} = \dots = \lambda_M = \delta^2 \quad (3)$$

결과적으로, 잡음 부공간은  $M-K$ 개의 고유벡터(eigenvector)  $[e_{K+1}, e_{K+2}, \dots, e_M]$ 로 표시되고, 잡음 부공간과 입사신호의 방향이 서로 직교한다는 가정에 의해, 입사 신호 방향  $\Theta$ 는 다음 식

$$a(\Theta)^H E_N E_N^H a(\Theta) = 0 \quad (4)$$

을 만족시킨다.

입사 신호 방향  $\Theta$ 는 우리가 찾고자 하는 미지의 값이다. 각도 영역내에서 일정간격으로 각도를 대입하는 방법을 통해 값을 찾는다. 따라서, 방향 정밀도(resolution)를 높이기 위해서는 입사방향  $\Theta$ 를 세밀하게 조사해야 하고, 이에 따라 계산량이 늘어나는 단점이 발생한다. 또한, 이 모델링을 통한 방향탐지는 안테나 개수보다 작은 수의 신호 발신원들까지만 식별할 수 있는 제한을 가지고 있다.

RootMUSIC<sup>13</sup>은 MUSIC알고리즘에서 모든 입사 방위각을 세분화 하여 계산하는 단점을 방정식 해법을 통해 계산량을 줄인 기법이다.

ESPRIT<sup>14</sup>는 배열안테나를 2개 이상의 중첩된(overlapping) 서브 배열안테나로 재구성하고, 각각의 결과를 조합하여 방향을 탐지하는 기법이다. 예를 들면, 배열안테나의 안테나 개수가 총  $N$ 개라면, 처음 1번부터  $N-k$ 번 안테나를 하나의 배열안테나로 구성하고, 2번부터  $N-k+1$ 번까지는 2번째 배열안테나로 구성

하는 등 다수의 서브 배열안테나로 나온 결과를 평균하여 계산한다. 따라서, 특정 안테나에 노이즈가 심해도 안정적으로 방향계산이 가능하다.

신경망을 활용한 방향탐지 연구는 1987년부터 연구되어 온 분야이다.<sup>[5-8]</sup> Matsumoto<sup>[7]</sup>는 수신신호들의 상관 행렬(correlation matrix)을 계산하고, 그 행렬을 신경망 입력으로 주어 학습하였다. 해당 신경망은 두 단계로 나누어 방향 탐지를 하는데, 큰 영역을 먼저 찾는 탐지 단계(detection stage)를 수행하고, 탐지된 영역에서 더 정밀하게 각도를 예측하는 측정 단계(estimation stage)로 구분하였다. 예를 들면, 10°도 단위로 먼저 탐지하고, 탐지된 영역에서만 1°도 단위로 세밀하게 계산하는 방식이다.

CayLar<sup>[8]</sup> 알고리즘은 Matsumoto<sup>[7]</sup> 것과 유사하나, 중간에 필터링 단계를 삽입하여 총 3단계로 구현하였다. 필터링 단계의 역할은 다양한 방향에서 들어오는 전체 신호에서 탐지된 구간의 신호만을 필터링하여 측정(estimation) 단계로 전달하는 기능으로 학습을 통해 구현하였다.

참고로 본 연구는 MUSIC 등 기존 방향탐지 기법에 대해 안테나의 개수와 노이즈 레벨을 달리하여 성능시험을 수행하였으며, 기존 신경망 알고리즘에 대해서도 안테나 개수에 따른 학습/실험 노이즈레벨을 달리하여 성능 시험 수행과 실 시스템에 적용 가능성을 타진하였다.

### III. 학습 데이터 확보를 위한 시뮬레이터 구성

신경망 학습을 위해 학습데이터 확보가 선행되어야 한다. 본 논문에서는 시뮬레이터 구현을 통해 정밀한 학습데이터를 생성하고자 한다. 더불어 생성된 데이터를 기반으로 신경망 학습 데이터의 분포를 살펴보고, 추가적으로 기존 MUSIC, RootMUSIC, ESPRIT 알고리즘에 대해, 노이즈 및 안테나 개수에 따른 성능을 분석하고자 한다.

#### 3.1 시뮬레이터의 구성

신호발신원의 입사방향을 계산하기 위해 수신부 안테나들에 들어오는 신호의 도달 시간차(위상차)를 이용한다. 그림 1처럼, 발신된 신호가 각도  $\theta$ 로 입사한다면, 발신원 신호는 안테나 M, ..., 2, 1번 순으로 도달하게 된다. 1번 안테나와 2번 안테나 거리가 D라고 하면, 두 안테나 사이에 수신된 신호의 거리 차는  $D\sin\theta$ 가 되고, 위상차는 신호파장  $\lambda$ 로 나눈  $2\pi D\sin\theta / \lambda$ 다. 따라서, 수신신호의 위상차가 역으로 주어질

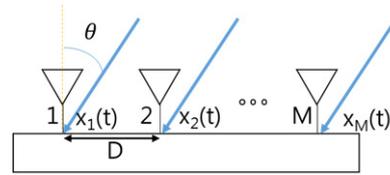


그림 1. 방향탐지 물리 모델  
Fig. 1. A physical model of direction finding

다면, 입사방향 $\theta$  계산이 가능하다.

데이터 생성 시뮬레이터는 환경변수로 수신기 위치, 안테나 개수, 안테나 사이 거리, 수신파장 길이가 주어지고, 임의의 발신원 위치를 입력받으면, 이에 따른 수신 방향각이 계산되고, 1번 안테나를 기준으로 상대적인 위상차를 계산하여 각 안테나에 수집되는 수신 신호들을 생성하게 된다.

#### 3.2 학습 데이터 분석 (송신 위치별 위상차)

송신 위치별 위상차가 어떻게 분포하는지 학습 데이터 분석을 통해 살펴보자. 실내 5m x 5m 공간을 0.1m 단위격자로 나누고, 각 격자지점에서 발신한 신호가 실내 중앙 하단에 배치된 수신기의 두 안테나에 도달했을 때 위상차를 3차원 곡면으로 도식해 보았다. 위상차 분포는 그림 2와 같이 완전한 곡면을 이루는 것을 확인할 수 있으며, 신경망 방향탐지 알고리즘 입장에서 해당 곡면을 학습하게 되는 것이다.

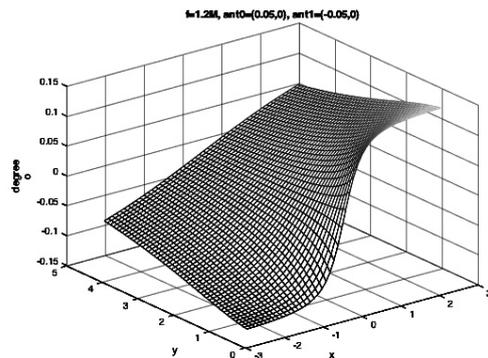


그림 2. 신호 발신 위치에 따른 위상차 곡면  
Fig. 2. Offset-curved surface respect to signal source locations

#### 3.3 시뮬레이터를 이용한 기존 알고리즘 성능비교

여기서는 기존의 MUSIC, RootMUSIC, ESPRIT 알고리즘들이 얼마나 잘 동작하는지 그 성능을 살펴 보기 위해, 시뮬레이터 생성 데이터를 기반으로 안테나 개수와 신호 노이즈레벨을 달리하여 각 알고리즘

의 정확도를 측정하는 실험을 수행하였다.

실험결과 알고리즘들의 성능은 유사하였으며, 다만, 안테나 개수에 따른 성능 차이가 확연함을 알 수 있었다. 그림 3은 노이즈 레벨 -20db에서 안테나 2개를 가지고 MUSIC 알고리즘을 각도 1°의 정확도로 시뮬레이션한 결과다. 실험은 각 각도별로 노이즈가 없는 신호에 화이트 노이즈를 적용한 100개의 랜덤 테스트 데이터를 생성하고, 알고리즘이 탐지한 방향과 노이즈 전의 실제 방향이 일치하는지 개수를 세어 그래프로 도시하는 방식으로 구현하였다. 방향이 정확히 일치하는 개수는 파란색으로, 각도가 1도 차이나는 개수는 주황색으로, 2도 차이는 노란색으로 도시하였다. 그림 4는 동일한 환경에서 안테나 수를 8개로 늘린 후 결과이다. 그림 3대비 대부분의 영역에서 정확히 방향탐지가 됨을 알 수 있다.

그림 3, 4에서 중앙부분의 오차보다는 양쪽 끝부분에 오차가 많이 발생함을 볼 수 있는데 이는 선형배열 안테나의 특성으로 인해 발생한다. 따라서 신경망 학습 시 입사방향각에 따른 학습 결과의 차이가 발생할 수 있으며, 안테나 개수에 따라 학습 성능도 차이가 날 것으로 예상할 수 있다.

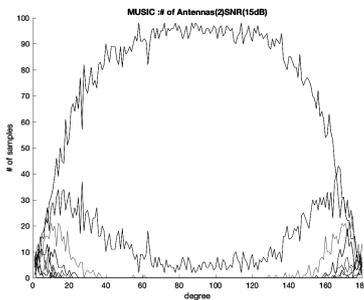


그림 3. MUSIC 실험 결과 (안테나 2개)  
Fig. 3. MUSIC result with two antennas

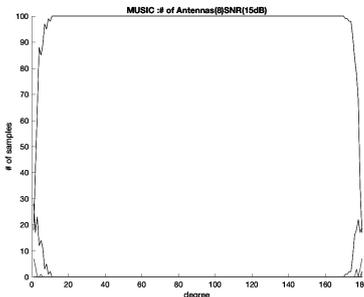


그림 4. MUSIC 실험결과 (안테나 8개)  
Fig. 4. MUSIC result with 8 antenna

#### IV. RBF기반의 신경망 방향탐지 알고리즘

III장에서 시뮬레이터 구현을 통해 학습데이터를 확보하였으며, 학습해야 될 데이터의 특성도 같이 살펴 보았다. 이 장에서는 기존 신경망기반 방향탐지 알고리즘에 대해 살펴보고, 안테나의 개수 및 노이즈 레벨에 따른 성능을 테스트해보고자 한다.

##### 4.1 기존 신경망을 이용한 방향탐지 연구

그림 5는 Matsumoto의 신경망기반 방향탐지 알고리즘<sup>[7]</sup>으로, 크게 전처리, 탐지(detection stage), 측정(estimation stage)의 세 단계로 나뉜다.

전처리 단계는 수신신호로 부터 신호의 상관행렬(correlation matrix)을 계산하여 학습해야하는 데이터의 크기를 줄이는 단계이다. 수신신호 대신 상관행렬을 사용하는 이유는 MUSIC 알고리즘의 경우 수신신호로부터 상관행렬을 계산하고, 상관행렬의 고유값분해(eigenvalue decomposition)를 통해 방향계산을 하는데, 이는 상관행렬에 충분한 방향정보가 있다는 것을 의미한다. 또한, 학습데이터 크기가 줄어들어 학습 용이성과 효율성도 좋아지게 된다.

탐지 단계는 큰 영역 탐지를 수행하고, 측정 단계는 탐지된 영역에서 보다 세밀하게 각도를 추정하는 역할을 수행한다. 1차원 방향탐지를 예로 들면, 방위각 영역  $-90^{\circ} \sim 90^{\circ}$ 에 대해, 탐지 단계에서  $15^{\circ}$  간격으로 총 12개 영역에서 탐지를 수행하고, 측정 단계는 탐지된  $15^{\circ}$ 범위 영역 안에서 세밀하게 최종 각도를 예측한다. 이와 같은 두 단계 기법은 학습난이도를 낮추어

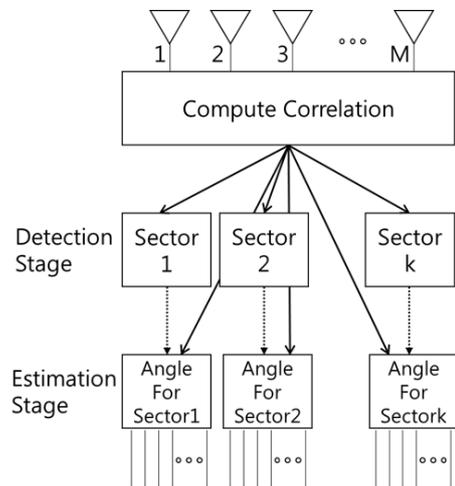


그림 5. 기존 신경망 방향탐지 알고리즘 개념도  
Fig. 5. Neural network direction finding algorithm flow diagram[7]

계산량을 줄이는 장점이 있다.

#### 4.2 신경망 학습

학습에 사용될 신경망은 RBF(Radial Basis Function)<sup>[11],[12]</sup>다. RBF는 3 layer로 이루어진 feed forward network으로, 이론적으로 임의의 함수를 근사할 수 있으며(universal approximation), 정규화(regularization) 능력이 가지고 있음이 알려져 있다. 또한 학습속도도 빨라서 여러 분야에서 많이 사용되고 있다. 일반적으로 신경망이라면, MLP(Multi-Layer Perceptron)을 생각하게 된다. 입력에 가중치(weight)값을 곱하고, 목적함수로 sigmoid함수를 사용하고, back-propagation 알고리즘을 통해 가중치를 학습하는 방식이다.

그림 6처럼 RBF는 모양이 MLP와 유사하지만, 동작방법은 조금 상이하다. 중간 RBF 뉴런은 입력과 자신의 가중치를 비교하여 둘 사이 거리를 계산한 값을 출력한다. 이는 최근접이웃알고리즘(Nearest Neighborhood Algorithm)처럼 기존 데이터와의 거리를 통해서 어느 분류에 속하는지 판별하는 방식과 유사하다. RBF는 MATLAB의 Neural Network Toolbox를 통해 newrb() 함수로 제공되며, 학습에 필요한 입력력 데이터와 사용할 뉴런 개수, 분산 정도 등 간단한 상수 설정으로 학습이 가능하다.

입력은 수신 신호들 간의 상관행렬을 계산하고 정규화한 후, 해당 행렬의 각 원소를 입력 값으로 준다. 신호는 각 개별원소가 복소수 형식이기 때문에, 신경망에는 실수부와 허수부를 구분하여 입력하게 된다. 참고로 실수부와 허수부를 구분하여 입력하는 이유는 기존 신경망 학습 도구들이 복소수 형식의 학습 기능

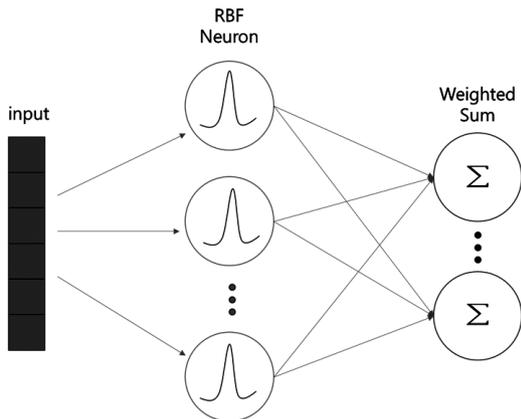


그림 6. RBF 개념도  
Fig. 6. RBF concept diagram

을 제공하지 않기 때문이다. 이 방법은 데이터의 크기나 처리성능 면에서 좋은 장점을 가지고 있다. 예를 들면, 안테나 M개의 시스템에서 각 안테나 별로 N개 샘플을 획득하면, 총 N\*M개의 샘플 데이터에 대한 학습이 필요하다. 하지만, 상관 행렬을 가지고 계산하면 M<sup>2</sup>만큼의 변수만을 학습하면 된다. 따라서, 학습시 필요한 신경망의 크기를 획기적으로 줄일 수 있는 동시에, 학습 성능에 영향을 미치지 않고도 샘플 개수를 증가시켜 정확도를 자유롭게 향상시킬 수 있다.

출력은 Detection Stage에서는 해당 영역에 포함이 되면 1을, 안되면 0을 표기한다. Estimation Stage에서는 세부영역의 개수만큼 배열을 할당, 해당 영역의 발신원 유무에 따라 1, 0을 표기한다.

학습 데이터는 탐지 단계(detection stage)를 위해 각 영역별로 충분한 개수(예: 1,000개)를 랜덤하게 생성하고, 측정 단계(estimation stage) 학습용 데이터도 동일하게 세부 각도에 해당하는 임의 데이터를 랜덤하게 생성하여 신경망 학습에 사용하였다.

#### 4.3 실험 결과

실험환경은 다음과 같다. 안테나 개수는 2개, 4개, 8개, 신호 대비 노이즈 레벨은 -30dB, -20dB, -10dB로 달리하여 각도 10° 분해능에 대해 실험하였다. 또한, 신경망이 학습 시 신호 노이즈 레벨과 실험데이터의 노이즈 레벨에 따라 정확도가 어떻게 변경되는지 확인해 보았다.

안테나는 균일간격 선형 안테나로 구성하였으며, 학습에 필요한 데이터는 각도 구간별로 랜덤하게 1,000개 데이터를 생성하여 학습을 수행하였다.

검증은 전체 대상이 되는 각도를 1,800개로 균등 분할한 테스트 셋을 사용하였다. 균등분할을 사용한 이유는 테스트 셋이 어떻게 선택되는지에 따라 신경망의 성능 변화를 차단하기 위함이다.

그림 7은 안테나 개수, 학습 노이즈 레벨, 테스트 노이즈 레벨에 따른 실험결과다. 실험을 통해 학습 노이즈 레벨과 테스트 노이즈 레벨이 일치하는 경우 좋은 성능을 보임을 알 수 있었으며, 반대로 둘 사이의 노이즈 레벨이 차이가 날수록 성능 저하가 발생함을 확인하였다. 안테나 2개인 경우 학습과 테스트 노이즈 레벨이 같은 경우에만 90%이상의 정확도를 보였으며, 안테나 개수가 4개, 8개로 늘수록 학습과 테스트 노이즈 레벨의 격차로 인한 영향을 줄어들었으며, 특히, 안테나가 8개인 경우 노이즈 차이에 관계없이 안정적인 결과를 보였다.

그림 8은 안테나 개수 2, 4, 8개, 학습 노이즈 -

#antenna	learn			
	test	-30db	-20db	-10db
2	-30db	0.9322	0.9100	0.4989
	-20db	0.4694	0.9333	0.5400
	-10db	0.0556	0.0556	0.8850
4	-30db	0.9111	0.8011	0.7456
	-20db	0.7650	0.9183	0.7789
	-10db	0.0556	0.0917	0.9117
8	-30db	0.9239	0.9111	0.9017
	-20db	0.9228	0.9100	0.9006
	-10db	0.9083	0.8989	0.9078

그림 7. 성능 테스트 결과 요약  
Fig. 7. Summary of performance test results

30db, -20db, -10db 각각에 대해 테스트 노이즈가 -30db(청색), -20db(녹색), -10db(노랑)인 경우에 대해 실험을 수행하였으며, 보다 자세한 분석을 위해 각도 10°별(x축) 정확도(y축) 결과를 도출하였다. 결과를 살펴보면, 왼쪽 열에는 청색이, 중간 열에는 녹색이, 오른쪽 열에는 노란색이 상대적으로 많음을 알 수 있다. 즉, 학습레벨과 테스트 레벨이 같은 경우에 정확도가 상대적으로 높음을 알 수 있다.

입사 각도에 따른 에러율을 살펴보자. 맨 끝 쪽 (-90°,x=0)보다는 맨 끝 쪽 하나 안쪽의 각도 (-80°,x=1)에서 에러가 가장 많이 발생함을 알 수 있다. 이는 MUSIC 등 수학적인 알고리즘과 다르게 신경망 방향탐지 알고리즘 입장에서는 맨 끝 부분의 경우 구분 경계가 양쪽이 아니라, 단지 한쪽만 존재하여, 좋은 결과를 보인 것으로 판단된다.

또한, 기존 MUSIC 등 알고리즘 시뮬레이션에서

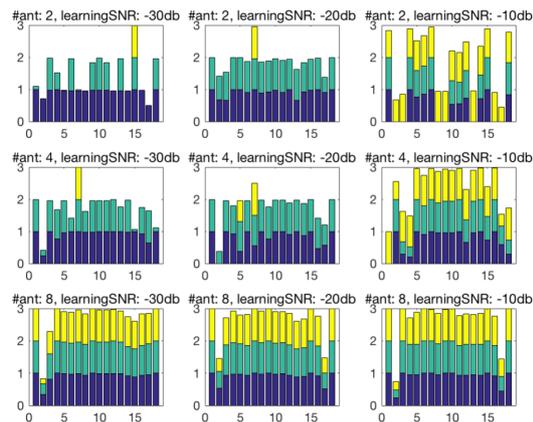


그림 8. 각도별 성능테스트 결과  
Fig. 8. Summary of performance test results by angles

방향탐지 오류가 양 끝 쪽으로 갈수록 에러가 높아지는 경향이 있음을 확인하였는데(그림 3 참조), 신경망의 경우 이런 경향이 상대적으로 적음을 확인할 수 있었다. 에러가 맨 끝쪽 하나 안쪽 각도를 제외하고는 각 각도별로 에러가 분산되어 있음을 볼 수 있다.

안테나가 2개, 4개인 경우에는 학습 노이즈 레벨과 노이즈 레벨이 같은 경우(왼쪽 파란색, 중간 녹색, 오른쪽 노랑색) 전체 각도에서 안정적인 결과를 보였으며, 안테나가 8개인 경우 노이즈 레벨의 차이와 관계없이 전반적으로 안정적인 결과를 보였다.

테스트 노이즈레벨이 -30db(파란색)인 경우 학습레벨 노이즈가 점점 증가함에 따라, 에러율도 같이 증가하는 추이를 볼 수 있었다.

### V. SDR을 이용한 실 시스템 구축

지금까지 시뮬레이션 데이터를 통한 신경망 학습 및 그 성능에 대해 살펴보았다면, 이 장에서는 실 시스템 구현을 통해, 신경망 학습 알고리즘이 실제 환경에서도 제대로 동작하는지 검증하려 한다.

실 시스템 구현을 위해 SDR기반의 NI사 USRP 2950R 두 대를 이용하여, 간단한 1차원 방향 탐지 시스템을 구축하였다. 그림 9는 실제 시스템 구성 사진이다. USRP 하나에 2개의 광대역 안테나(WA5VJB, 850MHz-6,500MHz)를 설치하고, 두 안테나의 수신 신호 동기를 위해 다른 USRP 한 대는 동기신호 송신 용도로 사용한다. SW 기능구현 시 Labview와 MATLAB을 이용하였다.

Labview를 통해 USRP 장비 설정, 주파수 Tune, 기기 동기화, Raw 데이터 수집 기능을 구현하고, MATLAB에서는 신호의 상관행렬 계산, 신경망 학습



그림 9. SDR기반 전파방향탐지 테스트베드  
Fig. 9. Our direction finding SDR testbed

수행 및 방향탐지를 수행토록 구현하였다.

SW 시뮬레이션과 다르게 하드웨어 구축 시 수신 채널간 시간적, 위상적 동기를 추가적으로 고려해야 한다. 각 채널 ADC(analog-digital-converter)에 입력 되는 클럭 차이로 인해 샘플시간에 차이가 발생할 수 있고, 또한 위상고정(phase locked) 수행시 임의의 위상(phase)으로 고정되어 채널간 위상 차이가 발생할 수도 있다. 이를 해결하기 위해, 공유(reference) 클럭을 사용하여 시간적 동기를 맞추었으며, 위상적 동기는 SSB-SC AM을 이용한 동기 신호를 우선으로 전달하는 방식으로 위상차를 보정하였다.

학습 결과의 정확도 비교를 위해 기존 MUSIC 알고리즘 결과를 사용하는 방법이 있으나, MUSIC 알고리즘 자체도 오차를 가지고 있어 제외하였다. 여기서는 실제 신호의 방향을 잘 찾는지 검증하기 위해 웹캠 영상을 통한 시각적인 검증 방법을 이용하였다.

그림 10은 신경망 방향탐지 결과를 웹캠 영상과 중첩하여 시각화한 결과다. 녹색 선은 신경망 방향탐지 알고리즘이 탐지한 방향이며, 영상에서 실제 발신원 안테나를 잘 가르키고 있음을 볼 수 있다. 참고로 웹캠 화각각도는  $-45^\circ$ 에서  $45^\circ$ 로 중심 각도이며, 학습은  $-20\text{db}$  시뮬레이터 데이터를 활용하였다.

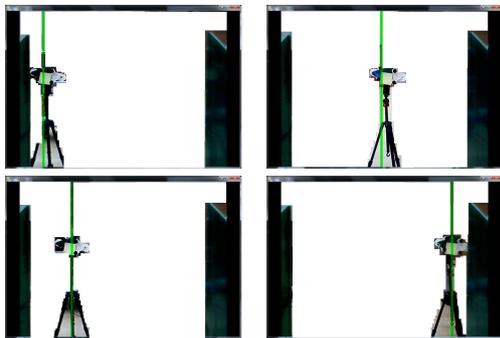


그림 10. 신경망을 이용한 방향탐지 결과  
 Fig. 10. Results on the direction finding using neural networks

## VI. 결 론

본 논문에서는 신경망을 이용한 방향탐지에 대한 성능 연구를 수행하였다. 학습 데이터 생성을 위해 시뮬레이터를 구현하였고, 획득한 데이터를 기반으로 기존의 MUSIC, Root-MUSIC, ESPRIT 알고리즘의 성능을 분석해 보았다. 신경망 방향탐지 알고리즘 구현을 통해 다양한 환경에서의 성능을 테스트 해보았으

며, 시뮬레이션 뿐 아니라 실시스템 구축을 통해 실제 응용에서도 활용 가능함을 확인할 수 있었다.

향후 연구로는 신경망 방향탐지 정확도 향상 및 딥러닝 적용 가능성을 살펴볼 예정이다.

## References

- [1] R. Schmidt, "Multiple emitter location and signal parameter estimation," *IEEE Trans. Ant. and Propag.*, vol. 34, no. 3, pp. 276-280, Mar. 1986.
- [2] Y. Cho, J.-W. Paik, and J.-H. Lee, "Determination of parameter value in constraint of sparse spectrum fitting DOA estimation algorithm," *J. KICS*, vol. 41, no. 8, pp. 917-920, Aug. 2016.
- [3] H. Hwang, et al., "Direction of arrival estimation using a root MUSIC algorithm," *Int. MultiConf. Eng. and Comput. Scientist*, vol. II, pp. 1507-1510, Hong Kong, China, Mar. 2008.
- [4] R. Roy and T. Kailath, "ESPRIT-estimation of signal parameters via rotational invariance techniques," *IEEE Trans. Sign. Process.*, vol. 37, no. 7, pp. 984-995, Jul. 1989.
- [5] R. Rastogi, P. K. Gupta, and R. Kumerason, "Array signal processing with inter-connected neuron-like elements," in *Proc. ICASSP*, pp. 2328-2331, Dallas, Texas, USA, 1987.
- [6] M. Agatonovic, et al., "Application of artificial neural networks for efficient high-resolution 2D DoA estimation," *RadioEngineering*, vol. 21, no. 4, pp 1178-1186, Dec. 2012.
- [7] T. Matsumoto, "2D DOA estimation using beam steering antenna by the switched parasitic elements and RBF neural network," *Electronics and Commun. in Japan*, vol. 89, no. 9, pp. 22-31, Sept. 2006.
- [8] S. CayLar, "A novel neural network based approach for direction of arrival estimation," Ph.D. Thesis, Dept. of Electrical and Electronics Engineering, Middle East Technical University, Sept. 2007.
- [9] J. H. Choi, J. W. Choi, and S. Kim, "The

- study of DOA estimation in frequency domain in automotive radar system,” *J. KICS*, vol. 41, no. 1, pp. 12-22, Jan. 2016.
- [10] Y. Kim, H.-G. Park, and H.-G. Ryu, “A computation reduction technique of MUSIC algorithm for optimal path tracking,” *J. KICS*, vol. 39, no. 4, pp. 188-194, Apr. 2014.
- [11] M. Wang, “A RBFNN approach for DOA estimation of ultra wideband antenna array,” *Neurocomputing*, vol. 71, pp. 631-640, Jan. 2008.
- [12] M. Buhmann, *Radial Basis Functions: Theory and Implementations*, Cambridge Univ. Press, 2003.

**조 민 경 (Minkyung Cho)**

1999년 2월 : 서울대학교 컴퓨터공학과 졸업  
2010년 8월 : U. of Maryland 전산학 박사(석박통합)  
2010년 10월~현재 : ETRI부설연구소 선임연구원  
<관심분야> 알고리즘, 데이터 분석, 딥러닝

**이 대 현 (Dae Heon Lee)**

1999년 2월 : 경북대학교 전자전기 공학부 졸업  
2001년 2월 : 경북대학교 전파공학과 석사  
2013년 8월 : 경북대학교 전파공학과 박사  
2003년 6월~현재 : ETRI부설연구소 선임연구원  
<관심분야> 전자파 해석, 안테나, EMI/EMC

**백 선 업 (Seon Yeob Baek)**

2003년 2월 : KAIST 전기 및 전자공학과 졸업  
2010년 1월 : KAIST 전기 및 전자공학과 박사(석박통합)  
2010년 2월~11월 : KAIST 전기 및 전자공학과 포닥  
2010년 12월~현재 : ETRI부설연구소 선임연구원  
<관심분야> 물리계층보안, 네트워크보안, 무선통신

**김 응 희 (Woong Hee Kim)**

2000년 2월 : 고려대학교 전기전자전파공학부 졸업  
2002년 2월 : 한국과학기술원전기및전자공학과 석사  
2012년 12월~현재 : ETRI부설연구소 선임연구원  
<관심분야> Video Comm. System, Image Analysis

**김 종 규 (Jong-Kyu Kim)**

1995년 2월 : 경북대학교 전자공학과 졸업  
2002년 8월 : 경북대학교 전자공학과(전파공학 전공) 박사  
2012년 6월~2013년 6월 : Univ. of Florida 방문학자  
2002년 9월~현재 : ETRI부설연구소 책임연구원  
<관심분야> 전자공학, 통신공학, 안테나