

1) Gaussian Mixture Model을 이용한 넓은 관측각에서의 효율적인 레이더 표적인식

서 동 규, *김 경 태, 김 효 태
포항공과대학교 전자전기공학과, *영남대학교 정보컴퓨터공학부
전화 : 054-279-5021 / 핸드폰 : 017-550-2501

Radar target recognition using Gaussian mixture model over wide-angular region

Dong-Kyu Seo, Kyung-Tae Kim, and Hyo-Tae Kim
Dept. of Electronic and Electrical Engineering, POSTECH
E-mail : [sdk@postech.ac.kr](mailto: sdk@postech.ac.kr)

Abstract

One-dimensional radar signature, such as range profile, is highly dependent on the aspect angle. Therefore, radar target recognition over wide-angular region is a very difficult task. In this paper, we propose the Bayes classifier with Gaussian mixture model for radar target recognition over wide-angular region and compare performances of proposed technique and radar target recognition with subclasses concept in the literature of probability of correct classification ratio.

I. 서론

레이더를 이용하여 표적을 인식하기 위해서, 아주 많은 기법들이 이용되고 있다. 이러한 여러 가지 기법들 중에서 1차원 range profile을 이용하는 방법은 실시간 레이더 표적인식 시스템을 위해 매우 유망한 방법중 하나이다[1]. 1차원 range profile은 주파수 영역 신호 이용방법-고유주파수(natural frequency) 기법 등-에 비해서 잡음(noise)에 매우 강인하고(robust), 2차원 ISAR(Inverse Synthetic Aperture Radar)나 SAR(Synthetic Aperture Radar) 영상에 비해서는 계산량

이 작고 데이터 저장공간이 작아 계산효율과 계산속도 면에서 우수하다[1][2].

그러나 이러한 1차원 range profile은 표적의 관측각의 변화에 따라 매우 민감하게 변화하는 단점을 안고 있다. 이러한 특징은 결국 넓은 관측각에서의 표적인식기법의 성능을 저하시킨다. 본 논문에서는 Gaussian mixture model을 사용하여 넓은 관측각에서의 구분성능을 향상 시키는 방법을 제안한다.

본 논문의 구성은 다음과 같다. 먼저 본론의 2.1에서는 range profile을 이용하여 표적구분실험을 행하는 경우에 관측각의 확장이 표적구분 성능에 주는 영향에 대해 분석하고 2.2절에서는 이러한 영향을 줄이기 위한 기법으로써 subclass 개념을 이용한 기법에 대해 간략히 정리를 한다. 2.3절에서는 Gaussian mixture model에 관해 설명하고, 2.4절에서는 Gaussian mixture model과 subclass 개념에 대해 비교한다. III에서는 포항공과대학교 내의 단축거리 무반향실(POSTECH Compact Range)에서의 측정데이터를 이용하여 구분실험을 하고 그 성능을 비교하며, IV에서는 이러한 결과를 바탕으로 결론을 내린다.

II. subclass 개념과 Gaussian mixture model을 이용한 표적인식기법

2.1 관측각의 확장에 따른 표적구분성능

앞서 밝힌바와 같이 range profile은 표적에 대한 관

1) 본 연구는 국방과학연구소의 연구비 지원에 의해 수행되었음. 계약번호 : EM-44

측각에 따라 매우 변화가 심하다. 따라서 넓은 관측각을 사용하는 경우엔 있어서는 이러한 range profile의 변화에 따른 표적구분기법의 성능 저하가 매우 크다. 그림 1은 관측각을 확장하면서 표적인식기법의 성능을 비교한 결과이다. 본 논문에서는 [1]에서 제안한 range profile과 센트럴 모멘트를 이용한 표적구분알고리즘을 사용하였다. 6개의 표적을 이용하였고, 고각은 0°로 고정된 상태에서 8.3~12.3GHz까지 4GHz 범위에서 측정하였다.




그림 3. 관측각 확장에 따른 표적구분성능변화

그림 1에서도 볼 수 있는 것처럼 관측각이 확장됨에 따라서 큰 폭의 구분성능(classification performance) 감소가 있는 것을 확인할 수 있다.

2.2 subclass 개념을 이용한 넓은 관측각에서의 표적인식기법의 성능 개선




그림 4. subclass 개념을 이용한 class의 분할

2.1절에서와 같이 관측각이 확대됨에 따라 표적인식기법의 성능이 감소하는 것은 range profile이 관측각에 따라서 민감하게 변화하는 것에 기인한다. 이렇게 range profile의 민감한 성질이 결국 특성벡터의 관측각에 따른 민감한 변화로 이어지고, 결과적으로 특성벡터의 분포는 특성공간상에서 관측각에 따라 매우 산

만하게 분포하게 된다. 따라서 일반적인 선형의 구분기(linear classifier)는 이렇게 산만하게 분포된 특성공간을 제대로 구분(classification)하기 힘들다. 따라서 그림 2와 같이 각 class를 subclass들로 나누고 구분기에 적용하면 특성벡터의 산만한 분포에 의한 성능저하를 줄일 수 있다[3].

2.3 Gaussian Mixture Model (GMM)

GMM은 확률분포를 식 (1)과 같이 Gaussian 분포를 갖는 여러 개의 mixture의 선형결합(linear combination)을 이용해서 나타낸다[4].

$$p(\mathbf{x}) = \sum_{k=1}^K p(\mathbf{x}|k)P(k) \quad (1)$$

위의 식에서 $p(\mathbf{x}|k)$ ($k=1, 2, \dots, K$)는 K 개의 Gaussian 확률밀도함수를 나타내며, $P(k)$ 는 각 mixture의 선형확률(prior probability)을 나타낸다. GMM은 확률밀도함수를 여러개의 가우시안 확률밀도함수의 선형결합으로 모델링하므로 이를 이용하면 비선형으로 분포된 확률함수도 적절히 모델링 할 수 있다[4]. 이때 각 mixture의 평균과 분산에 해당하는 파라미터와 $P(k)$ 는 EM(Expectation-Maximization) 알고리즘을 이용하여 학습한다.

그림 3은 EM 알고리즘을 사용하여 학습한 1차원의 예시이다. 그림에서 볼 수 있는 것처럼 표본(sample) 데이터가 x축 상의 [0.5 0.8 0.9 1 1.1 1.2 1.5 1.8 1.9 2 2.1 2.2 2.5]의 위치에 12개의 지점으로 주어진 경우 이러한 표본을 2개의 Gaussian mixture를 이용하여 모델링하면 두개의 mixture가 각각의 지역적인(localized) 표본의 분포를 학습하게 된다. 아래 그림에서 x축에 나타난 'o' 마크로 표시된 것이 바로 표본들의 위치이다.




그림 5. 1차원에서의 GMM 학습의 예

2.4 GMM과 subclass 개념의 비교

subclass 개념은 결국 각 class들을 분할하여 Bayes 구분기에 적용시키는 기법이다[3]. 그러나 GMM의 경우에는 Bayes rule을 이용하여 구분을 하는 것은 동일하지만 구분기에 아무런 조작을 가하지 않고 확률분포를 바꾸어, 하나의 Gaussian이 아닌 여러 개의 Gaussian 분포의 mixture로 표현을 하게 된다[4].

subclass의 경우에는 특성벡터가 관측각에 따라 변화하여 산만하게 분포될 때 이러한 분포를 각 subclass가 학습을 하여, 구분성능을 개선하게 된다. 그런데 GMM의 경우에는 각 가우시안 mixture들이 이렇게 산만하게 분포된 특성벡터들을 확률분포로써 학습하게 된다.

결국 이 두개의 기법은 subclass를 이용하여 구분기에서 여러개의 class들로 특성공간을 분할하는가와 GMM을 이용하여 여러개의 Gaussian 확률분포로 분할하는가에 대한 차이로써 나타나게 된다. 즉, subclass 개념에서의 각 subclass들이 GMM의 경우에는 각 mixture에 해당되는 것이다. 그런데 subclass와 달리 GMM을 이용한 분할은 확률적인 개념이므로 subclass개념에 비해 상당한 fuzziness를 가질 수 있다. 따라서 복잡하게 분포된 특성을 더 우수하게 학습할 수 있으며, 이러한 특징은 특성공간 분할에 더욱 유리하다고 말할 수 있다.

III. 실험결과

3.1 측정조건

본 구분실험을 위해 포항공과대학교 내에 설치된 단축거리 무반향실(POSTECH Compact Range)에서 F4, F14, F16, F117, F22, Mig29 등 6개의 축소모형을 이용하여 실험하였다. 측정주파수는 8.3~12.3GHz(401 point sampling)이다. 표적이 대부분 좌우 대칭의 구조로 되어 있기 때문에 방위각 방향으로 0~180° 영역에서만 측정하였고(0.5° 간격으로 샘플링), 고각은 0°로 고정하였다. 모든 실험은 SNR(Signal-to-noise ratio)에 따른 구분성능을 확인하기 위해서 10번의 Monte-Carlo 시뮬레이션을 하였다.

그림 4는 전통적인 range profile 추출기법인 IFFT (Inverse Fast Fourier Transform)를 이용하여 표적인식기법에 적용시킨 결과이다.

가우시안 분포를 가정하여 하나의 Gaussian 확률분포함수를 이용하여 Bayes 법칙에 의해 구분하는 일반적인 Bayes 구분기에 비하여 subclass를 이용하면

SNR이 높은 경우 8~9%정도의 성능향상이 있었다. GMM의 경우에는 subclass에 비해서도 7~9%정도의 성능향상이 있어 SNR이 40 dB인 경우에 대해서는 그림 4에서 볼 수 있는 것처럼 기본적인 형태의 Bayes 구분기에 비해 18%정도의 성능향상이 있는 것을 관찰할 수 있다. 그러나 0 dB로 잡음의 영향이 매우 큰 경우에는 subclass나 GMM이 잡음에 의한 특성벡터의 분산에 의한 영향까지 같이 학습하게 되어 성능이 많이 저하된다.

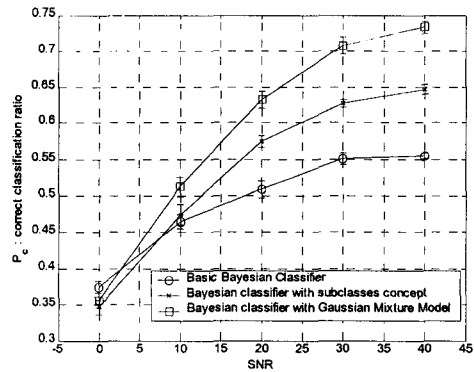


그림 6. IFFT의 range profile을 이용한 경우의 구분결과 비교

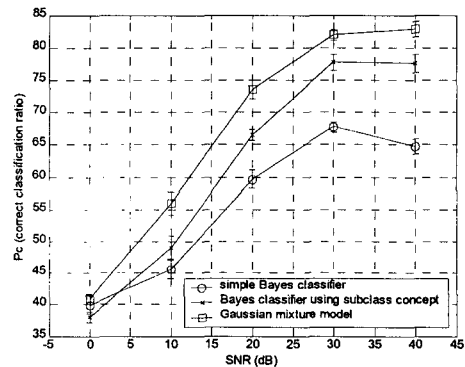


그림 7. MUSIC의 range profile을 이용한 경우의 구분결과 비교

그림 5는 같은 실험을 고해상도 방법인 MUSIC (Multiple Signal Classification)에 적용시킨 결과이다. MUSIC을 사용할 경우 고해상도의 range profile이 사용되기 때문에 전체적으로 IFFT만을 이용하는 경우보다 성능이 향상되었다. 특히 IFFT를 이용하는 경우와 차이는 MUSIC에 의해 잡음에 의한 효과가 많

이 감소되어 특성벡터가 추출된다. 따라서 그림 5에서 보는 것처럼 SNR이 0 dB로 잡음이 매우 큰 경우에 대해서도 잡음의 분산이 줄어들고 GMM 기법이 잡음에 의한 영향을 적게 받게 되어 일반 Bayes 기법의 성능보다 우수하게 나타난다. 또한 높은 SNR을 가지는 경우에 있어서 구분확률을 82~83%까지 끌어올릴 수 있다.

IV. 결론

이상으로 range profile을 이용하여 넓은 관측각에 대해서 표적구분을 하는 기법들에 대해 살펴보았다. range profile은 그 특성상 관측각에 민감하게 변화하며, 이는 추출된 특성벡터가 관측각에 따라 민감하게 변화하게 하여 구분성능을 저하시킨다. 본 논문에서는 이러한 구분성능 저하를 막기 위해 Gaussian mixture model을 이용하여 구분하는 방법을 제안하였고, 측정된 데이터를 이용하여 구분실험을 한 결과, Gaussian mixture model을 이용하는 것이 이 경우에 상당한 구분성능 향상을 가져오는 것을 확인하였다.

참고문헌

- [1] Kyung-Tae Kim, Dong-Kyu Seo, and Hyo-Tae Kim, "Efficient radar target recognition using the MUSIC algorithm and invariant features," *IEEE trans. on Antennas and Propagation*, vol. 50, no. 3, pp 325~337, Mar. 2002
- [2] H.-J. Li, and S.-H. Yang, "Using range profile as feature vectors to identify aerospace objects," *IEEE Trans. on AP*, vol. 41, no. 3, March 1993
- [3] 서동규, 김경태, 김효태, "subclass concept을 이용한 넓은 관측각에서의 레이더 표적인식 성능향상에 관한 연구," 2002년도 춘계 마이크로파 및 전파 전파 학술대회, 성균관대학교, 2002. 5. 25 발표예정
- [4] S. Gong, S. J McKenna, and A. Psarrou, *Dynamic Vision*, London, Imperial College Press