

Subclass 개념을 이용한 넓은 관측각에서의 레이더 표적인식 성능향상에 관한 연구

Wide-Angle Radar Target Classification with Subclass Concept

서동규 · 김경태* · 김효태

Dong-Kyu Seo · Kyung-Tae Kim* · Hyo-Tae Kim

요약

일반적인 시간 영역에서의 레이더 신호들은 표적의 관측각에 민감하게 변화한다. 따라서 대표적인 시간영역 레이더 신호인 1차원 range profile을 이용하여 구분실험을 하는 경우에 있어서 central moments와 PCA를 결합하여 먼저 특성벡터를 추출한 후 clustering 기법에 기반한 subclass concept을 사용하는 구분기를 사용하여 넓은 관측각에서의 표적인식 성능을 향상시킨 결과들을 보여준다.

Abstract

The range profile is easily obtainable and promising feature vector in the aspect of real-time radar target recognition system. However, the range profile is highly dependent on a aspect angle of a target and this dependence make it difficult the recognition over wide-angular region. In this paper, we propose the classifier with subclass concept in order to solve this dependence problem. Recognition results using six aircraft models measured at compact range facility are presented to show the effectiveness of this proposed classifier over wide-angular region.

Key words : Radar Target Recognition, Radar Signal Processing, Range Profile, Subclass Concept

I. 서 론

레이더 표적인식을 위해 사용되는 특성벡터의 종류는 매우 다양하다. 그러나 잡음에 강인하면서도 (robust) 실시간 처리를 가능하게 하기 위해서 표적의 거리방향으로의 RCS 크기 분포를 나타내는 1차원 range profile에 기반한 방법들이 매우 유망하다 [1]~[3]. 그러나 고유주파수나 시간-주파수 영역 해석 법과 같은 주파수 영역에서의 특성벡터들은 관측각에 상관없이 일정한 결과를 보여주는 반면, 1차원 range profile 기법의 경우에는 관측각에 따라 range

profile이 민감하게 변화하는 문제가 있다. 따라서 range profile을 이용하는 표적인식 알고리즘들의 경우 관측각 확장에 따른 표적인식 성능의 저하가 심각하게 나타난다.

본 논문에서는 이러한 문제를 해결하기 위해 subclass 개념을 구분기에 적용하여 구분기의 구분 성능이 관측각이 넓어짐에 따라 급격히 저하되는 것을 보상하는 방법을 제안하고, 이렇게 제안된 구분기를 이용한 구분 성능을 보여준다. 이때, subclass 개념을 이용한 구분기의 구분성을 검증하기 위해 포항공대 내의 단축거리 무반향실(POSTECH

「본 연구는 국방과학연구소의 연구비 지원에 의해 수행되었음. 계약번호 : EM-44」

포항공과대학교 전자전기공학과(Dept. of Electronic and Electrical Engineering, Pohang Univ. of science and Technology)

*영남대학교 전자정보공학부(Dept. of Eletronic and Computer Science, Yeungnam Univ.)

· 논문 번호: 20020525-06S

· 수정완료일자: 2002년 7월 29일

compact range)에서 측정된 6개의 축소 모형의 데이터를 이용하여 실제의 구분 실험을 행하였다.

본 논문은 다음과 같은 순서로 구성되어 있다. 먼저 본론에서는 센트럴 모멘트(central moment)와 PCA(Principal Component Analysis)에 기반하여 range profile로부터 효율적인 특성벡터를 추출하는 기법^[3]에 대해 설명하고, 다음으로 subclass 개념에 대해 설명한다. 본론의 마지막 절에서는 subclass의 개수를 결정하기 위해 사용된 유전 알고리즘(GA : Genetic Algorithm)에 대해 간략하게 소개하며, subclass 분할에 이용될 FCM(Fuzzy c-mean) 알고리즘에 대해서도 소개한다. III장에서는 측정된 RCS (Radar Cross Section) 데이터를 제안된 구분알고리즘에 적용하여, 실제 구분한 결과를 보여주고, IV장에서는 이를 바탕으로 결론을 내린다.

II. 본 론

2-1 센트럴 모멘트와 PCA를 이용한 Range Profile로부터의 특성벡터 추출

표적의 RCS 데이터로부터 시간에 대한 스펙트럼을 계산하면 1차원 range profile을 구할 수 있다. 이렇게 구해진 1차원 range profile의 특성벡터의 크기를 줄이고, 또한 표적의 위치나 전체 신호레벨에 따른 변화를 줄이기 위해, 본 실험에서는 센트럴 모멘트와 PCA에 기반하여 특성벡터를 추출하는 알고리즘을 사용하였다^[3].

2-1-1 센트럴 모멘트의 계산

모멘트와 모멘트 함수는 다양한 이미지 패턴으로부터 물체 위치의 이동이나 절대적인 신호레벨에 의한 변화에 민감하지 않은 특성벡터를 구할 수 있기 때문에 여러 분야에 응용되고 있다^[3]. 표적으로부터 산란된 산란파로부터 1차원 range profile을 구하고 나면, 이를 이용해서 1차원 range profile의 센트럴 모멘트를 구한다.

$$\mu_p = \sum_{k=1}^L (\bar{r}_k - \bar{\eta}_r)^p \left[\frac{\bar{a}_k}{\sum_{k=1}^L \bar{a}_k} \right], \quad (1)$$

$$\bar{r}_k \in [0, 1]$$

여기서

$$\bar{\eta}_r = \sum_{k=1}^L \bar{r}_k \left[\frac{\bar{a}_k}{\sum_{k=1}^L \bar{a}_k} \right],$$

$$\bar{r}_k = \frac{r_k}{R_u}, \quad k = 1, 2, \dots, L,$$

$$\bar{a}_k = \frac{|a_k|}{|a_k|_{\max}}, \quad k = 1, 2, \dots, L.$$

그리고 L 은 range profile의 전체 데이터 샘플의 수를 말하고, p 는 모멘트의 차수를 나타낸다. 또한 r_k 는 k 번째 range profile 상의 데이터 샘플에 대응되는 거리를 말하고, a_k 는 r_k 에 대응되는 range profile의 크기(amplitude)를 나타낸다. $|a_k|_{\max}$ 는 계산된 L 개의 산란점의 크기 중에서 제일 큰 것이다.

먼저 식 (1)의 센트럴 모멘트는 위치이동 불변특성(translational invariance)을 갖기 때문에 표적까지의 거리가 표적의 이동에 따라 변화하더라도, 거리의 변화에 상관없이 일정한 표적구분성능을 얻을 수 있다^[5]. 식 (1)에서 거리 파라미터를 위와 같이 정규화 한 것은 모멘트의 차수가 올라감에 따라 잡음에 더 민감해지므로, 정규화를 통해 $|\bar{r}_k - \bar{\eta}_r|$ 가 1보다 작도록 하여 차수에 따라 값이 점점 커지지 못하도록 한 것이다. 그리고 신호극점의 크기를 정규화 한 것은 표적으로부터 오는 산란파의 절대적인 레벨에 의존하지 않도록 하기 위한 것이다. 식 (1)에서의 센트럴 모멘트를 사용하여 구해진, 위치변화와 크기변화에 의존하지 않는 특성벡터 f 는 다음과 같이 표현된다.

$$f = [f_1, f_2, \dots, f_{p_{\max}}]^T = [\mu_1, \mu_2, \dots, \mu_{p_{\max}}]^T, \quad (2)$$

여기서 p_{\max} 는 특성벡터를 만들기 위해 사용되는 센트럴 모멘트의 최대 차수를 나타낸다.

2-1-2 특성 공간 사상(Mapping)

구분기를 만들기 위해서는 서로 다른 여러 개의 표적과 서로 다른 관측각(aspect angle)에서 측정된 데이터의 특성벡터들을 포함하는 훈련 데이터 베이스가 필요하다. 우리는 다음처럼 훈련 데이터 베이스 F 를 식 (2)를 이용하여 아래처럼 쓸 수 있다.

$$\mathbf{F} = \begin{bmatrix} f_{11} & f_{12} & \cdots & f_{1Q} \\ f_{21} & f_{22} & \cdots & f_{2Q} \\ \vdots & \vdots & & \vdots \\ f_{p_{\max}, 1} & f_{p_{\max}, 2} & \cdots & f_{p_{\max}, Q} \end{bmatrix} \quad (3)$$

여기서 $Q = N_c \times N_a$ 이고, \mathbf{F} 는 $p_{\max} \times Q$ 크기의 행렬이다.

식 (1)에서 획득된 센트럴 모멘트의 값은 차수 p 가 증가함에 따라 급격히 감소하기 때문에, \mathbf{F} 의 각 원소의 크기 f_{ij} 는 j 가 고정된 경우에 대해 i 가 증가함에 따라 급격히 감소한다. 어쨌든, 구해진 센트럴 모멘트들은 유클리디안(Euclidean) 특성 공간(feature space)상에서 차수 p 에 관계없이 같은 가중치를 갖게 해야 한다. 따라서 아래의 식에 의해 0에서 1사이의 값으로 바꾸어 주어 이러한 가중치를 없애준다.

$$\overline{f}_{ij} = \frac{f_{ij} - f_{i,\min}}{f_{i,\max} - f_{i,\min}}, \quad (4)$$

$(i = 1, 2, \dots, p_{\max}, j = 1, 2, \dots, Q)$

여기서

$$f_{i,\min} = \text{최소값 } f_{ij}, \quad j=1, 2, \dots, Q$$

for a given i

$$f_{i,\max} = \text{최대값 } f_{ij}, \quad j=1, 2, \dots, Q$$

for a given i

그리고 나면 정규화된 훈련 데이터 베이스 $\overline{\mathbf{F}}$ 는 다음 식으로부터 구해진다.

$$\overline{\mathbf{F}} = \begin{bmatrix} \overline{f}_{11} & \overline{f}_{12} & \cdots & \overline{f}_{1Q} \\ \overline{f}_{21} & \overline{f}_{22} & \cdots & \overline{f}_{2Q} \\ \vdots & \vdots & & \vdots \\ \overline{f}_{p_{\max}, 1} & \overline{f}_{p_{\max}, 2} & \cdots & \overline{f}_{p_{\max}, 1} \end{bmatrix} \quad (5)$$

2-1-3 PCA를 이용한 특성벡터 추출

센트럴 모멘트 중에서 높은 차수의 센트럴 모멘트에는 작은 차수의 모멘트에도 포함되어 있는 임여정보(redundant information)가 많다. 이렇게 임여정보를 가진 특성벡터는 실제로 표적구분단에 계산효율만 떨어뜨릴뿐 정확도에는 별로 기여하지 못한다. 따라서 PCA 기법을 이용하여 이러한 특성벡터 공간을 변환하여 임여정보(redundancy)를 줄이고 표적특성벡터의 차원을 줄일 수 있다^[5]. 먼저 \overline{f}_k 를

훈련 데이터 행렬 $\overline{\mathbf{F}}$ 의 k 번째 열벡터라고 하자. 그러면 PCA기법은 \overline{f}_k 를 다음과 같이 더 낮은 차원을 갖는 특성벡터 \mathbf{x}_k 로 바꾸어 준다.

$$\mathbf{x}_k = \mathbf{P}^T \overline{f}_k \quad (6)$$

식 (6)에서 \mathbf{P} 는 다음과 같은 형태의 변환 행렬이다.

$$\mathbf{P} = [\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_L], \quad (7)$$

여기서 \mathbf{v}_k 는 샘플 상호분산행렬(covariance matrix)의 가장 크기가 큰 k 개의 고유치(eigenvalue)에 대응하는 고유벡터(eigenvector)를 의미한다. 여기서 \mathbf{P} 를 만들기 위해 사용하는 샘플 상호분산행렬은 훈련 데이터 세트만을 이용하여 만든다는 것에 주의하여야 한다.

2-2 Subclass 개념

Subclass 개념이란 각 class를 그림 1과 같이 더 작은 단위의 subclass들로 나누어 구분하는 방법이다. 일단 subclass로 나누어지면, 구분기는 각 subclass를 모두 다른 class로 학습(training)시킨다. range profile이 각도에 따라 매우 달라지기 때문에 각도에 따라 큰 변화를 보이는 표적의 특성벡터를 서로 다른 subclass에 대응시켜 그룹화(grouping)하면, 결국 각도에 따른 특성벡터의 변화의 영향을 줄일 수 있다.

2-3 Subclass의 개수를 결정하기 위한 유전알고리즘

Subclass 개념을 적용하는데 있어서 문제가 될 수

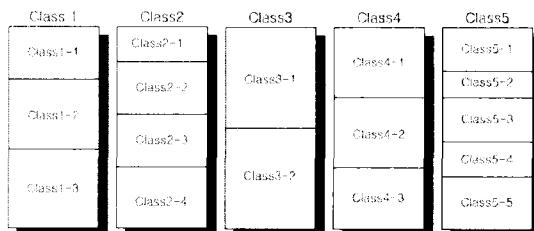


그림 1. Subclass 개념

Fig. 1. An example of subclass concept.

있는 것 중 하나가, 과연 subclass의 개수를 어떻게 정하는가 하는 것이다. 본 논문에서는 subclass의 개수를 구하기 위해서 정수형 유전알고리즘(Integer-coded GA)을 적용하였다^[7]. 유전 알고리즘은 다수의 개체(individual)들을 만들어 각각에 대해 교배(cross-over)와 돌연변이(mutation) 등의 진화 연산을 수행하여, 병렬화된 임의공간 검색(parallelized random search)을 통해 최적화된 해를 찾는 기법이다. 본 연구에서는 각 개체의 각 bit의 숫자를 각 class의 subclass의 개수에 대응시켜 정수형 유전 알고리즘을 적용하였다. 예를 들면 그림 2의 첫 번째 개체인 [2 9 8 4 1 10]은 첫 번째 class는 2개의 subclass로 나누고(개체의 첫 번째 bit가 2이기 때문에), 두 번째는 9개의 subclass들로, 세 번째는 8개의 subclass들로, ..., 마지막 6번째 class는 10개의 subclass로 나누게 된다는 뜻이다. 여기서 사용된 정수형 유전알고리즘은 그림 2, 3과 같은 형태의 교배와 돌연변이 진화 연산을 사용하게 된다.

Gene1 : 2 9	<table border="1"> <tr><td>8</td></tr> </table>	8	4 1 10
8			
Gene2 : 6 3	<table border="1"> <tr><td>5</td></tr> </table>	5	1 7 4
5			
Gene1' : 2 9	<table border="1"> <tr><td>5</td></tr> </table>	5	4 1 10
5			
Gene2' : 6 3	<table border="1"> <tr><td>8</td></tr> </table>	8	1 7 4
8			

그림 2. 교배 알고리즘

Fig. 2. Cross-over.

2 9

5

 4 1 10
Mod(5+n, max_gene)

그림 3. 돌연변이(mutation)

Fig. 3. Mutation.

위의 예에서 max_gene은 초기조건으로 사용하는 최대 subclass의 개수를 말하는 것이고, n은 1 ~ max_gene 사이의 임의의 정수를 말한다.

위의 유전알고리즘을 적용하기 위해서 측정된 데이터를 두개의 부분으로 나누어 하나는 training set으로 사용하고 하나는 validation set으로 사용하여, training set에 위의 알고리즘을 이용하여 구해진 subclass 개수만큼 각 class로 나눈 후 구분기를 훈련시키고, 이렇게 훈련된 구분기에 validation set으로

구분을 수행하여 그때 나온 구분성능(Pc : correct classification ratio)을 적합도함수(fitness function)로 하여 유전알고리즘을 수행하여 P_c 가 최대가 되는 최적의 subclass 개수를 결정하게 된다.

2-4 FCM(Fuzzy c-means Clustering)

본 논문에서는 훈련 특성벡터를 subclass들로 나누기 위해 FCM기법을 이용하였다. FCM 기법은 k-means clustering 기법에 fuzziness를 추가하여 clustering 하는 기법이다^[4]. 이러한 clustering 과정을 거치고 나면 training set 내의 여러 특성벡터들이 각각 어느 subclass에 속할지 각 cluster의 중심과의 거리를 이용해서 결정하고, 이렇게 결정된 subclass를 각 샘플의 새로운 class index로 사용하여 새로운 training set을 만들어 이를 이용하여 구분기를 학습하게 된다. 아래의 그림은 FCM기법을 수행하여 2 차원 특성공간상에 분포된 특성벡터를 3개의 cluster를 이용해서 clustering을 수행하는 예이다. 이 때 각 샘플의 색깔은 각 샘플이 어느 cluster에 속하는지를 나타내는 것이다. 이처럼 서로 다른 색깔에 속하는 샘플은 서로 다른 subclass에 속하게 된다.

III. 실험결과

제시될 모든 실험 결과들은 포항공대내의 단축거리 무반향설(POSTECH compact range)에서 F4, F14, F16, F117, F22, Mig29의 여섯 개의 축소모형

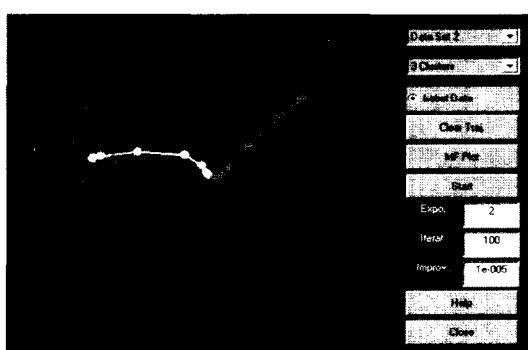


그림 4. FCM(Fuzzy c-means Clustering)의 예

Fig. 4. An example of FCM(Fuzzy c-means Clustering).

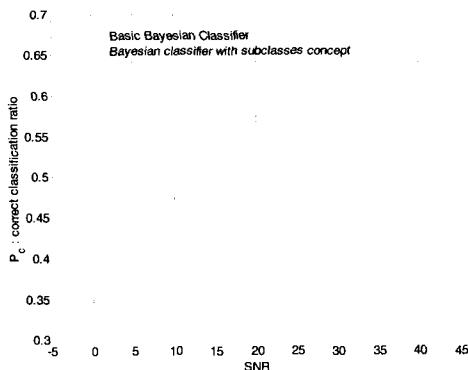


그림 5. Subclass 개념을 사용한 classifier와 기본적인 Bayes classifier의 성능비교(IFFT range profile 이용)

Fig. 5. The performance comparisons of the simple Bayes classifier and the classifier with subclass concept(using IFFT range profile).

에 대해 실험한 결과이다. 이 다섯 개의 축소모형은 대략 1/16으로 축소된 것이고 모든 모형이 길이가 1 미터 정도 된다. 위의 구분실험을 위해 여섯 개의 축소모형에 대해서 0~180°의 관측각에서 0.5°의 간격으로 측정하였고, 각 관측각마다 8.3~12.3 GHz의 주파수 대역에서 401 point로 sampling하여 측정하였다. 이중에서 0°부터 1° 간격으로 sampling 하여 training vector로 선택하여, 구분기를 훈련하는데 사용하였고, 나머지 0.5°부터 1° 간격으로 test vector를 선택하여 제안된 subclass 개념을 이용한 구분기의 구분성능을 시험하였다.

그림 5는 IFFT(Inverse Fast Fourier Transform)를 이용하여 range profile을 계산하였을 경우에 대해 앞서 설명한 표적인식기법을 사용하여, subclass 개념을 이용한 Bayes 구분기와 일반적인 Bayes 구분기를 측정데이터에 적용하여 구분실험을 행한 결과이다. 이때 subclass 개념을 이용한 구분결과는 미리 정수형 유전 알고리즘을 적용하여, 최적의 subclass 를 결정하고 이렇게 결정된 최적의 subclass 개수를 이용하여 각 class마다 서로 다른 개수의 subclass를 사용하여 구분한 결과를 나타낸 것이다. 잡음에 대한 영향을 알아보기 위해서 잡음(noise)를 첨가하여 서로 다른 SNR에서 실험을 수행하였고, 결과의 정확성을 높이기 위해서 각 SNR에 대해 같은 실험을

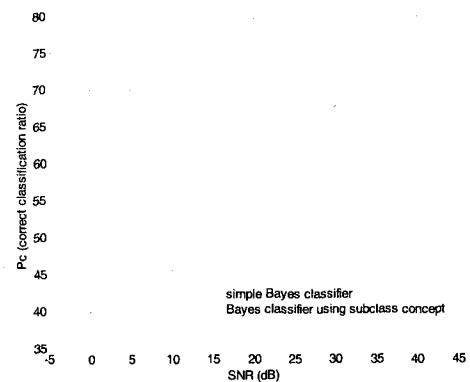


그림 6. Subclass 개념을 사용한 classifier와 기본적인 Bayes classifier의 성능비교(IFFT range profile 이용)

Fig. 6. The performance comparisons of the simple Bayes classifier and the Bayeclassifier with subclass concept(using the MUSIC range profile).

10번 반복하여 나온 구분 성능을 평균내었다.

그림 5에서 알 수 있듯이 subclass 개념을 이용하면 SNR이 10 dB이상인 경우 subclass를 적용하지 않은 것에 비해 우수한 성능을 보이는 것을 알 수 있다.

그림 6은 고해상도 스펙트럼(spectrum) 예측기법인 MUSIC(Multiple Signal Classification) 기법^[6]을 이용하여 고해상도의 range profile을 추출하고 이렇게 추출된 range profile에 대해 구분한 결과를 보여준다. 전체적인 구분성능이 IFFT를 이용하여 range profile을 추출한 후 구분한 경우에 비해 더욱 우수한 것을 확인할 수 있다. 또한 고해상도 range profile을 이용하여 구분하는 경우 더욱 subclass에 의한 성능 개선 효과가 크다는 것을 그림 6을 통해 알 수 있다.

IV. 결 론

본 연구에서는 range profile을 이용하여 구분실험을 행하는데 있어서 제일 큰 문제점인 관측각 확장에 따른 구분성능의 저하를 해결하기 위해 subclass 개념을 제안하였다. 이렇게 subclass를 이용하면 관측각에 따른 특성벡터의 변화를 각 subclass가 적절

히 학습하게 되어 일반적인 Bayes classifier를 바로 적용하는 경우에 비해 매우 우수한 성능을 보이는 것을 구분 실험을 통해 확실할 수 있었다.

참 고 문 헌

- [1] H.-J. Li, S.-H. Yang, "Using range profile as feature vectors to identify aerospace projects", *IEEE trans. on Antennas and Propagation*, vol. 41, no. 3, March 1993.
- [2] J. Tang, Z. Zhu, "Comparison study on high resolution radar target recognition", *Proceedings of the IEEE 1996 National*, vol. 1, 1996.
- [3] K.-T. Kim, D.-K. Seo and H.-T. 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, March 2002.
- [4] J.-S. R. Jang, C.-T. Sun and E. Mizutani, *Neuro-Fuzzy and Soft Computing*, Prentice Hall, 1997.
- [5] S. Haykin, *Neural Networks : A comprehensive foundation*, 2nd Edition, Prentice Hall, 1998.
- [6] R. O. Schmidt, "Multiple emitter location and signal parameter estimation", *IEEE trans. on Antennas and Propagation*, vol. 34, no. 3, March 1986.
- [7] T. Yokota, M. Gen, "Solving for nonlinear integer programming problem using genetic algorithm and its application", *IEEE International Conference on Systems, Man, and Cybernetics*, vol. 2, pp. 1602-1609, 1994.

서 동 규



1999년 2월: 홍익대학교 전자전기
제어공학과 (공학사)
2001년 2월: 포항공과대학교 정보
통신대학원 (공학석사)
2001년 3월~현재: 포항공과대학
교 전자공학과 박사과정
[주 관심분야] 레이더 표적인식,
레이더 신호처리, RCS 측정

김 경 태



1994년 2월: 포항공과대학교 전자
전기공학과 (공학사)
1996년 2월: 포항공과대학교 전자
전기공학과 (공학석사)
1999년 2월: 포항공과대학교 전자
전기공학과 (공학박사)
1999년 3월~2001년 2월: 포항공과
대학교 전자전기공학과 연구원
2001년 2월~2002년 2월: 포항공과대학교 전자전기공학
과 연구조교수
2002년 2월~현재: 영남대학교 전자정보공학부 전임강사
[주 관심분야] 레이더 표적인식, 레이더 영상, 어레이 신
호처리

김 효 태



1978년 2월: 서울대학교 전자공학
과 (공학사)
1982년 2월: 서울대학교 전자공학
과 (공학석사)
1986년 2월: 미국 오하이오 주립대
학 (공학박사)
1986년 3월~현재: 포항공과대학
전자전기공학과 교수
[주 관심분야] 전자파 산란해석, stealth 설계, RCS 예측
및 측정