

HOG 특징 기반 능동 소나 식별 기법

신현학¹⁾ · 박재현¹⁾ · 구분화¹⁾ · 서익수²⁾ · 김태환²⁾ · 임준석³⁾ · 고한석¹⁾ · 홍우영^{*,3)}

¹⁾ 고려대학교 전기전자전파공학과

²⁾ 국방과학연구소 소나체계개발단

³⁾ 세종대학교 국방시스템공학과

Active Sonar Classification Algorithm based on HOG Feature

Hyunhak Shin¹⁾ · Jaihyun Park¹⁾ · Bonhwa Ku¹⁾ · Iksu Seo²⁾ · Taehwan Kim²⁾ ·
Junseok Lim³⁾ · Hanseok Ko¹⁾ · Wooyoung Hong^{*,3)}

¹⁾ Department of Electrical Engineering, Korea University, Korea

²⁾ Sonar Systems PMO, Agency for Defense Development, Korea

³⁾ Department of Defense Systems Engineering, Sejong University, Korea

(Received 27 June 2016 / Revised 12 September 2016 / Accepted 23 December 2016)

ABSTRACT

In this paper, an effective feature which is capable of classifying targets among the detections obtained from 2D range-bearing maps generated in active sonar environments is proposed. Most conventional approaches for target classification with the 2D maps have considered magnitude of peak and statistical features of the area surrounding the peak. To improve the classification performance, HOG(Histogram of Gradient) feature, which is popular for their robustness in the image textures analysis is applied. In order to classify the target signal, SVM(Support Vector Machine) method with reduced HOG feature by the PCA(Principal Component Analysis) algorithm is incorporated. The various simulations are conducted with the real clutter signal data and the synthesized target signal data. According to the simulated results, the proposed method considering HOG feature is claimed to be effective when classifying the active sonar target compared to the conventional methods.

Key Words : Active Sonar Classification(능동소나 식별), Histogram of Gradient feature(HOG 특징)

1. 서론

최근 수중으로 기동하는 표적의 침공을 대비하기 위

하여 능동 소나를 이용한 감시시스템에 대한 관심이 높아지고 있다. 능동 소나를 이용한 표적 감시는 수신된 반사파와 송신파와의 정합 필터의 결과를 주로 이용한다. 하지만 수신된 반사파에는 표적 신호뿐만 아니라 해수면, 해저면 및 바위와 같은 물체로 인하여 클러터로 간주되는 잔향 신호가 다수 존재하며, 이로

* Corresponding author, E-mail: wyhong@sejong.ac.kr
Copyright © The Korea Institute of Military Science and Technology

인해 표적을 탐지하는데 어려움이 따른다^[1]. 따라서 표적으로 오인 될 수 있는 다수의 클러터들을 표적 반사파와 구별하는 연구가 필요하다.

거리와 방위에 대한 정합 필터의 2차원 결과에서의 대표적인 식별 기법은, 일정한 오검출률을 바탕으로 표적 최대치에 대한 문턱값을 설정하는 CFAR(Constant False Alarm Rate) 기법이다^[2,3]. 위 방법은 표적/클러터에 대한 훈련 없이 규준화 기법 및 문턱치 설정을 통하여 표적을 효과적으로 검출할 수 있는 기법으로 여겨져 왔다. 하지만 CFAR기법의 경우 정합 필터의 준위가 큰 클러터를 표적으로 오인하는 문제가 빈번히 발생한다. 이러한 문제점을 해결하기 위하여 최근에는 단순한 최대치의 문턱값이 아닌, 최대치 주변 영역에 대한 정보를 기반으로 표적을 식별하는 연구가 진행되고 있다^[4-8]. 최대치 주변 영역에 대한 대표적인 특징으로는 모멘트 정보를 활용한 방법이 제안되었다^[4]. 또한 국내에서는 이러한 모멘트 특징에 대해서 영역 전체가 아닌 영역간의 비율을 특징으로 활용한 기법이 제안되었다^[5]. 최근에는 영역 내 화소값을 바탕으로 추정된 확률 분포의 파라미터를 특징으로 하는 연구가 진행되고 있다. 다양한 확률 분포 중 K-분포에 대한 파라미터를 특징으로 하는 식별 기법이 제안되었으며 이에 대한 분석이 이루어지고 있다^[6-8]. 2차원 거리-방위 맵 상에서의 표적 식별을 위해 최대치 주변 영역들에서의 다양한 특징 분석 방법이 제안되었지만, 표적 최대치의 준위가 주변 클러터와 유사해지는 경우에는 여전히 식별이 어려운 상황이다.

본 논문에서는 표적 최대치의 준위가 주변 클러터와 유사한 상황에서의 특징 추출 및 식별 기법에 대해서 제안한다. 표적 최대치의 준위가 주변과 유사해지는 경우 주변 클러터에 의하여 발생하는 패치 내 준위값들의 세부적인 변화를 반영하기 위하여, 영상 식별 시 사용되는 HOG(Histogram of Gradient) 특징을 능동 소나 식별에 적용하였다. 또한 실 해상데이터에 표적 신호를 합성한 다양한 시뮬레이션을 수행하였으며, 기존에 주로 연구되었던 특징들과의 성능 비교 분석을 통하여 제안하는 기법의 효용성을 입증하였다.

본 논문의 구성은 다음과 같다. 2장에서는 능동소나 식별 시 2차원 거리-방위 맵을 생성하는 배경지식에 대하여 간략히 다룬다. 3장에서는 제안하는 특징 추출 및 식별 과정에 대해서 설명한다. 또한 4장에서는 시뮬레이션을 통하여 제안 방법을 평가하며, 5장에서는 결론에 대하여 기술한다.

2. 2차원 거리-방위 맵 생성 기법

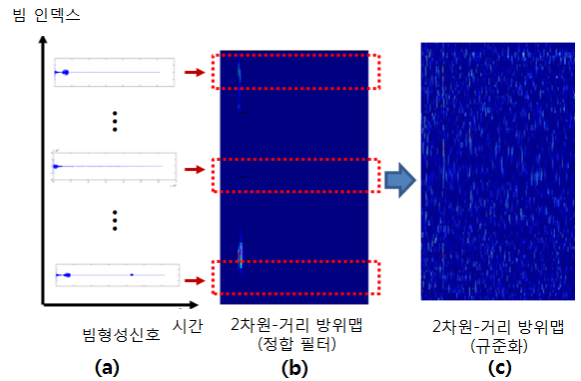


Fig. 1. 2D bearing-range map generation process
(a) Beam signal (b) 2D map (c) Normalized 2D map

능동 소나를 이용한 표적 탐지는 LFM(Linear Frequency Modulation) 또는 CW(Continuous Wave) 송신파와 수신된 반사파와의 정합 필터 결과를 입력값으로 사용한다. 2차원 거리-방위 맵을 생성하기 위해서는 Fig. 1의 (a)에서 같이 수신한 다수의 빔형성 신호에 대해서 아래의 수식과 같이 송신한 파형과의 정합 필터 결과를 이용한다.

$$m_i(n) = \sum_{k=-\infty}^{\infty} h(n-k)x_i(k) \quad (1)$$

수식에서 x_i 는 수신한 i 번째의 빔형성 신호를 의미하며, h 는 시간이 반전된 송신파를 의미하며, m_i 는 정합 필터의 결과를 의미한다. 정합 필터 준위 $y(k, i)$ 는 i 번째 빔형성 신호의 k 번째 짧은 구간(L) 동안의 정합 필터의 결과의 제곱의 합을 이용하여 아래의 수식과 같이 구한다.

$$y(k, i) = \sum_{n=(k-1) \times L+1}^{n=k \times L} m_i(n)^2 \quad (2)$$

각각의 방위 별로 획득한 빔형성 신호의 정합 필터 준위인 y 를 Fig. 1의 (b)와 같이 나열하면, 2차원 거리-방위에 대한 정합 필터 결과 맵을 획득 할 수 있다. 획득된 2차원 거리-방위 맵은 거리에 따른 클러터의 영향을 줄이기 위해 아래와 같은 규준화(Normalization) 과정을 수행한다^[2,3].

$$z(k,i) = \frac{y(k,i)}{n(k,i)} \quad (3)$$

수식에서 z 는 Fig. 1의 (c)에서와 같이 규준화 된 결과인 SNR(Signal to Noise Ratio)값을 나타내며, n 은 주변 준위를 바탕으로 추정된 잡음값을 의미한다. CA-CFAR [2,3]에서 n 의 경우 주변 영역에 대한 준위값의 평균값을 통해 추정하게 된다.

3. 제안 방법

3.1 알고리즘 흐름도

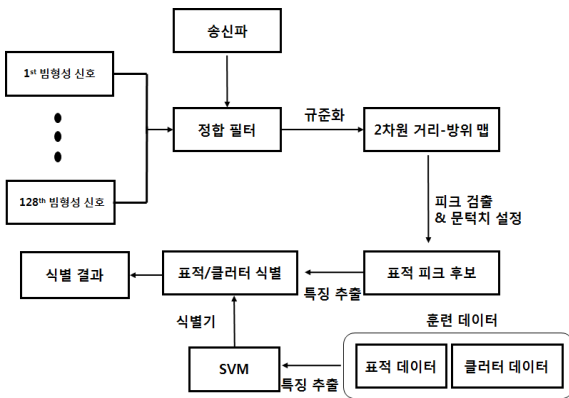


Fig. 2. Flow diagram of proposed method

표적/클러스터 식별을 위한 제안된 알고리즘의 전체적인 흐름은 Fig. 2와 같다. 우선 빔형성 신호와 송신파와의 규준화 된 정합 필터로부터 생성된 2차원 거리-방위 정합 필터 맵 내에서 일정 문턱치 이상의 최대치들을 표적에 대한 후보로 추출한다. 이후 추출된 표적에 대한 후보군들에 대해서 최대치 주변 영역 내에서 특징을 추출한다. 마지막으로 훈련 데이터로부터 추출된 특징을 기반으로 SVM(Support Vector Machine) [9] 기법을 이용하여서 표적/클러스터 식별을 수행한다.

3.2 특징 추출 방법

일반적으로 정합 필터 및 규준화를 거친 2차원 거리-방위 맵 상에서 표적 신호는 Rayleigh분포를 가지며, 클러스터 신호는 Non-Rayleigh 분포를 가진다[7]. 이러한 통계적 특성을 기반으로 최대치 주변 내 영역에 대한 정합 필터 값을 이용하여 표적과 클러스터를 식별

하기 위한 연구가 진행되어 왔다[4,6-8]. 표적 최대치 주변에 대한 평균 분산과 같은 저차원 모멘트뿐만 아니라, 3,4차 모멘트와 같은 고차원 모멘트를 활용한 식별 연구가 진행되어 왔다[4]. 또한 Non-Rayleigh 분포인 K-분포의 파라미터를 기반으로 표적과 클러스터를 식별하는 연구가 주로 진행되었다[6-8]. 즉 2차원 거리-방위 맵 내에서 주로 연구되어온 방법들은 최대치 주변 영역에 대한 규준화된 준위 값들을 통계치에 대한 파라미터를 기반으로 식별을 수행하였다. 이러한 통계치 기반의 특징들은 Fig. 3의 (a)와 같이 표적의 준위가 주변 클러스터에 비하여 큰 경우에는 효과적으로 표현할 수 있다. 하지만 Fig. 3의 (b)와 같이 2차원 거리-방위 맵 내에서 표적의 준위가 영역 내 클러스터들과 준위가 유사한 경우에는, 영역 내 준위들의 통계적 특징이 클러스터에 의하여 변하기 때문에 식별이 어려워지게 된다.

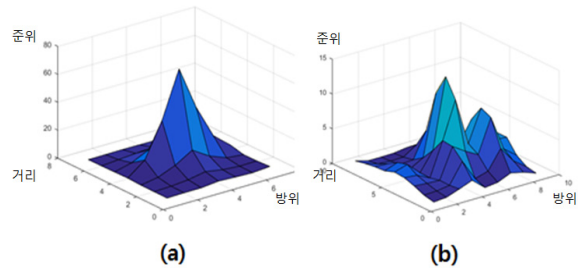


Fig. 3. Target examples in 2D range-bearing map
(a) High peak value (b) Low peak value

본 논문에서는 위에서 언급한 상황에서도 강인하게 표적을 식별하기 위하여 영상 기반 식별 시 사용하는 특징을 능동 소나 기반 표적 식별에 적용하고자 한다. 영상 인식 분야에서는 사람 또는 번호판 등의 사물을 효과적으로 검출하기 위한 특징에 대한 연구가 진행되어 왔다. 특히 다양한 사물의 형태 및 방향의 변화에 따른 화소값의 변화에 대해서도 강인한 특징에 대해 연구되어왔다. 그 중 HOG 특징은 화소값의 크기 변화에 대한 정보를 바탕으로 세부적인 변화를 효과적으로 반영하는 특징으로 알려져 있다[10,11]. 따라서 Fig. 3의 (b)와 같이 표적의 준위가 낮고 주변의 클러스터가 존재하여 패치 내 준위 값들의 세부적인 변화가 커지는 상황에서는 HOG 특징을 이용하여 효과적으로 표적을 표현할 수 있다. 따라서 본 논문에서는 이러한 가능성을 확인하고자 HOG 특징을 능동 소나에서 2차

원 거리-방위 맵 기반 표적 식별을 위한 특징으로 적용하였다.




Fig. 4. Example of HOG feature extraction process

HOG 특징^[10,11]은 Fig. 4와 같이 최대치를 중심으로 하는 패치 영역 내에 준위값들의 기울기의 방향 및 크기를 바탕으로 생성한 히스토그램이다. 여기서 기울기는 준위의 급격한 차이를 의미하며, $[-1, 0, 1]$ 및 $[-1, 0, 1]^T$ 형태의 필터들을 이용해 각각 수평, 수직 방향의 기울기를 얻을 수 있다. 그리고 아래의 수식을 이용하여 각각의 위치별로 준위값들의 변화 방향 및 크기를 계산한다.

$$|G(x,y)| = \sqrt{G_x^2(x,y) + G_y^2(x,y)} \quad (4)$$

$$\theta(x,y) = \arctan \frac{G_y(x,y)}{G_x(x,y)} \quad (5)$$

수식에서 $G_x(x,y)$, $G_y(x,y)$ 는 각각 패치 영역 내 특정 위치 (x, y) 에 대한 수평 수직 방향의 기울기를 의미한다. 또한 $|G(x,y)|$, $\theta(x,y)$ 는 기울기의 크기 및 방향을 의미한다. 특징을 추출할 패치 영역 내 모든 위치의 값들을 특정 개수의 방향으로 양자화 시키며, 방향 별 크기인 $|G(x,y)|$ 의 합을 통해 히스토그램을 생성한다. 이러한 히스토그램을 표적 식별을 위한 특징으로 사용한다.

3.3 특징 차원 축소 방법

HOG 특징은 기본적으로 양자화 된 방향의 개수로 특징의 차원의 개수가 결정되며, 영역을 세분화하여 특징을 추출할수록 특징의 차원의 개수 또한 증가하게 된다. HOG 특징의 차원을 늘릴수록 좀 더 세분화된 표현이 가능해지지만, 식별을 위한 연산량이 차원의 수에 따라 선형적으로 증가하며 식별 성능에 도움이

되지 않는 특징값에 의하여 성능이 저하 될 수 있다. 따라서 본 논문에서는 주성분 분석(Principal Component Analysis, PCA)기법^[12]을 통하여 표적과 클러스터 데이터를 효과적으로 표현할 수 있는 축으로 변환하였다.

$$QW = \lambda W \quad (6)$$

수식에서 Q 는 추출된 표적 및 클러스터 특징들에 대한 공분산 행렬을 의미하며, λ , W 는 각각 특징 데이터에 대한 고유값 및 고유벡터를 의미한다. 고유값을 크기 순으로 정렬한 후, 전체 고유값의 합 대비 선택된 고유값이 일정 수준 이상이 되도록 고유벡터들을 선택한다.

$$\hat{f}_i = W_L f_i \quad (7)$$

수식에서 f_i 는 최대치 주변 패치에서 추출한 HOG 특징을 의미하며, W_L 은 선택된 고유벡터들을 의미한다.

3.4 SVM 기법 기반 표적 식별 방법

수식 (7)에서 축소된 차원의 특징 \hat{f}_i 를 바탕으로 SVM 기법으로 훈련된 식별기를 통해서 표적/클러스터 식별을 수행하였다.

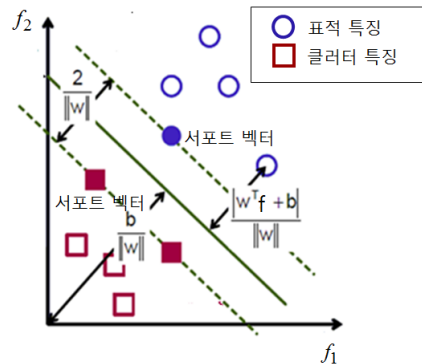


Fig. 5. Example of decision boundary by SVM

Fig. 5는 SVM 기법을 통해서 훈련 데이터로부터 식별기인 결정 경계(Decision boundary) 구한 예시를 나타낸다. 그림에서와 같이 결정 경계와 가장 가까운 곳에 위치한 훈련 데이터를 서포트 벡터(Support vector)라고 정의한다. SVM은 서포트 벡터간의 거리를 최대화시키

는 결정결계를 훈련 데이터를 기반으로 학습하는 기법이다. 결정결계는 아래의 수식과 같이 정의된다.

$$g(f) = w^T f + b \tag{8}$$

수식에서 w 는 결정결계의 법선벡터를 의미하며, b 는 원점에서 결정결계까지의 거리를 의미한다. 결정결계를 구성하는 변수인 w , b 는 서포트 벡터간의 거리 ($\frac{2}{\|w\|}$)를 최대화한다는 제한조건하에서, 훈련 오차를 최소화하는 라그랑지(Lagrange) 기법 기반의 최적화 기법을 통하여서 구할 수 있다^[9].

4. 실험 및 결과

4.1 성능 평가 지표

본 실험에서는 Fig. 6에서 표현된 표적/클러터의 분류 결과를 바탕으로, 표적 검출률(True Positive rate) 및 오검출률(False Positive rate)를 성능 평가지표로 고려하였다. 표적 검출률(%)은 True Positive / (True Positive + False Negative)로 실제 표적 데이터 중 표적으로 식별한 데이터의 비율을 의미한다. 또한 오검출률(%)은 False Positive / (True Negative + False Positive)로 실제 클러터 데이터 중 표적으로 잘못 식별한 데이터의 비율을 의미한다. 식별기의 성능은 특정 오검출률에서 표적 검출률이 높을수록 우수하다고 할 수 있다.




Fig. 6. Target/Clutter classification result

4.2 실험 환경

Fig. 7은 표적/클러터 식별을 위하여 실 해상데이터에 표적 반사파를 합성하여 실험을 수행한 과정을 나타낸다. 클러터 및 잔향에 대한 신호는 중주파수 대역의 LFM 50 ms 송신파로부터 획득한 빔형성 데이터를 이용하였다. 표적에 대한 반사파 신호는 하이라이트 기반 시뮬레이터^[13]를 기반으로 위치 및 자세각의 각도

에 따라 다양하게 생성한 후 클러터 및 잔향 신호와 합성하였다. 합성과정은 시나리오 설정(Scenario Set-up) 과정을 거쳐 생성된다. 빔형성 신호 합성 시 표적 신호 및 주변 클러터 신호의 파워의 비율(Target to Clutter Ratio, TCR)을 변수로 시나리오를 생성하였다. TCR의 값이 높을수록 표적 준위의 최대값이 커져서 클러터의 구분이 용이한 시나리오를 의미하며, 낮을수록 주변 클러터와 준위가 유사해지거나 작아지기 때문에 구분이 어려운 시나리오가 조성됨을 의미한다.




Fig. 7. Feature extraction of target/clutter data

성능 평가를 위해 훈련 데이터와 시험 데이터에 대해 교차검증(cross-validation) 기반 식별을 수행하였다. 전체 클러터 1500개 표적 1000개의 특징 데이터를 5개의 집합으로 나누어서, 한 집합인 클러터 300개 / 표적 200개를 시험 데이터로 설정하였으며 나머지 특징 데이터인 클러터 1200개 / 표적 800개를 훈련 데이터로 설정하였다. 총 5개의 시험 데이터 집합에 대하여 교차적으로 식별을 수행하여서 평균 식별 결과를 구하였다.

클러터 및 표적 신호에 대한 패치의 크기는 7×7을 고려하여서 데이터 생성 및 특징 추출을 진행하였다. HOG 특징은 최대치 주변 패치를 4개의 영역으로 나누어서 영역별로 8개의 양자화 된 방위에 대한 히스토그램을 생성하였다. 이렇게 생성된 32차원의 HOG 특징을 PCA 기법을 적용하여 고유값이 전체 합 대비 95 % 이상이 되도록 고유 벡터를 선택하고, 이를 바탕으로 차원을 축소하였다. 차원이 축소된 표적과 클러터에 대한 HOG 특징을 바탕으로 SVM 기법을 통하여서 식별기를 학습하고 식별 결과를 도출하였다.

제안 특징의 식별 성능을 평가하기 위하여 기존의 2차원 거리.방위 맵 기반 능동식별에서의 대표적인 특징인 CPD(Cluster Peak Detection)^[5], K-분포 기반 Shape 파라미터^[6], 통계적 모멘트^[4] 특징을 고려하였다. 기존 방법들도 훈련 데이터로부터 각각의 특징을 추출하고, SVM 기법을 통하여서 학습된 식별기를 이용하여서 식별 결과를 도출하였다.

4.3 실험 결과

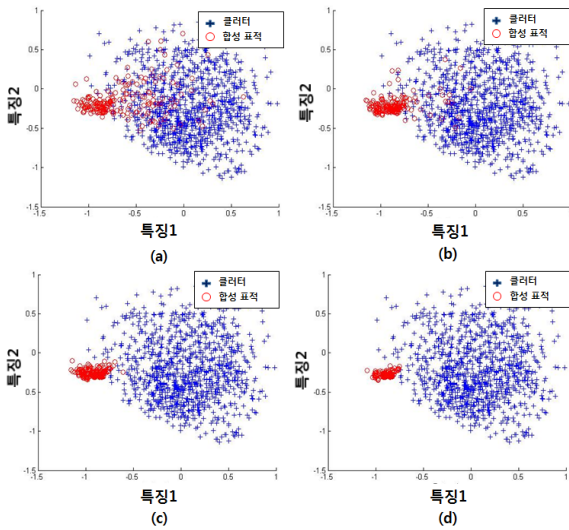


Fig. 8. HOG Features for varying TCR
 (a) TCR = -3(dB), (b) TCR = 0(dB),
 (c) TCR = 3(dB), (d) TCR = 6(dB)

Fig. 8은 표적 및 클러스터 패치에서 추출한 HOG 특징들에 대하여 나타낸 그림을 의미한다. 추출한 특징들을 효과적으로 시각화하기 위하여, PCA 기법으로 구한 고유값이 가장 큰 2개의 고유벡터만을 이용하여 차원을 축소하고 이를 나타내었다. 주변에 클러스터가 존재하는 상황에서 표적을 합성하여 추출한 특징은 적색이며, 클러스터의 특징은 청색으로 표시하였다.

Fig. 8에서 TCR이 3(dB) 이상으로 큰 (c), (d)의 경우 표적과 클러스터에 대한 특징이 완전히 이격되어 있음을 알 수 있다. 이는 Fig. 3의 (a)와 같이 합성 표적의 신호가 주변 클러스터의 영향을 받지 않아 봉우리 형태로 형성되어 준위의 기울기 값의 특징이 좌측에 집중되어 분포하여 있고, 클러스터는 다양한 형태로 형성되어 표적에 비하여 준위의 기울기 값의 특징이 분산이 크게 분포됨을 알 수 있다. 반면에 TCR이 3(dB) 미만으로 작은 Fig. 8의 (a), (b)의 경우에는 Fig. 3의 (b)와 같이 표적의 특징 추출 과정에 준위가 유사한 주변 클러스터 영향을 받게 된다. 따라서 그림에서와 같이 표적 특징과 클러스터의 특징이 중첩되는 부분이 발생하게 되며 -3(dB)의 경우에는 표적의 준위가 주변 클러스터와 유사하거나 작아지는 경우가 빈번하게 발생하게 되어 분별이 어려운 상황임을 알 수 있다. 본 실험에

서는 표적과 주변 클러스터와 분별이 쉬운 경우와 어려운 경우 각각에 대하여, HOG 특징과 기존에 연구되었던 타 특징과의 식별 성능의 비교를 수행하였다.




Fig. 9. ROC Curve results for varying TCR
 (a) TCR = -3(dB), (b) TCR = 0(dB),
 (c) TCR = 3(dB), (d) TCR = 6(dB)

Fig. 9는 TCR이 -3 ~ 6(dB) 인 경우에 대한 식별 결과를 토대로 생성한 ROC(Receiver Operating Characteristic) 커브를 나타낸다. ROC 커브의 x축은 오검출률을 의미하며, y축은 표적 검출률을 의미한다. TCR이 3(dB) 이상으로 큰 경우에는 표적 신호의 준위가 주변 클러스터에 비하여 완전히 크기 때문에 모든 특징들이 표적과 클러스터를 쉽게 식별함을 확인할 수 있다. 반면에 TCR이 0(dB) 이하인 (a), (b)에서는 제안하는 HOG 특징을 적용한 기법이 기존의 특징들을 이용하여 식별한 경우에 비하여 식별 성능이 우수함을 확인할 수 있다. 특히 표적과 클러스터의 준위가 가장 유사하여 구분이 어려운 -3(dB)인 경우에도 제안하는 HOG 특징의 성능이 가장 우수함을 확인할 수 있다. TCR이 -3(dB)인 경우 오검출률이 10 %인 경우 K-분포 기반 Shape 파라미터^[6]는 66 %의 검출률을 나타냈다. 또한 통계적 모멘트^[4]중 1차원 모멘트만 사용한 경우에는 66 %, 1 ~ 4차원의 모든 통계적 특징을 고려한 경우에는 73 %의 검출률, 영역별 통계적 특징의 비율을 고려한 CPD^[5] 기법은 77 %의 검출률을 가짐을 알 수 있다. 반면에 제안하는 HOG 특징 기반 식별기는 92 %의 성능으로 기존에 연구되었던 타 특징

들에 비하여 15 % ~ 26 % 정도의 검출 성능이 향상되었음을 알 수 있다. 실험 결과를 통해서 표적과 클러터의 준위가 유사해지는 경우에도 기존의 특징들에 비하여 HOG 특징을 적용한 식별 방법이 효과적으로 표적을 식별 가능함을 보여준다.

5. 결론

본 논문에서는 중주파수 능동 소나 표적 식별을 위한 2차원 거리-방위 맵 상에서의 특징을 제안하였다. 표적의 준위가 주변 클러터와 유사하게 낮은 상황에서도 효과적인 식별을 위한 특징으로 HOG 특징의 적용을 제안하였다. 실 해상데이터에 표적 신호를 합성한 실험을 통해서 제안하는 특징과 기존의 대표적인 다른 특징들과의 비교 실험을 수행하였다. 실험 결과를 통해서 표적이 주변 클러터와 준위가 유사해지는 상황에서도 제안하는 특징 기반 식별이 기존의 다른 특징들에 비하여 효과적으로 표적을 식별 가능함을 확인 할 수 있었다.

후 기

본 연구는 국방과학연구소의 지원으로 수행되었습니다(연구과제번호 UD160002DD).

References

- [1] G. Ginolhac, J. Chanussot, and C. Hory, "Morphological and Statistical Approaches to Improve Detection in the Presence of Reverberation," *IEEE Journal of Oceanic Engineering*, Vol. 30, No. 4, pp. 881-899, 2005.
- [2] M. Barkat and F. Soltani, "Cell-Averaging CFAR Detection in Compound Clutter with Spatially Correlated Texture and Speckle," *IEE Proc. Radar Sonar and Navigation*, Vol. 146, No. 6, pp. 279-284, 1999.
- [3] J. H. Shapiro and J. G. Thomas, "Performance of Split-Window Multipass-Mean Noise Spectral Estimators," *IEEE Transactions on Aerospace and Electronic Systems*, Vol. 36, No. 4, pp. 1360-1370, 2000.
- [4] J. Gelb and W. O. Andrew, "Active Sonar Clutter Classification using Higher Order Moments," *Proceedings of Meetings on Acoustics*, Vol. 9, No. 1, 2015.
- [5] I. Seo and S. Kim, "Single Ping Clutter Reduction Algorithm Using Statistical Features of Peak Signal to Improve Detection in Active Sonar System," *The Journal of the Acoustical Society of Korea*, Vol. 34, No. 1, pp. 75-81, 2015.
- [6] R. Bares et al., "Noise Estimation in Long-Range Matched-Filter Envelope Sonar Data," *IEEE Journal of Oceanic Engineering*, Vol. 35, No. 2, pp. 230-235, 2010.
- [7] D. A. Abraham and P. L. Anthony, "Reliable Methods for Estimating the-Distribution Shape Parameter," *IEEE Journal of Oceanic Engineering*, Vol. 35, No. 2, pp. 288-301, 2010.
- [8] J. R. Preston, and D. A. Abraham, "Statistical Analysis of Multistatic Echoes From a Shipwreck in the Malta Plateau," *IEEE Journal of Oceanic Engineering*, Vol. 40, No. 3, pp. 643-656, 2015.
- [9] S. Amari and S. Wu, "Improving Support Vector Machine Classifiers by Modifying Kernel Functions," *Neural Networks*, Vol. 12, No. 6, pp. 783-789, July 1999.
- [10] T. Kobayashi, "BFO Meets HOG: Feature Extraction based on Histograms of Oriented pdf Gradients for Image Classification," *IEEE Conference on Computer Vision and Pattern Recognition*, pp. 747-754, 2013.
- [11] H. Tan et al., "Face Recognition based on the Fusion of Global and Local HOG Features of Face Images," *IET Computer Vision*, Vol. 8, No. 3, pp. 224-234, 2014.
- [12] V. Chamundeeswari et al., "An Analysis of Texture Measures in PCA-based Unsupervised Classification of SAR Images," *IEEE Geoscience and Remote Sensing Letters*, Vol. 6, No. 2, pp. 214-218, 2009.
- [13] J. Seok, T. Kim, K. Bae, "Simulator for Active Sonar Target Recognition," *The Journal of the Korea Institute of Information and Communication Engineering*, Vol. 16, No. 10, pp. 2137-2142, 2012.