

다중 각도 정보를 이용한 표적 구분 알고리즘 비교에 관한 연구

A Comparative Study of Algorithms for Multi-Aspect Target Classifications

정 호령 · 김 경태* · 김 효태

Ho-Ryung Jung · Kyung-Tae Kim* · Hyo-Tae Kim

요약

일반적인 시간 영역에서의 레이더 신호들은 표적의 관측각에 민감하게 변화한다. 이로 인하여 각도가 넓어짐에 따라서 표적 구분의 정확도가 상당히 감소하게 된다. 이러한 문제를 해결하기 위하여 본 논문에서는 다중 각도 정보를 이용하여 표적 구분 성능을 향상시키기 위한 방법을 제시한다. 먼저, 대표적인 시간영역 레이더 신호인 1차원 range profile로부터 central moments와 PCA를 결합하여 특성벡터를 추출한다. 추출된 특성벡터에 다중 각도 정보를 사용하는 구분기를 적용시켜 넓은 관측각에서 표적 인식 성능을 향상시킬 수 있다. 다중 각도 정보를 이용하는 기법에는 독립방식과 종속방식이 있으며, 본 논문에서는 두 기법의 성능을 비교한다. 성능 비교 실험에는 포항공대 단축거리 무반향실에서 측정된 여섯 개의 항공기 모델에 대한 레이더 단면적 데이터가 이용된다.

Abstract

The radar signals are generally very sensitive to relative orientations between radar and target. Thus, the performance of a target recognition system significantly deteriorates as the region of aspect angles becomes broader. To address this difficulty, in this paper, we propose a method based on the multi-aspect information in order to improve the classification capability even for a wide angular region. First, range profiles are used to extract feature vectors based on the central moments and principal component analysis(PCA). Then, a classifier with the use of multi-aspect information is applied to them, yielding an additional improvement of target recognition capability. There are two different strategies among the classifiers that can fuse the information from multi-aspect radar signals: independent methodology and dependent methodology. In this study, the performances of the two strategies are compared within the frame work of target recognition. The radar cross section(RCS) data of six aircraft models measured at compact range of Pohang University of Science and Technology are used to demonstrate and compare the performances of the two strategies.

Key words : HMM, Majority Vote, Sum Vote, Target Classification, Multi-Aspect

I. 서 론

레이더 표적인식기법은 레이더에 의해 발견된 미지의 표적으로부터 산란하는 신호를 분석하여 표적의 종류를 구분하는 기법이다. 과거의 레이더 시스

템들은 단지 표적의 거리와 속도 등의 간단한 정보만을 얻을 수 있었지만^[1], 최근에는 레이더 시스템이 전장에서 발견된 표적에 대해서 공격목표인지 아닌지를 결정하여 빠른 판단을 할 수 있도록 돋겨나, SAR(Synthetic Aperture Radar) 등의 영상 레이더 시

포항공과대학교 전자전기공학과(Department of Electronic and Electrical Engineering, Pohang University of Science and Technology)

*영남대학교 전자전기공학부(School of Electrical and Computer Engineering, Yeungnam University)

· 논문 번호 : 20040402-041

· 수정완료일자 : 2004년 5월 6일

스템과 결합하여 전장의 상황을 판단하고 전략 및 전술을 확립하기 위해 필요한 정보를 공급하는 능력을 가져야 하는 등, 레이더 시스템에 대한 요구사항이 점차 증가하고 있는 상황이다^{[2],[3]}.

레이더 표적인식에 쓰일 특성벡터는 다음과 같은 특징이 있어야 한다. 일단 특성벡터의 크기가 작아야 하며, 잡음에 강하고, 실시간 처리가 가능해야 한다. 실제 상황에서는 구분해야 할 표적의 종류가 매우 많으므로 특성벡터의 크기가 커질 경우 상당히 큰 데이터베이스가 필요하게 되며 데이터베이스를 처리하기 위한 계산시간도 늘어나게 된다^[4]. 따라서 잡음에 강하면서도 크기가 작은 특성벡터가 요구된다. 이런 특성벡터를 구하기 위해서 레이더 표적인식에서는 표적의 RCS(Radar Cross Section) 값을 이용한다. 일반적으로 표적의 RCS는 측정 주파수와 각도에 상당히 의존적인 경향을 보이게 된다. 이러한 RCS의 주파수-각도 의존 경향을 해결하고 효과적이고 강건한 특성벡터를 얻기 위하여 range profile, ISAR(Inverse Synthetic Aperture Radar) 영상, 고유 주파수(natural frequency), 시간-주파수 신호가 사용되고 있다.

잡음에 강인(robust)하면서도 실시간 처리를 가능하게 하기 위해서는 1차원 range profile에 기반을 둔 방법들이 매우 유망하다^[5]. 그러나 고유 주파수와 시간-주파수 영역 해석법과 같은 주파수 영역에서의 특성벡터들은 관측각에 상관없이 일정한 결과를 보여주는 반면, 1차원 range profile 기법의 경우에는 관측각에 따라 결과가 민감하게 변화하는 문제가 있다. 따라서 [6]에서는 1차원 range profile을 이용하는 표적인식 알고리즘에서 관측각을 확장할 경우 발생하는 표적인식 성능의 저하를 해결하기 위해 subclass 개념을 적용하여 구분 성능을 향상시키는 기법을 개발하였다.

[6]에서는 subclass의 개수를 구하기 위해서 정수형 유전 알고리즘(integer-code GA)을 적용하였다. 하지만, Subclass의 개수를 구하기 위해 유전 알고리즘이 구분 알고리즘에 포함됨으로써 구분기 설계시간이 증가하였고, 같은 유전 알고리즘일지라도 개체(individual)의 초기치가 최적화 값에 근접하지 않을 경우 초기 수렴에 빠질 가능성성이 있다^[7]. 본 논문에서는 이러한 문제를 해결하기 위하여 유전 알고리즘

의 적용 없이 다중 각도 정보를 이용하는 구분방식을 제안하고, 이를 크게 독립방식과 종속방식으로 나눈 후 각각의 시뮬레이션 결과를 제시할 것이다.

독립방식은 [8]에서 제시된 방법과 같이 IFFT (Inverse Fast Fourier Transform) range profile과 central moment를 이용하여 특성벡터를 추출한 뒤 PCA (Principal Component Analysis)를 이용하여 훈련 데이터베이스를 구성한다. 이후 얻어진 훈련 데이터베이스를 이용하여 Bayes 구분기를 설계한 뒤, 여러 개의 각도에서 추출한 실험 특성벡터를 Bayes 구분기에 입력한 결과를 종합하여 최종적으로 표적이 어떤 클래스에 속하는지 구분하는 방식이다.

종속방식은 HMM(Hidden Markov Model)을 구분기로 이용하는 방법으로써 측정된 RCS 주파수 데이터로부터 IFFT range profile을 얻고 이로부터 central moment를 이용하여 특성벡터를 추출한 뒤 PCA를 이용하여 최종 훈련 데이터베이스를 얻는 과정은 [8]에서 제시된 방법과 동일하며 이후는 [9]에서 제시된 방법처럼 훈련 데이터베이스를 FCM(Fuzzy c-means Clustering)으로 코드화하고 이 코드들을 이용하여 HMM의 파라미터들을 결정하게 된다. 마지막으로 실험 특성벡터 열을 HMM에 입력하고 가장 높은 HMM 출력 값을 가지는 클래스에 표적을 할당하게 된다.

본 논문의 실험은 위 두 가지 방식에 동일한 파라미터 값을 적용한 후 훈련 데이터의 크기, 실험 데이터 열의 개수 및 각도 샘플링 간격, 신호 대 잡음비(SNR)와 같은 파라미터들을 변화시켜 가면서 각 방식의 구분 확률이 어떤 식으로 변화하는지 관찰할 것이다. 두 가지 기법의 성능비교를 하기 위하여 포항공대의 단축거리 무반향설(compact range)에서 측정한 여섯 개 항공기 모델의 RCS 주파수 데이터가 사용되었다.

II. 센트럴 모멘트에 기초한 특성벡터 추출

2-1 IFFT Range Profile

표적을 구분하기 위해서는 표적에서 측정된 RCS 주파수 데이터를 이용하여 range profile을 생성하는 과정이 필요하다. RCS 주파수 데이터에서 range profile을 생성할 시 IFFT 기법 또는 MUSIC(Multiple

Signal Classification) 기법을 이용한다.

N 개의 값으로 구성되어 있는 이산신호(discrete signal) $x(n)$ 이 존재한다고 가정할 때, $x(n)$ 의 DFT (Discrete Fourier Transform)는 다음과 같이 정의할 수 있다.

$$X(k) = \sum_{n=0}^{N-1} x(n) \exp\left[-j\frac{2\pi}{N} nk\right]$$

$$k = 0, 1, 2, \dots, N-1 \quad (1)$$

FFT(Fast Fourier Transform)는 식 (1)에 포함되어 있는 $\exp[-j2\pi/N]i$ 주기성을 가지고 있다는 것을 이용하여 N^2 에 비례하는 DFT의 계산량을 $N \log N$ 까지 감소시킨 알고리즘이다. IFFT(Inverse Fast Fourier Transform)는 FFT의 역변환으로 이산 주파수 신호에서 이산 시간 신호를 재생성하는 알고리즘이다. 본 논문에서는 MUSIC에 비해 상대적으로 처리속도가 빠른 IFFT range profile을 구분 실험에 이용한다.

2-2 센트럴 모멘트

모멘트와 모멘트 함수는 다양한 이미지 패턴으로부터 물체 위치의 이동이나 절대적인 신호레벨에 의한 변화에 민감하지 않은 특성벡터를 구할 수 있기 때문에 여러 분야에 응용되고 있다^[8].

표적으로부터 얻어진 RCS 주파수 데이터로부터 1차원 range profile을 구하고 나면 p 차 센트럴 모멘트는 다음과 같이 계산할 수 있다.

$$\mu_p = \sum_{i=1}^N (r_i - \eta_r)^p \left[\frac{\bar{p}_m(r_i)}{\sum_{i=1}^N \bar{p}_m(r_i)} \right] \quad (2)$$

$$\eta_r = \sum_{i=1}^N r_i \left[\frac{\bar{p}_m(r_i)}{\sum_{i=1}^N \bar{p}_m(r_i)} \right], \quad r_i \in [0, R_u] \quad (3)$$

위 수식에서 $\bar{p}_m(r_i)$ 은 range profile의 최대 크기를 1로 정규화 한 range profile이고 N 은 range profile 샘플링 개수이며 R_u 는 maximum unambiguous range이다. 식 (2)의 센트럴 모멘트는 range profile의 무게중심을 기준으로 계산되었기 때문에 위치이동 불변특성(translational invariance)을 가진다. 따라서 표적까지의 거리가 변화하더라도 거리의 변화에 상관없이 일정한 표적구분성능을 얻을 수 있다^[10]. 그리고 range profile의 크기를 정규화한 것은 표적으로부터 오

는 산란파의 절대적인 레벨에 의존하지 않도록 하기 위한 것이다.

식 (2)와 (3)을 이용하여 센트럴 모멘트를 구한 뒤 특성벡터 f 는 다음과 같이 표현할 수 있다.

$$f = [f_1, f_2, \dots, f_{p_{max}}]^T$$

$$= [\mu_1, \mu_2, \dots, \mu_{p_{max}}]^T \quad (4)$$

식 (4)에서 p_{max} 는 특성벡터에 사용될 최대 센트럴 모멘트 차수를 의미한다.

구분기를 설계하기 위해서 서로 다른 여러 개의 표적과 서로 다른 관측각(aspect angle)에서 측정된 데이터의 특성벡터들을 포함하는 훈련 데이터 베이스가 필요하다. 만약 N_c 개의 표적 클래스와 각 클래스별로 N_a 개의 각도 정보가 있다고 가정한다면 식 (4)을 이용하여 훈련 데이터베이스 F 는 다음과 같이 구성할 수 있다.

$$F = \begin{bmatrix} f_{11} & f_{12} & \cdots & f_{1Q} \\ f_{21} & f_{22} & \cdots & f_{2Q} \\ \vdots & \vdots & \ddots & \vdots \\ f_{p_{max}1} & f_{p_{max}2} & \cdots & f_{p_{max}Q} \end{bmatrix} \quad (5)$$

식 (5)에서 $Q=N_c \times N_a$ 이며 F 는 $P_{max} \times Q$ 행렬이 된다.

식 (2)에서 얻은 센트럴 모멘트의 크기는 센트럴 모멘트의 차수가 커질 경우 빠르게 감소하게 되므로 F 의 원소인 f_{ij} 또한 i 가 증가할 경우 급격히 감소하게 된다. 그러나 특성벡터를 구성하는 각 센트럴 모멘트들은 p 값과 관계없이 동일한 가중치를 가져야 하므로 다음과 같이 F 행렬의 열벡터 성분의 가중치를 없애준다.

$$f_{ij} = \frac{f_{ij} - f_{i, \min}}{f_{i, \max} - f_{i, \min}}$$

$$i = 1, 2, \dots, p_{max}, \quad j = 1, 2, \dots, Q \quad (6)$$

식 (6)에서 $f_{i, \min}$ 과 $f_{i, \max}$ 는 F 행렬 각각의 열벡터 성분 중에서 최대값과 최소값을 의미한다. 식 (5)를 이용하여 정규화된 훈련 데이터베이스 \bar{F} 는 다음과 같이 정의할 수 있다.

$$\bar{F} = \begin{bmatrix} \bar{f}_{11} & \bar{f}_{12} & \cdots & \bar{f}_{1Q} \\ \bar{f}_{21} & \bar{f}_{22} & \cdots & \bar{f}_{2Q} \\ \vdots & \vdots & \ddots & \vdots \\ \bar{f}_{p_{max}1} & \bar{f}_{p_{max}2} & \cdots & \bar{f}_{p_{max}Q} \end{bmatrix} \quad (7)$$

2-3 PCA를 이용한 특성벡터 차원 감소

센트럴 모멘트는 차수 p 가 증가할수록 더욱더 많은 임여정보를 가지게 된다^[8]. 특성벡터에 포함된 임여정보는 올바른 구분 확률의 증가에 도움이 되지 않고 단지 계산시간의 증가만 가져오게 된다. 따라서 본 논문에서는 특성벡터의 임여정보를 없애기 위하여 PCA 기법을 사용하였다. PCA를 사용함으로 인하여 특성벡터의 임여정보를 줄일 수 있으며 특성벡터의 차원 또한 함께 줄일 수 있는 장점이 있다^[10].

먼저 \mathbf{f}_k 를 훈련 데이터 행렬 \mathbf{F} 의 k 번째 열벡터라고 가정한다면 PCA는 \mathbf{f}_k 를 다음과 같이 더 낮은 차원을 갖는 특성벡터 \mathbf{x}_k 로 바꾸어 준다.

$$\mathbf{x} = \mathbf{P}^T \mathbf{f}_k \quad (8)$$

식 (8)에서 \mathbf{P} 는 다음과 같은 형태의 변환행렬이다.

$$\mathbf{P} = [\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_l] \quad (9)$$

여기서 \mathbf{v}_k 는 샘플 상호분산행렬(sample covariance matrix)의 가장 크기가 큰 l 개의 고유치(eigenvalue)에 대응하는 고유벡터(eigenvector)를 의미한다. 여기서 \mathbf{P} 를 만들기 위해 사용하는 샘플 상호분산행렬은 훈련 데이터베이스만을 이용하여 만들고 변환행렬 \mathbf{P} 는 실험 특성벡터의 차원을 줄일 때도 이용된다.

III. 다중각도 정보를 이용한 표적 구분

3-1 다중 각도정보를 이용하는 구분 기법들

다중 각도정보 구분 기법은 기존에 쓰이던 하나의 range profile만을 구분에 이용하는 것이 아니라 동시에 여러 개의 서로 다른 각도에서 측정한 range profile을 표적 구분에 이용하는 것이다. 하나의 range

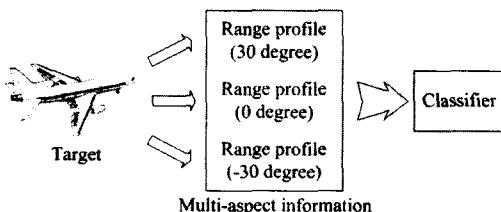


그림 1. 다중 각도정보를 이용한 표적 구분
Fig. 1. Radar target recognition by using multi-aspect information.

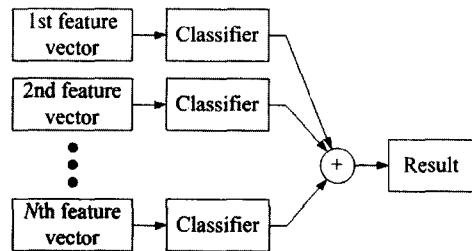


그림 2. 독립방식을 이용한 구분 방식

Fig. 2. Target recognition by using independent classification method.

profile은 하나의 각도에 대한 표적의 정보를 포함하고 있기 때문에 여러 개의 range profile을 동시에 이용할 경우 여러 개의 각도정보를 동시에 표적 구분에 이용하는 것이 된다. 다중 각도정보와 같이 여러 개의 입력이 구분기에 들어왔을 경우 이를 동시에 처리하는 방식은 독립방식과 종속방식 두 가지가 있다.

독립방식은 그림 2에서와 같이 여러 개의 입력을 각각 동일한 구분기에 넣은 뒤 얻어진 결과를 종합하여 입력된 특성벡터들이 어떤 클래스에 속하는지 결정하는 구분 방식이다. 각각의 결과를 종합하는 방법에는 max rule, min rule, sum vote(median) rule, majority vote rule이 있으며^[11], 본 논문에서는 위 다섯 가지 방식 중 구분기 결합 기법에서 일반적으로 가장 많이 사용되는 majority vote와 sum vote 두 가지 방식을 이용하여 구분 실험을 하였다^[12].

종속방식은 독립방식처럼 여러 개의 특성벡터들을 따로따로 취급한 후 그 결과를 종합하는 것이 아니라 입력된 특성벡터들의 순서 또한 특성벡터들의

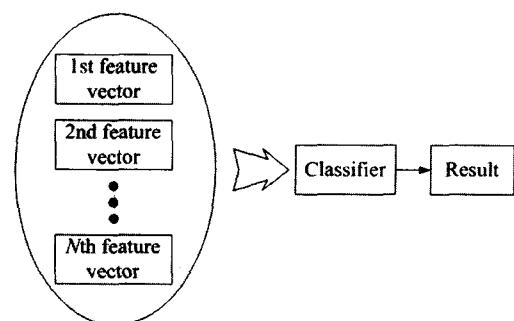


그림 3. 종속방식을 이용한 구분 방식

Fig. 3. Target recognition by using dependent classification method.

값과 마찬가지로 구분 결과에 영향을 미치는 방식이다. 독립방식에서는 특성벡터가 같으면 그 순서가 뒤바뀌더라도 동일한 결과를 출력하지만 종속방식에는 특성벡터가 같더라도 그 순서가 다르다면 다른 결과를 출력하게 된다.

각도 정보에 따른 특성벡터의 변화를 이용하여 구분기를 설계하는 방법은 HMM이 대표적이며 본 논문에서는 [9]에서 제시된 fuzzy c-means clustering과 HMM을 이용한 방식으로 구분 실험을 하였다.

3-2 독립방식

여러 개의 특성벡터가 존재할 경우 패턴을 결정하는 기본적인 Bayesian 결정 규칙(decision rule)은 다음과 같다.

$$\text{assign } Z \rightarrow \omega_j \quad \text{if} \\ P(\omega_j | \mathbf{x}_1, \dots, \mathbf{x}_R) = \max_k P(\omega_k | \mathbf{x}_1, \dots, \mathbf{x}_R) \quad (10)$$

식 (10)에서 Z 는 특정 패턴을 의미하며 m 은 클래스 ($\omega_1, \omega_2, \dots, \omega_m$)의 총 개수이다. \mathbf{x}_i ($i=1, \dots, R$)는 패턴 Z 에서 측정된 특성벡터를 의미하며 R 은 측정된 특성벡터의 총 개수이다. 그리고 $P(\omega_j | \mathbf{x}_1, \dots, \mathbf{x}_R)$ 는 posteriori 확률 밀도 함수를 의미한다. 식 (10)에서 볼 수 있듯이 Bayesian 결정 규칙은 결론을 이끌어내기 위하여 모든 특성벡터를 동시에 이용한다. 이런 방식은 구분 확률의 오류를 최소로 줄일 수 있지만 posteriori 확률 밀도 함수를 계산하기 위해서는 likelihood 확률 밀도 함수 $P(\mathbf{x}_1, \dots, \mathbf{x}_R | \omega_j)$ 를 계산해야 하는데, 일반적으로 큰 R 값으로 인해서 likelihood 확률 밀도 함수를 구하기가 상당히 힘들기 때문에 Bayesian 결정 규칙을 이용한 구분기를 실제로 구현하기에는 상당한 어려움이 따른다^[11]. 따라서 실제 상황에 적용할 수 있는 구분기를 설계하기 위해서는 결정 규칙은 간단한 것을 사용하고 여러 개의 특성벡터를 결정 규칙에 적용한 결과를 종합하는 방식의 구분기를 설계하는 것이 좋다.

Sum vote 규칙은 다음과 같이 표현할 수 있다.

$$\text{assign } Z \rightarrow \omega_j \quad \text{if} \\ \frac{1}{R} \sum_{i=1}^R P(\omega_j | \mathbf{x}_i) = \max_{k=1}^m \frac{1}{R} \sum_{i=1}^R P(\omega_k | \mathbf{x}_i) \quad (11)$$

식 (11)에 사용된 결정 방식은 R 개의 특성 벡터가 입

력으로 들어왔을 경우 패턴 Z 를 최대의 posteriori 확률 밀도 함수 평균을 가지는 클래스에 할당한다.

Majority vote 규칙은 다음과 같이 표현할 수 있다.

$$\text{assign } Z \rightarrow \omega_j \quad \text{if} \quad \sum_{i=1}^R \Delta_{ij} = \max_{k=1}^m \sum_{i=1}^R \Delta_{ki} \quad (12)$$

식 (12)에서 Δ_{ij} 는 j 번째 특성벡터가 m 개의 posteriori 확률 밀도 함수에 입력으로 들어갔을 경우, i 번째 클래스의 posteriori 확률 밀도 함수가 나머지 클래스의 posteriori 확률 밀도 함수보다 큰 값을 가질 경우는 1의 값을 가지며 그 이외의 경우는 0의 값을 가진다. 즉 majority vote rule은 각각의 특성벡터를 입력으로 넣었을 경우 가장 많은 개수의 posteriori 확률 밀도 함수 최대 값을 가지는 클래스에 패턴 Z 를 할당한다.

Majority vote 규칙과 sum vote 규칙을 이용할 시 posteriori 확률 밀도 함수를 계산하는 것이 필요하고 이를 위해서 본 논문에서는 Bayes 구분기를 사용하였다. posteriori 확률 밀도 함수를 Bayes 규칙을 이용하여 재정리하면 다음과 같다.

$$P(\omega_k | \mathbf{x}_1, \dots, \mathbf{x}_R) = \frac{P(\mathbf{x}_1, \dots, \mathbf{x}_R | \omega_k) P(\omega_k)}{P(\mathbf{x}_1, \dots, \mathbf{x}_R)} \quad (13)$$

식 (13)에서 posteriori 확률 밀도 함수는 likelihood 확률 밀도 함수 $P(\mathbf{x}_1, \dots, \mathbf{x}_R | \omega_j)$ 와 prior 확률 밀도 함수 $P(\omega_j)$ 및 evidence 확률 밀도 함수 $P(\mathbf{x}_1, \dots, \mathbf{x}_R)$ 를 이용하여 구할 수 있다. 그러나 실제 evidence 확률 밀도 함수는 클래스에 무관하고 일반적인 경우 prior 확률 밀도 함수에 관한 정보를 알 수 없기 때문에 prior 확률 밀도 함수는 모든 클래스에 동일한 값을 가진다고 가정한다. 이런 가정을 적용할 경우 $P(\mathbf{x}_1, \dots, \mathbf{x}_R)$ 와 $P(\omega_j)$ 는 상수로 취급할 수 있고 posteriori 확률 밀도 함수를 likelihood 확률 밀도 함수로 대체해서 사용하는 것이 가능하다.

다중 변수 정규 분포와 동일한 prior 확률 밀도 함수를 이용한 likelihood 확률 밀도 함수는 다음과 같다.

$$g_i(\mathbf{x}_u) = -\frac{1}{2} \log |\mathbf{C}_i| \\ -\frac{1}{2} (\mathbf{x}_u - \mathbf{m}_i)^T \mathbf{C}_i^{-1} (\mathbf{x}_u - \mathbf{m}_i) \quad (14)$$

식 (14)에서 \mathbf{C}_i 는 i 번째 클래스에 속하는 특성벡터들의 상호분산 행렬이며 \mathbf{m}_i 는 i 번째 클래스에 속하는

특성벡터들의 평균벡터를 의미한다. \mathbf{x}_i 는 구분기에 입력되는 훈련벡터를 의미한다. 식 (13)에 의해서 구해진 likelihood 확률 밀도 함수는 posterior 확률 밀도 함수의 경향을 따라 가기 때문에 sum vote 규칙과 같은 soft 결정 방식에도 적용할 수 있다.

3-3 종속방식

만일 하나의 특성벡터가 입력으로 들어오지 않고 순서가 정해진 특성벡터 열이 입력으로 들어올 경우 하나의 입력만을 가정하고 설계된 Bayes 구분기로 특성벡터 열의 순서를 출력에 반영할 수 없다. 반면 HMM은 입력된 각각의 특성벡터가 어떠한 값을 가지는가와 동시에 특성벡터의 입력 순서를 고려하기 때문에 특성벡터 열의 순서까지 고려된 출력 결과를 얻고 싶을 경우 HMM을 이용한 구분기가 적당하다. 따라서 같은 특성벡터 집합이라도 그 순서가 달라질 경우 HMM 구분기가 출력하는 posterior 확률 밀도 함수값 또한 달라진다.

그림 4에서 $\omega_1, \dots, \omega_3$ 은 hidden state를 의미하며, v_1, v_2, v_3 는 각 hidden state에서 나올 수 있는 출력을 의미한다. a_{ij} 는 i 번째 hidden state에서 j 번째 hidden state로 state가 천이될 확률을 의미하며 b_{ik} 는 i 번째 hidden state에서 k 번째 출력이 나올 확률을 의미한다. 만일 hidden state의 개수를 N 이라 하고 출력의 개수를 M 이라고 가정한다면 a_{ij} 를 행렬의 원소로 가지는 $N \times N$ 행렬 \mathbf{A} 를 구성할 수 있으며 이 행렬은 상태 천이 확률분포(state transition probability distribution)라 한다. 또한 b_{ik} 를 행렬의 원소로 가지는 $N \times M$ 행렬 \mathbf{B} 를 구성할 수 있으며 이를 관찰 기호 확률분

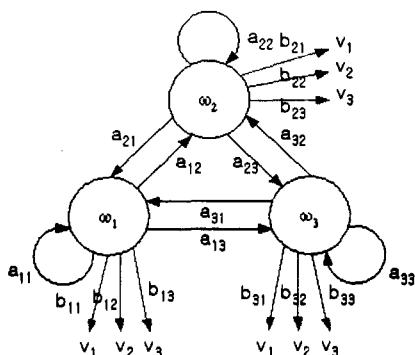


그림 4. 3개의 hidden state를 가진 HMM
Fig. 4. Three hidden state HMM.

포(observation symbol probability distribution)라 한다. 그림 3에서는 나타나 있지 않지만 hidden state가 존재하지 않는 상태에서 특정 hidden state로 초기화할 확률을 나타내는 $N \times 1$ 행렬 π 가 있으며 이를 초기 상태 분포(initial state distribution)라 한다. HMM 구분기를 설계하기 위해서는 먼저 이 세 개의 행렬을 각각의 클래스별로 정의한 뒤 적절한 방식으로 초기화시킨다^[9]. 그 다음 훈련 데이터에서 각각의 클래스에 해당하는 훈련 특성벡터 열과 Baum-Welch's algorithm^[13]을 이용하여 \mathbf{A} , \mathbf{B} , π 행렬의 값을 변화시키게 된다. 마지막으로 주어진 훈련 특성벡터 열과 각 클래스별 \mathbf{A} , \mathbf{B} , π 행렬을 이용하여 각 클래스별 posterior 확률 밀도 함수를 얻고 이를 이용하여 입력된 훈련 특성벡터가 어떤 클래스에 속하는지 결정하게 된다.

IV. 실험결과

4장에서 제시될 모든 실험 결과들은 포항공대 내의 단축거리 무반향실(compact range)에서 F4, F14, F16, F22, F117, MIG 29의 여섯 개의 1/16 축소모형에 대해 실증한 결과이다. 그림 5에서 볼 수 있듯이 구분실험을 위해 여섯 개의 축소모형별로 표적 정면을 기준으로 0~180°의 관측각에서 0.5° 간격으로 RCS 주파수 데이터를 측정하였다.

각 관측각의 주파수 데이터는 8.3~12.3 GHz의 주파수 대역에서 동일한 주파수 간격으로 401 point로 샘플링한 데이터로 구성되어 있다.

그림 6~8은 표적의 정면을 기준으로 30° 각도에서 측정한 각 표적의 range profile을 나타낸 것이다.

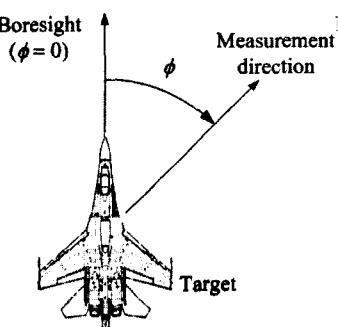


그림 5. Range profile 관측각 변화방향
Fig. 5. Target measurement direction change.

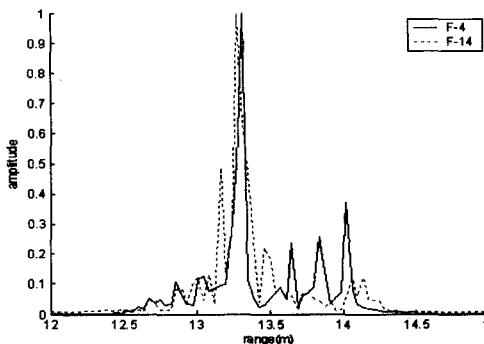


그림 6. $\phi=30^\circ$ 에서 측정한 F-4와 F-14의 range profile
Fig. 6. F-4 and F-14's range profile($\phi=30^\circ$).

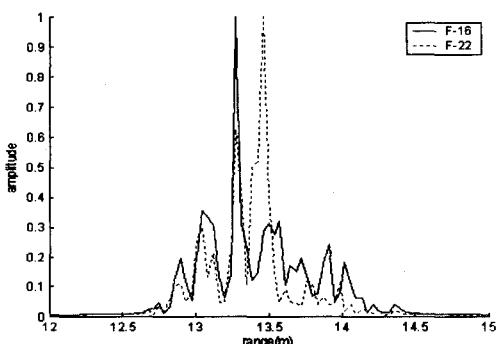


그림 7. $\phi=30^\circ$ 에서 측정한 F-16와 F-22의 range profile
Fig. 7. F-16 and F-22's range profile($\phi=30^\circ$).

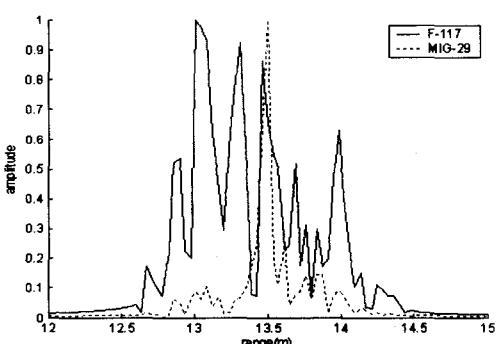


그림 8. $\phi=30^\circ$ 에서 측정한 F-117와 MIG-29의 range profile
Fig. 8. F-117 and MIG-22's range profile($\phi=30^\circ$).

그림에서 볼 수 있는 것처럼 크게 산란되는 위치가 표적마다 다르게 나타나는 것을 알 수 있다.

4장의 실험은 크게 다섯 가지로 나누어진다. 첫 번째 실험은 구분기를 훈련하기 위해 필요한 훈련 데이터베이스의 크기를 변화시켰을 때 이 변화가 구

분 성능에 어떤 영향을 미치는지 알아보는 실험이다. 두 번째 실험은 훈련 데이터베이스를 구성하는 특성벡터 열의 원소 개수를 변화시켰을 때 이 변화가 구분 성능에 어떤 영향을 미치는지 알아보는 실험이다. 세 번째 실험은 특성벡터 열이 차지하는 각도 범위는 일정하게 유지한 채 특성벡터 열의 원소 개수를 변화시켰을 때 이 변화가 구분 성능에 어떤 영향을 미치는지 알아보는 실험이다. 네 번째 실험은 특성벡터 열의 원소 개수는 유지하면서 원소간의 샘플링 각도를 조정하는 것이 구분 성능에 어떤 영향을 미치는지 알아보는 실험이다. 다섯 번째 실험은 SNR을 변화시킬 경우 구분 성능에 어떤 변화가 있는지 알아보는 실험이다. 각각의 실험은 서로 다른 AWGN(Additive White Gaussian Noise)을 SNR에 맞게 추가한 100개의 주파수 데이터를 이용하여 100회 Monte-Carlo 반복 실험을 하였다. 각 실험마다 공통적으로 사용되는 파라미터들은 표 1에 나타나 있다.

그림 9는 표 1의 파라미터에서 훈련/실험데이터 비율을 1에서 5까지 1 간격으로 변화시키면서 100회 Monte-Carlo 반복 실험에서 나온 전체 결과의 평균값을 그린 것이다. 훈련 데이터베이스를 구축할 때에는 특성벡터의 분포가 한 각도 근처로 편향되지 않도록 전 각도 범위에서 골고루 샘플링을 하였다.

그림 9에서 나타난 결과를 보면 훈련/실험데이터의 비율이 변하더라도 구분 확률은 크게 변하지 않는다는 것을 알 수 있다. 이는 전체 각도 정보를 특정 각도 영역으로 그룹화 할 수 있고^[6], 실험에서 훈련 데이터베이스를 한 각도 영역에 치우치지 않고 고른 샘플링을 하였기 때문에 비록 훈련 데이터베이스를 구성하기 위한 특성벡터 샘플링 개수가 적어지

표 1. 기본적인 파라미터 설정

Table 1. Basic parameters which were used in simulation.

파라미터	수치	비고
훈련 : 실험데이터 비율	1:1	
특성벡터 열 원소 개수	10	
특성벡터 열 샘플링 간격	5°	
SNR	30	
Hidden state 개수	6	종속방식에만 적용
Code number	24	종속방식에만 적용

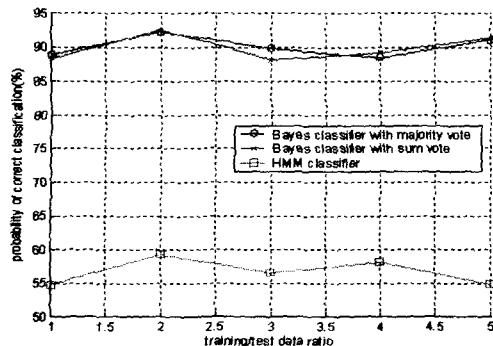


그림 9. 훈련/실험데이터 비율을 변화시켰을 경우 구분 확률의 변화

Fig. 9. Probability of correct classification versus training/test data ratio.

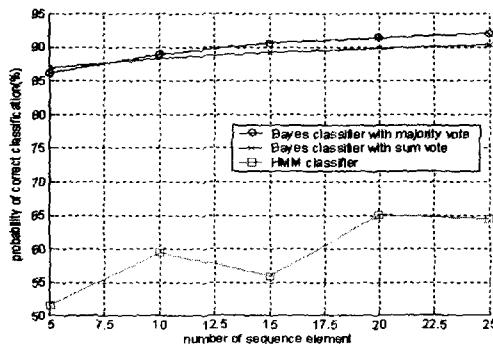


그림 10. 특성벡터 열 원소간의 샘플링 간격을 일정하게 유지한 상태에서 특성벡터 원소 개수를 변화시켰을 경우 구분 확률의 변화

Fig. 10. Probability of correct classification versus element number of feature vector(sampling angle is fixed).

더라도 구분기에 각각도 그룹별로 가지고 있는 고유 특성을 충분히 반영한 결과라고 예상할 수 있다.

그림 10은 표 1의 파라미터에서 특성벡터 열의 원소개수를 5에서 25까지 5 간격으로 변화시키면서 100회 Monte-Carlo 반복 실험에서 나온 전체 결과의 평균값을 그린 것이다. 그림 8에서 볼 수 있듯이 모든 구분 방식은 열의 원소 개수가 증가할수록 구분 확률이 증가하는 경향을 보여주고 있다. 이는 특성 벡터 열의 원소개수가 증가할수록 구분에 유용한 정보 또한 증가하기 때문이다.

그림 11은 특성벡터 열이 차지하고 있는 각도 범위를 45° 로 유지하고 표 1의 파라미터에서 특성벡터

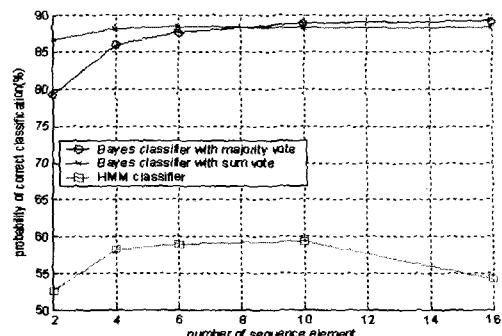


그림 11. 특성벡터 열이 차지하고 있는 각도 범위를 고정시킨 상태에서 특성벡터 원소 개수를 변화시켰을 경우 구분 확률의 변화

Fig. 11. Probability of correct classification versus element number of feature vector(aspect angle area which feature vector occupy is fixed).

열 원소 개수를 2, 4, 6, 10, 16개로 변화시키면서 100회 Monte-Carlo 반복 실험에서 나온 전체 결과의 평균값을 그린 것이다.

그림 11에서 볼 수 있듯이 majority vote와 sum vote의 구분 결과는 그림 10의 결과와 유사하다. 하지만 HMM 구분기의 구분 확률은 특성벡터 열의 원소 개수가 극단적으로 작거나 크지 않은 한 일정하게 유지되는데 이는 각도 영역만 관찰할 경우 특성벡터의 변화는 그렇게 크지 않다고 볼 수 있으며, 특성벡터 열이 차지하고 있는 각도 영역이 일정하게 유지되면 특성벡터 열에서 얻을 수 있는 변화 정보는 열의 원소 개수와 관계없이 거의 일정하기 때문이다. 또한 그림 10에서 HMM 구분기에 입력되는 특성벡터 열의 원소 개수가 너무 크거나 작을 경우 구분 확률이 떨어진다는 것을 알 수 있는데 이는 열의 원소 개수가 너무 작을 경우 각도 변화를 충분히 반영할 수 없고, 열의 원소 개수가 너무 클 경우 구분기의 overfitting 현상으로 인해서 오히려 구분 확률이 떨어지는 현상이 발생한다.

그림 12는 표 1의 파라미터에서 특성벡터 열 원소간의 각도 샘플링 간격을 2° , 5° , 8° , 10° , 15° 로 변화시키면서 구분실험을 한 결과이다. 그림 11에서 볼 수 있듯이 majority vote와 sum vote 구분기법은 샘플링 간격이 넓어지더라도 구분 확률에 큰 변화는 보이지 않는 반면, HMM 구분기는 구분 확률의 증

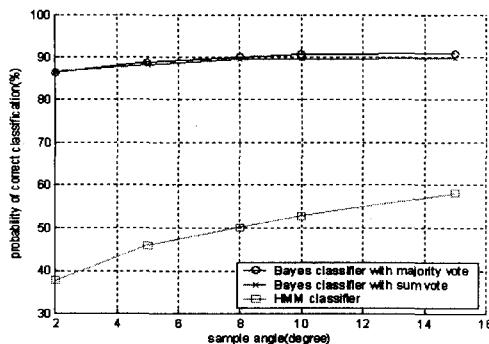


그림 12. 특성벡터 원소간의 각도 샘플링 간격을 변화시켰을 경우 구분 확률의 변화
Fig. 12. Probability of correct classification versus sampling angle.

가율이 다른 두 기법보다 상대적으로 크다는 것을 알 수 있다. 이는 특성벡터의 변화를 구분에 이용하는 HMM의 특성상 각도 샘플링 간격이 넓어질수록 전체 특성벡터 열이 차지하는 각도범위가 넓어지게 되고, 특성벡터 열 내부에 특성벡터의 각도에 따른 변화가 더 잘 반영될 수 있기 때문이다.

그림 13과 14는 SNR을 0에서 30 dB까지 5 dB 간격으로 변화시키면서 100번의 Monte-Carlo 실험을 하였을 경우 각 구분기의 구분 확률 평균과 표준편차를 나타낸 것이다. 그림 13을 보면 SNR이 높을 경우 majority vote와 sum vote의 구분 확률이 HMM의 구분 확률보다 높은 반면, SNR이 낮아질수록 majority vote와 sum vote의 구분 확률은 급격히 감소하고 HMM의 구분 확률은 상대적으로 작은 감소율을 보이고 있다. 그리고 그림 14를 보면 알 수 있듯이

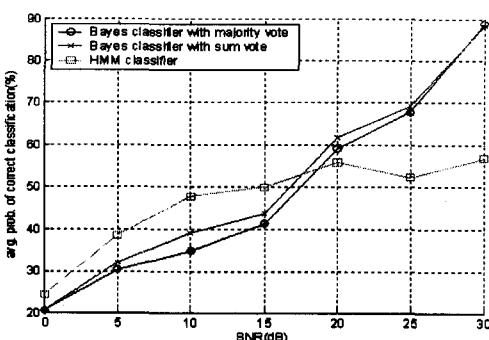


그림 13. SNR의 변화에 따른 구분 확률 평균의 변화
Fig. 13. Average probability of correct classification versus SNR.

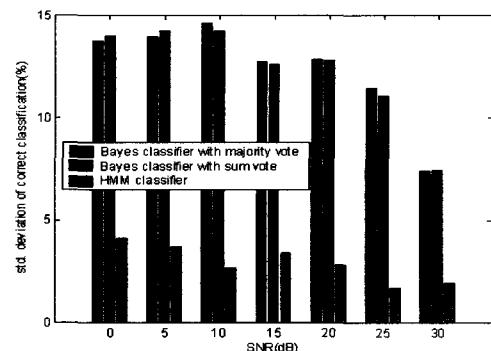


그림 14. SNR의 변화에 따른 구분 확률 표준편차의 변화
Fig. 14. Standard deviation of probability of correct classification versus SNR.

HMM이 나머지 두 구분방식보다 훨씬 더 작은 표준편차를 가지고 있다는 것을 알 수 있다. 이는 majority vote와 sum vote의 경우 특성벡터의 값 자체를 구분에 이용하기 때문에 특성벡터에 잡음이 첨가될 경우 그대로 구분 확률에 그 영향이 미치는 반면, HMM은 특성벡터를 코드화하는 과정에서 어느 정도 잡음의 효과를 없애줄 수 있고 비록 하나의 코드가 잘못되었다 할지라도 전체적인 특성벡터 열의 변화에 크게 영향을 주지 않기 때문에 상대적으로 잡음의 영향을 적게 받는다고 볼 수 있다. 그리고 majority vote와 sum vote를 비교해 볼 경우 sum vote가 상대적으로 높은 구분 확률을 보여주는데 이는 SNR 관련 실험을 하기 위하여 RCS 주파수 데이터에 AWGN을 첨가하였으며 Bayes 구분기에서 나온 posteriori 확률 밀도 함수값과 원 posteriori 확률 밀도 함수의 차이가 가우시안 분포를 가지게 되었기 때문이다. 만일 두 값의 차이가 가우시안 분포를 가질 경우 sum vote가 majority vote보다 우수한 성능을 보인다는 것이 증명되어 있다^[12].

V. 결 론

본 논문에서는 range profile을 이용하여 구분실험을 수행하는데 있어서 제일 큰 문제점인 관측각 확장에 따른 구분성능의 저하를 해결하기 위한 다중 각도 정보 기법을 제안하였다. 다중 각도 정보 기법에서 독립방식은 높은 SNR에 대해 우수한 구분 확

률을 보이는 반면 잡음에 따라 구분 확률의 변동이 심하고 SNR이 낮아질수록 급격한 구분 확률의 저하가 나타난다는 것을 알 수 있었으며 종속방식은 SNR이 높을 경우는 독립방식과 비교하여 상대적으로 낮은 구분 확률을 보였지만 잡음의 영향을 독립방식에 비해 적게 받으며 낮은 SNR에서도 독립방식보다 상대적으로 높은 구분 확률을 보장한다는 것을 실험을 통하여 알 수 있었다.

참 고 문 헌

- [1] N. Levanon, *Radar Principle*, John Wiley & Sons, 1988.
- [2] W. E. Pierson Jr., *Comparison of Scattering Center Extraction Algorithms*, A Master's Thesis, The Ohio State University, 1993.
- [3] B. Bhanu, G. Jones III, "Object recognition results using MSTAR synthetic aperture radar data", *Computer Vision Beyond the Visible Spectrum: Methods and Applications*, Proceedings, IEEE Workshop on, pp. 55-62, 2000.
- [4] R. O. Duda, P. E. Hart and D. G. Stork, *Pattern Classification and Scene Analysis*, Pre-published print of 2nd ed., 1997.
- [5] H.-J. Li, S.-H. Yang, "Using range profile as feature vector to identify aerospace projects", *IEEE Transactions on Antennas and Propagation*, vol. 41, no. 3, Mar. 1993.
- [6] 서동규, 김경태, 김효태, "Subclass 개념을 이용한 넓은 관측각에서의 레이더 표적인식 성능향상에 관한 연구", 한국전자과학회 논문지, 13(8), 2002년 9월.
- [7] D. B. Fogel, "An introduction to simulated evolutionary optimization", *IEEE Transactions on Neural Networks*, vol. 5, no. 1, pp 3-14, Jan. 1994.
- [8] K.-T. Kim, D.-K. Seo and H.-T. Kim, "Efficient radar target recognition using the MUSIC algorithm and invariant features", *IEEE Transactions on Antennas and Propagation*, vol. 50, no. 3, pp. 325-337, Mar. 2002.
- [9] P. K. Bharadwaj, P. R. Runkle and L. Carin, "Target identification with wave-based matched pursuit and hidden Markov models", *IEEE Transactions on Antennas and Propagation*, vol. 47, no. 10, pp. 1543-1554, Oct. 1999.
- [10] S. Haykin, *Neural Networks: A Comprehensive Foundation*, 2nd Edition, Prentice Hall, 1997.
- [11] J. Kittler, M. Hatef, R. Duin and J. Matas, "On combining classifiers", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 20, no. 3, pp. 226-239, Mar. 1998.
- [12] J. Kittler, F. M. Alkoot, "Sum versus vote fusion in multiple classifier systems", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 25, no. 1, Jan. 2003.
- [13] L. R. Rabiner, B. H. Juang, "An introduction to hidden Markov models", *IEEE ASSP Magazine*, vol. 3, no. 1, Jan. 1986.

정 호령



2000년 2월: 경북대학교 전자공학과 (공학사)
2002년 2월: 포항공과대학교 전자전기공학과 (공학석사)
2002년 3월~현재: 포항공과대학교 전자전기공학과 박사과정
[주 관심분야] 레이더 표적인식, 레이더 신호처리, 패턴인식

김효태



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

김경태



1994년 2월: 포항공과대학교 전자전기공학과 (공학사)
1996년 2월: 포항공과대학교 전자전기공학과 (공학석사)
1999년 2월: 포항공과대학교 전자전기공학과 (공학박사)
1999년 3월~2001년 2월: 포항공과대학교 전자전기공학과 연구원
2001년 3월~2002년 2월: 포항공과대학교 전자전기공학과 연구조교수
2002년 3월~2004년 3월: 영남대학교 전자정보공학부 전임강사
2004년 4월~현재: 영남대학교 전자정보공학부 조교수
[주 관심분야] 레이더 표적인식, 레이더 영상, 어레이 신호 처리, 패턴인식