

# 모노스테틱 RCS와 바이스테틱 RCS의 표적 구분 성능 분석

## Performance Comparison for Radar Target Classification of Monostatic RCS and Bistatic RCS

이 성 준 · 최 인 식

Sung-Jun Lee · In-Sik Choi

### 요 약

본 논문은 바이스테틱 RCS와 모노스테틱 RCS를 이용하여 각각 표적 구분 실험을 수행하고 그 성능을 비교 분석하였다. 모노스테틱 및 바이스테틱 RCS로부터 특성을 추출하기 위하여 시간-주파수 영역 해석법인 STFT와 CWT를 이용하였으며, 다중 퍼셉트론 신경망을 구분기로 이용하였다. 실험 결과, 모노스테틱과 바이스테틱 RCS 모두 CWT가 STFT보다 더 나은 구분 성능을 보여주었다. 또한, STFT에서는 바이스테틱 RCS를 이용했을 때, CWT에서는 모노스테틱 RCS를 이용하였을 때 대체적으로 더 좋은 성능을 나타내었다. 결과적으로 본 논문을 통하여 바이스테틱 RCS도 모노스테틱 RCS처럼 표적 구분에 똑같이 적용할 수 있다는 것을 알 수 있었다.

### Abstract

In this paper, we analyzed the performance of radar target classification using the monostatic and bistatic radar cross section(RCS) for four different wire targets. Short time Fourier transform(STFT) and continuous wavelet transform(CWT) were used for feature extraction from the monostatic RCS and the bistatic RCS of each target, and a multi-layered perceptron(MLP) neural network was used as a classifier. Results show that CWT yields better performance than STFT for both the monostatic RCS and the bistatic RCS. And, when STFT was used, the performance of the bistatic RCS was slightly better than that of the monostatic RCS. However, when CWT was used, the performance of the monostatic RCS was slightly better than that of the bistatic RCS. Resultingly, it is proven that bistatic RCS is a good candidate for application to radar target classification in combination with a monostatic RCS.

Key words : Bistatic RCS, Feature Extraction, Time-Frequency Analysis, MLP Neural Network, Target Classification

### I. 서 론

RCS는 주파수, 입사와 산란의 방향, 편파와 같이 다양한 파라미터들로 이루어진 함수이다. 특히, RCS는 송수신기 위치에 따라 모노스테틱 RCS와 바이스테틱 RCS로 분류된다<sup>[1]</sup>. 송수신기의 위치가 동일한 위치에 있어서 입사 방향과 산란의 방향이 같은 경우에 얻어지는 것이 모노스테틱 RCS이며, 송수신기

가 서로 다른 위치에 위치하여 입사 방향과 산란의 방향이 다른 경우에 얻어지는 것이 바이스테틱 RCS이다. 바이스테틱 레이다는 새로운 개념이 아니다. 왜냐하면 레이다는 본래 바이스테틱으로 시작되었으며, duplexer의 발달 이후 모노스테틱이 레이다의 전반적인 추세가 되었기 때문이다<sup>[2]</sup>. 그래서 일반적으로 레이다라고 하면 모노스테틱 레이다를 일컬었다고 해도 과언이 아닐 정도로 모노스테틱 레이다가

「본 논문은 2010년도 한남대학교 교비학술연구비의 지원에 의한 연구결과임.」

한남대학교 전자공학과(Department of Electronic Engineering, Hannam University)

· 논문 번호 : 20101012-150

· 교신저자 : 최인식(e-mail : recog@hnu.kr)

· 수정완료일자 : 2010년 10월 29일

널리 응용되고 있다. 하지만, 최근 바이스테틱 레이더를 이용한 TV 방송 송신기, SAR 영상 획득<sup>[3]</sup> 및 표적 구분<sup>[4],[5]</sup>, 항공 레이더, 침입 감지 센서 등 여러 분야에 걸쳐 바이스테틱 레이더가 활발히 연구되어 지고 있다. 게다가 스텔스(stealth)형 표적이 등장함에 따라 스텔스형 표적을 탐지하기 위한 레이더로 바이스테틱 레이더가 관심을 받고 있다<sup>[6]</sup>. 기존의 표적 인식 기술들은 주로 모노스테틱 레이더를 이용하였기 때문에 스텔스 디자인은 역산란(back-scattering) 신호를 최소화시키는 역할을 하도록 설계되어 있다. 그렇기 때문에 스텔스 표적과 같이 역산란 신호가 작은 경우에는 모노스테틱 레이더에 비해 바이스테틱 레이더가 탐지에 더욱 효과적일 수 있다<sup>[7]</sup>.

RCS는 표적에 대한 중요한 정보들을 가지고 있으며, RCS를 해석함으로써 그러한 정보를 추출해낼 수 있다. 표적의 중요한 정보에는 산란점과 공진 주파수가 있으며, 표적 인식에 사용될 수 있는 특성들이다. 산란점은 표적의 산란파의 크기가 큰 점을 가리키며, 공진 주파수란 표적의 물리적인 크기에 의해서 결정되는 고유한 주파수를 말한다. 전자파가 표적을 지나가는 동안의 시간인 초기 시간 영역에서는 산란점을 관찰할 수 있으며, 표적을 통과한 후의 후기 시간 영역에서는 공진 주파수를 관찰할 수 있다. 이 두 가지 정보는 시간-주파수 영역 해석법(time-frequency analysis)을 이용하면 동시에 추출해낼 수 있다.

본 논문에서는 4개의 선형 표적(wire target)의 모노스테틱 RCS와 바이스테틱 RCS에 대하여 시간-주파수 영역 해석법인 STFT(Short Time Fourier Transform)와 CWT(Continuous Wavelet Transform)를 이용하여 각 표적들의 특성 벡터를 추출하였다<sup>[8]</sup>. 각 표적에 대해 특성 벡터들을 추출한 후, 표적을 구분하기 위하여 MLP(Multilayered Perceptron)를 이용한 신경망 표적 구분기를 사용하였다. 이런 과정을 통해 모노스테틱 RCS와 바이스테틱 RCS의 표적 구분 성능을 비교 및 분석하였다.

## II. 표적의 특성 벡터 추출

그림 1은 본 논문에서 사용된 표적 구분 과정 블록도이다<sup>[8]</sup>. 데이터를 얻기 위하여 시뮬레이션 소프




그림 1. 표적 구분 과정

Fig. 1. Process of target classification.


트웨어를 이용해 주파수 영역에서의 모노스테틱 및 바이스테틱 RCS를 계산한다. 얻어진 주파수 영역의 RCS 데이터를 역 푸리에 변환(inverse Fourier transform)하여 시간 영역의 데이터를 얻는다. 얻어진 데이터로부터 시간-주파수 영역 해석법인 STFT와 CWT를 이용하여 특성 벡터들을 추출한다. 여기에서 얻어진 특성 벡터가 MLP 신경망 구분기의 입력으로 사용되어 표적을 구분하게 된다.

### 2-1 STFT


레이더 신호처럼 non-stationary 신호를 해석하기 위한 기본적인 방법으로, 시간 영역의 신호를 작은 세그먼트로 나누어 그 세그먼트 동안은 신호가 stationary하다고 가정하고 푸리에 변환을 한다. 일반적으로 세그먼트는 윈도우 함수를 사용하며, 가우시안 윈도우를 사용한다. STFT는 윈도우 길이가 고정되기 때문에 일정한 해상도를 가지며, 시간 영역의 해상도와 주파수 영역의 해상도가 반비례 관계가 성립한다. 그렇기 때문에 해석의 용도에 따라 적절한 윈도우 길이의 선정이 필요하다.

$$STFT(\tau, \Omega) = \int_{-\infty}^{\infty} [f(t)w^*(t-\tau)]\exp(-j\Omega t)dt \quad (1)$$


시간 영역에서 STFT의 식은 식 (1)과 같다. 식 (1)에서  $f(t)$ 는 시간 영역의 신호이며,  $w(t)$ 는 윈도우 함수이다. 식 (1)으로부터 주파수와 시간 영역의 신호가  $M \times N$ 인 STFT 행렬이 얻어진다. 하지만, 신경망의 입력으로는 너무 큰 차원이기 때문에 차원을 줄여줄 필요성이 있다. 따라서 그림 2(a)의  $M \times N$  차원을 그림 2(b)와 같이  $K \times J$  차원으로 압축시켜 준다. 압축 방법은 그림 2(b)와 같이 하나의 셀은 그 안에 포함되는 여러 셀 데이터의 합으로 이루어지도록 하는 것이다<sup>[8]</sup>. 이렇게 줄여진  $K \times J$  차원의 행렬은



(a)  $M \times N$  차원 특성 벡터  
(a) Feature vector of  $M \times N$  dimensions



(b) STFT의  $K \times J$  차원 특성 벡터 압축  
(b) Feature vector compression of  $K \times J$  dimensions for STFT



(c) CWT의  $K_e \times J_e + K_i \times J_i$  차원 특성 벡터 압축  
(c) Feature vector compression of  $K_e \times J_e + K_i \times J_i$  dimensions for CWT

그림 2. 특성 벡터 추출  
Fig. 2. Extraction of feature vector.

신경망 구분기의 입력으로 사용될 특성 벡터가 된다.

### 2-2 CWT

CWT는 STFT의 해상도 문제를 해결할 수 있는 방법으로써, 해상도가 시간과 주파수에 따라 유동적으로 변화한다. 주파수 영역에서의 CWT의 식은 식 (2)와 같다. 식 (2)에서  $\Psi(w)$ 는 'mother wavelet' 함수이며, STFT의 윈도우 함수와 비슷하지만, 고정되어 있지 않고 팽창, 수축 또는 이동하는 유동적 함수이다.

$$CWT_f(\phi, \Omega) = \sqrt{\tau} \int F(w) \Psi(\tau(w - \Omega)) dw \quad (2)$$

주파수 영역에서의 CWT는 초기 시간일수록 시간 영역의 해상도가 좋아지고, 후기 시간으로 갈수록 주파수 영역의 해상도가 좋아진다. 주로 산란점은 초기 시간 영역에 나타나며, 공진 주파수는 후기 시간 영역에 나타나므로 표적에 대한 특성 벡터 추출 시 STFT보다 더욱 효율적인 해상도라고 할 수 있다. STFT와 마찬가지로 식 (2)를 이용하면  $M \times N$  차원의 특성 벡터가 얻어진다. 얻어진 데이터의 차원을 줄이기 위해 초기 시간과 후기 시간의 경계를 나눈다. 그림 2(c)와 같이 초기 시간이 끝나는 시간  $t_0$ 의 이전 시간의 데이터를  $K_e \times J_e$  차원으로, 이후 시간의 데이터를  $K_i \times J_i$  차원으로 압축한다. 초기 시간에는 시간 영역의 산란점을 더 효율적으로 관찰하기 위해  $J_e$ 가  $K_e$ 보다 더 크게 하고, 후기 시간에는 주파수 영역의 공진 주파수를 더 효율적으로 관찰하기 위해  $K_i$ 이  $J_i$ 보다 더 크게 한다. 그렇게 해서  $M \times N$  차원의 특성 벡터를  $K_e \times J_e + K_i \times J_i$ 개의 차원으로 줄일 수 있다<sup>[8]</sup>.

## III. 시뮬레이션 결과

### 3-1 RCS 계산

모노스테틱 RCS와 바이스테틱 RCS의 표적 구분 성능을 간단하게 확인하기 위해 4개의 선형 표적에 대한 시뮬레이션을 하였다. 표적 A와 B, 표적 C와 D는 각각 같은 길이의 몸통과 날개를 가지지만 다른 날개의 각도를 가진다. 시뮬레이션에 사용된 표적은 그림 3과 같다. RCS는 FEKO 시뮬레이션 툴에는 여러 계산 방법이 있지만, 본 논문에서는 모멘트법을




그림 3. 시뮬레이션에 사용된 표적  
Fig. 3. Targets for simulation.

이용하여 계산하였다. 주파수는 7.8125 MHz에서부터 1 GHz까지 7.8125 MHz 간격으로 128포인트 샘플링하였으며, 편파 각은 90°로서 HH의 선형 편파만을 고려하였다. 모노스테틱 RCS는 송수신기를 0°에 고정시킨 후 표적을 0°부터 150°까지 반시계 방향으로 회전시키며 계산하고, 바이스테틱 RCS는 송수신기를 각각 0°와 45°로 고정시킨 후 표적을 0°부터 150°까지 반시계 방향으로 회전시키며 계산하였다.

### 3-2 특성 벡터 추출

시간-주파수 영역 해석법인 STFT와 CWT를 이용하여 각 표적에 대해 특성 벡터를 추출하였다. 특성 벡터는 표적의 각 방위각에 대하여 추출하며, 신경망 구분기의 학습 데이터로 사용될 75개의 홀수 각도 데이터와 테스트 데이터로 사용될 76개의 짝수 각도 데이터로 구분된다. STFT는 윈도우 길이를 15 nsec, 23 nsec로 하여 각각 128×128 차원의 특성 벡터를 얻었으며, 이것을 신경망 구분기에 효율적으로 사용하기 위해 8×8 차원으로 압축하여 각각 64 차원의 특성 벡터를 얻었다. CWT는 wavelet basis 함수의 각각 시간 및 주파수 해상도와 wavelet의 중심을 나타내는  $\alpha$ 와  $t_0$ 를  $\alpha=0.5 \text{ GHz}^{-2}$ ,  $t_0=3 \text{ nsec}$ 와  $\alpha=0.3 \text{ GHz}^{-2}$ ,  $t_0=2 \text{ nsec}$ 로 변경해가며 128×128 차원의 특성 벡터를 얻었다. CWT도 STFT와 마찬가지로 차원을 압축해줄 필요가 있기 때문에, 우선 표적을 모두 지나가는 시간인 10 nsec를 기준으로 초기 시간과 후기 시간으로 구분하였다. 초기 시간의 경우 시간 해상도가 더 좋아야 하므로 4×8 차원으로 압축하였으며, 후기 시간의 경우 주파수 해상도가 더 좋아야 하므로 8×4 차원으로 압축하였다. 이렇게 CWT를 이용하여 32+32=64 차원의 특성 벡터를 얻었다.

### 3-3 표적 구분 실험

본 연구에서는 표적을 구분하기 위해서 2개의 은닉층(hidden layer)을 가지고 있는 MLP 신경망을 이용하였다. 1번째 은닉층은 입력 특성 벡터 차원의 1/2개의 뉴런을 가지며, 2번째 은닉층은 1번째 은닉층 뉴런수의 1/3개의 뉴런을 갖는다. 각 표적에 대한 0°에서 150°의 특성 벡터 데이터 중 홀수 각도의 데이터를 신경망 학습(training) 데이터로 사용하였으며, 짝수 각도의 데이터를 테스트(test) 데이터로 사용하였다. 또한, 일반적으로 레이더 신호는 잡음이 많이 섞여 있으므로 표적 구분기는 잡음에 강건(robust)해야 한다. 그래서 우리는 MLP 신경망의 학습 과정에서 학습 데이터에 백색 잡음(white Gaussian noise)을 추가하여 잡음에 매우 강건한 구분기를 얻게 되었다<sup>[9]</sup>. 구분기의 성능을 높이기 위해 평균 제곱 오류가  $10^{-5}$ 이 될 때까지 학습을 시켰다. 그림 4와 그림 5는 각각 모노스테틱 RCS와 바이스테틱 RCS의 SNR에 대한 구분 확률을 나타낸 것이다. 구분 확률의 신뢰성을 높이기 위해 100회의 몬테카를로 시뮬레이션을 수행하였다. 그림 4와 그림 5를 보면 알 수 있듯이, 모노스테틱과 바이스테틱에 관계없이 STFT보다 CWT를 이용한 특성 벡터가 더 구분 확률이 높은 것을 확인할 수 있다. 또한, 모노스테틱에서는 윈도우 길이가 15 nsec인 STFT와  $\alpha=0.3 \text{ GHz}^{-2}$ ,  $t_0=2 \text{ nsec}$ 인 CWT가, 바이스테틱에서는 윈도우 길이가 23 nsec인 STFT와  $\alpha=0.3 \text{ GHz}^{-2}$ ,  $t_0=2 \text{ nsec}$ 인 CWT가 대체적으로 더 나은 성능을

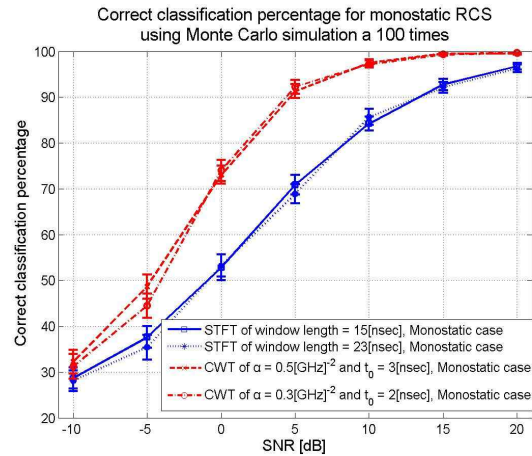


그림 4. 모노스테틱 RCS의 SNR에 대한 구분 확률  
Fig. 4. Classification probability for SNR of monostatic RCS.

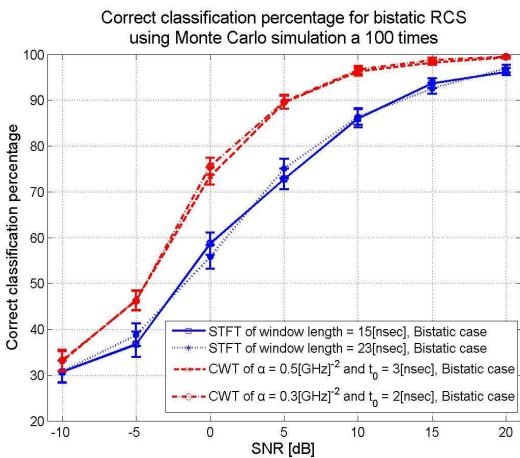


그림 5. 바이스테틱 RCS의 SNR에 대한 구분 확률  
Fig. 5. Classification probability for SNR of bistatic RCS.

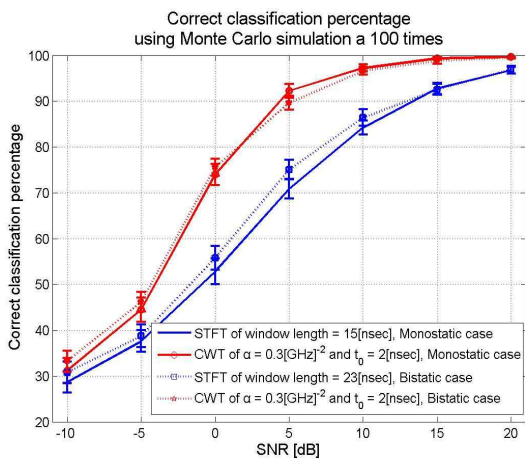


그림 6. 모노스테틱 RCS와 바이스테틱 RCS의 구분 확률 비교  
Fig. 6. Classification probability comparison between monostatic and bistatic RCS.

맞는다. 그림 6은 모노스테틱 RCS와 바이스테틱 RCS 각각의 가장 나은 성능을 보인 STFT와 CWT의 구분 확률을 비교한 것이다. STFT의 경우 바이스테틱 RCS를 이용한 표적 구분이 더 효율적이며, CWT의 경우 낮은 SNR에서는 바이스테틱 RCS를 이용한 표적 구분이 더 나은 성능을 갖지만 SNR이 증가할수록 모노스테틱 RCS를 이용한 표적 구분이 더 나은 성능을 가지는 것을 알 수 있다.

다음으로는 confusion matrix를 이용하여 각 표적 간의 혼동 관계를 알아보았다. 표 1은 SNR이 10 dB

일 때, 바이스테틱과 모노스테틱 RCS에 대해 CWT와 STFT를 이용하여 얻어진 confusion matrix이다. 이 결과 또한, 실험 결과의 신뢰성을 높이기 위하여 100회의 몬테카를로 시뮬레이션을 수행하였다. CWT는  $\alpha = 0.3 \text{ GHz}^{-2}$ ,  $t_0 = 2 \text{ nsec}$ , STFT의 윈도우 길이는 15 nsec인 경우에 대해서만 나타내었다. 또한, 76개의 테스트 데이터를 사용하였다. 표 1의 결과를 요약하면 다음과 같다. 본 논문에 사용된 선형 표적들

표 1. SNR 10 dB에서의 confusion matrix  
Table 1. Confusion matrix in SNR 10 dB.

(a) CWT for bistatic RCS

Actual class	Classification			
	A	B	C	D
A	75.03	0.75	0.16	0.06
B	0.45	75.23	0.02	0.3
C	0.7	0.16	73.13	2.01
D	0.5	0.25	4.9	70.35

(b) CWT for monostatic RCS

Actual class	Classification			
	A	B	C	D
A	74.08	0.32	0.86	0.74
B	0.56	74.94	0.06	0.44
C	0.87	0.06	72.92	2.15
D	0.27	0.18	1.9	73.65

(c) STFT for bistatic RCS

Actual class	Classification			
	A	B	C	D
A	65.35	6.56	2.59	1.5
B	3.37	68.87	1.36	2.4
C	1.19	0.14	64.67	10
D	0.94	1.38	11.22	62.46

(d) STFT for monostatic RCS

Actual class	Classification			
	A	B	C	D
A	62.03	2.88	8.63	2.46
B	4.32	68	0.53	3.15
C	2.87	0.16	63.73	9.24
D	1.46	3.12	9.81	61.61

을 육안으로 보게 되면 표적 A와 B, 표적 C와 D가 유사하게 보인다. 실제로 confusion matrix의 결과에서도 확인할 수 있듯이, 모노스테틱과 바이스테틱 RCS에 따라 미세한 차이가 존재하지만, 대체적으로 표적 A와 B, 표적 C와 D가 상당한 혼동 관계를 갖는 것을 알 수 있다.

본 절에서는 신경망 구분기를 이용하여 구분 성능을 시뮬레이션하고, confusion matrix를 이용함으로써 표적 모양의 유사함과 특성 벡터를 추출하는 방법에 따라 구분 성능에 미치는 영향이 크다는 것을 확인하였다. 또한, 모노스테틱 RCS뿐만 아니라 바이스테틱 RCS를 이용하여도 충분히 좋은 성능의 구분기를 얻을 수 있음을 확인하였다.

#### IV. 결 론

본 논문에서는 4개의 선형 표적에 대해 모노스테틱 RCS와 바이스테틱 RCS를 이용하여 표적 구분 성능을 분석하였다. 시간-주파수 영역 해석법인 CWT와 STFT를 이용하여 각 표적들의 고유 정보인 특성 벡터를 추출하였으며, MLP 신경망 구분기를 이용하여 표적 구분을 하였다. 구분기가 잡음에 강건하도록 학습 데이터에 백색 잡음을 부가하여 학습시켰다. 시뮬레이션을 수행한 결과, STFT보다 CWT 특성 벡터의 구분 성능이 더 좋았으며, 윈도우 길이와 wavelet basis 함수의  $\alpha$ 와  $t_0$  값에 따라 구분 성능에 상당한 영향을 주는 것을 볼 수 있었다. STFT 경우에는 바이스테틱 RCS를 이용했을 때, CWT 경우에는 모노스테틱 RCS를 이용했을 때 대체적으로 더 좋은 성능을 나타냈다. 또한, 각 표적 간의 혼동 관계를 분석하기 위하여 confusion matrix를 사용하였다. Confusion matrix 결과를 분석함으로써, 표적 모양의 유사함에 따라 구분 성능에 미치는 영향을 확인할 수 있었다. 이러한 결과를 통해 본 논문에서는 모노스테틱 RCS뿐만 아니라 바이스테틱 RCS를 이용하여도 충분히 좋은 성능의 구분기를 얻을 수 있음을 확인할 수 있었으며, 앞으로 바이스테틱 레이더의 최적 성능을 발휘하기 위한 시스템 구성에 대한 연구

와 선형 표적이 아닌 실제 표적을 이용한 실험이 이루어져야 할 것이다.

#### 참 고 문 헌

- [1] J. I. Glaser, "Some results in the bistatic Radar Cross Section(RCS) of complex objects", *Proceedings of the IEEE*, vol. 77, no. 5, pp. 639-648, May 1989.
- [2] M. Cherniakov, *Bistatic Radar: Principles and Practice*, John Wiley & Sons Ltd., 2007.
- [3] M. Cherniakov, "Space-surface bistatic synthetic aperture radar-prospective and problems", *Proc. RADAR 2002 Conference*, Edinburgh, UK, no. 490, pp. 22-26, Oct. 2002.
- [4] A. K. Mishra, B. Mulgrew, "Bistatic SAR ATR", *IET Radar, Sonar & Navigation*, vol. 1, no. 6, pp. 459-469, Dec. 2007.
- [5] N. K. Ibrahim, R. S. A. Raja Abdullah, and M. I. Saripan, "Artificial neural network approach in radar target classification", *Journal of Computer Science*, vol. 5, no. 1, pp. 23-32, 2009.
- [6] L. Gürel, H. Bagci, J. C. Castelli, A. Cheraly, and F. Tardivel, "Validation through comparison: Measurement and calculation of the bistatic radar cross section of a stealth target", *Radio Science*, vol. 38, no. 3, pp. 1046-1058, Sep. 2003.
- [7] C. Wei, W. Chang, "System level investigations of television based bistatic radar", Master Thesis, University of Cape Town, pp. 14-15, 2005.
- [8] In-Sik Choi, Hyo-Tae Kim, "Efficient feature extraction from time-frequency analysis of transient response for target identification", *Microwave and Optical Technology Letters*, vol. 26, pp. 403-407, Sep. 2000.
- [9] S. Chakrabarti, N. Bindal, and K. Theagarajan, "Robust radar target classifier using artificial neural network", *IEEE Trans. on Neural Network*, vol. 6, pp. 760-766, May 1996.

이 성 준



2010년 2월: 한남대학교 전자공학과 (공학사)  
2010년 2월~현재: 한남대학교 대학원 전자공학과 석사과정  
[주 관심분야] Radar 신호 처리, Radar 시스템 설계

최 인 식



1998년 2월: 경북대학교 전자공학과 (공학사)  
2000년 2월: 포항공과대학교 전자전기공학과 (공학석사)  
2003년 2월: 포항공과대학교 전자전기공학과 (공학박사)  
2003년~2004년: LG전자 선임연구원  
2004년~2007년: 국방과학연구소 선임연구원  
2007년~현재: 한남대학교 전자공학과 교수  
[주 관심분야] Radar 신호 처리, Radar 시스템 설계, RFID