
SVM 커널함수의 파라미터 값에 따른 능동소나 표적신호의 식별 성능 분석

박정현* · 황찬식* · 배건성**

Analysis of target classification performances of active sonar returns depending on parameter values of SVM kernel functions

Jeonghyun Park* · Chansik Hwang* · Keunsung Bae**

이 연구는 방위사업청과 국방과학연구소의 지원으로 수행되었습니다. (계약번호: UD130007DD)

요 약

수중 천해 환경에서 능동소나의 반향 신호로 기뢰를 탐지 및 식별하는 일은 복잡한 해양 환경의 영향으로 어려운 문제이다. SVM은 패턴인식 문제에서 최적의 해를 제공하는 이진 분류기이다. 본 논문에서는 SVM을 이용하여 능동소나의 반향 데이터로 기뢰와 같은 금속 물체와 바위를 식별하는 실험을 수행하면서, SVM에 사용되는 커널함수의 파라미터 값의 변화에 따른 식별 성능을 분석하고 제시하였다.

ABSTRACT

Detection and classification of undersea mines in shallow waters using active sonar returns is a difficult task due to complexity of underwater environment. Support vector machine(SVM) is a binary classifier that is well known to provide a global optimum solution. In this paper, classification experiments of sonar returns from mine-like objects and non-mine-like objects are carried out using the SVM, and classification performance is analyzed and presented with discussions depending on parameter values of SVM kernel functions.

키워드

소나표적 식별, SVM, 커널함수

Key word

sonar target classification, support vector machine, kernel function

* 정회원 : 경북대학교
** 정회원 : 경북대학교(교신저자, ksbae@ee.knu.ac.kr)

접수일자 : 2013. 02. 06
심사완료일자 : 2013. 02. 26

Open Access <http://dx.doi.org/10.6109/jkiice.2013.17.5.1083>

©This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<http://creativecommons.org/licenses/by-nc/3.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.
Copyright © The Korea Institute of Information and Communication Engineering.

I. 서 론

표적에서 반사되어 수신된 능동소나의 신호를 이용하여 수중의 표적을 탐지 및 식별하는 문제는 수중감시 체계에서 아주 중요한 일이지만, 천해 수중환경의 복잡성과 표적신호 획득의 어려움으로 인해 여전히 어려운 문제로 남아있다. 실제 해상에서의 능동소나 표적신호의 획득이 어려우므로 수조에서의 모형 표적을 이용한 데이터를 이용하거나, 모델을 이용한 합성신호를 이용하는 방법 등으로 연구가 수행되고 있다[1,2]. 미국 캘리포니아대학의 UCI machine learning repository[3]에서는 기계학습 및 패턴인식 관련 연구자에게 다양한 데이터를 제공하고 있는데, 그 중에 1988년 Gorman 과 Sejnowski의 연구[4]에서 처음 사용된 능동소나의 표적신호에 대한 데이터가 포함되어 있다. 제공되는 데이터는 기뢰와 같은 금속 실린더 물체와 실린더 모양의 바위로부터 반사되는 능동소나 반향신호를 분석하여 얻은 60차의 스펙트럼 특징벡터로 총 208개로 구성되어 있다. 능동소나 신호의 식별에는 주로 인공신경망을 이용한 기법들이 주로 많이 연구되어 왔다[5,6]. SVM은 최적해를 제공할 수 있는 이진 분류기인데, 커널함수를 사용하면 비선형 특성을 갖는 입력 공간에서 더 높은 차원의 특징 공간으로 변환하여 선형 분리를 가능하게 한다. 커널함수로는 주로 다항식 형태와 방사기저함수, 즉, polynomial과 가우시안함수 형태의 radial basis function(RBF) 등이 사용되는데, 각 커널 함수마다 사용자가 적절한 파라미터 값을 결정해주어야 한다. 커널 함수와 그 함수의 파라미터 값에 따라 식별 성능에 큰 차이를 보일 수 있기 때문에 적절한 파라미터의 선택은 중요한 문제이다. 본 논문에서는 2개의 표적 클래스를 포함하고 있는 UCI 소나 데이터를 이용하여 능동소나 표적신호의 식별 문제를 다루었다. 식별기로는 이진 분류에 적합한 SVM을 이용하였으며, SVM의 커널함수와 각 함수의 파라미터 값의 변화에 따른 식별률을 분석하였다.

본 논문의 구성은 다음과 같다. 2장에서는 본 연구에서 식별기로 사용한 SVM 및 커널함수에 대해 간략히 설명한다. 3장에서는 UCI 소나 데이터의 구성과 시뮬레이션 방법에 대해 소개하고 시뮬레이션 결과를 제시하며, 마지막으로 4장에서 결론을 맺는다.

II. Support Vector Machine

두 클래스를 선형 분리할 수 있는 결정평면(decision surface)에 가장 가까이 존재하는 각 클래스의 샘플을 SV(Support Vector)라고 하는데, SVM은 결정평면과 SV 사이의 거리, 즉, 마진(margin)이 최대가 되는 결정평면을 훈련에 사용되는 각 클래스의 샘플을 이용하여 구하는 이진 분류기이다. 입력 샘플이 \mathbf{x}_i 이고 클래스 출력이 $d_i \in \{1, -1\}$ 인 N 개의 샘플 $\{(\mathbf{x}_i, d_i)\}_{i=1}^N$ 을 고려할 때, 결정평면은 $\mathbf{w}\mathbf{x} + b = 0$ 로 표시된다. 여기서 \mathbf{w} 는 가중치 벡터, b 는 바이어스를 나타낸다. 이때 두 클래스의 SV 사이의 분리 마진은 $2/\|\mathbf{w}\|$ 가 되며, 이를 최대화하기 위해서는 $\|\mathbf{w}\|$ 를 최소화해야 한다. 여기서 결정평면과 목표 클래스 출력의 곱이 양수라는 제약조건을 적용하여 식 (1)의 비용함수가 최소가 되는 \mathbf{w} 와 b 를 구하면 최적화된 결정평면을 얻을 수 있다[7].

$$\Phi(\mathbf{w}) = \frac{1}{2} \|\mathbf{w}\|^2 \tag{1}$$

두 클래스에 포함된 샘플들이 선형적으로 완전 분리가 어려운 경우에는 식 (2)와 같이 오류에 대한 허용 변수를 적용한 비용함수를 통해 최적화가 가능하다. 이때 훈련 샘플들을 이용하여 마진의 최대화와 분류 허용에 대한 조절 인자인 C 의 적절한 값을 경험적으로 결정해야 한다.

$$\Phi(\mathbf{w}) = \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^N \xi_i \tag{2}$$

식 (2)에 대한 최적화 문제는 라그랑지승수(Lagrange multiplier) 방법을 도입하여 해를 찾을 수 있는데, 분류하고자 하는 두 클래스가 비선형 분리면을 갖는 경우에는 커널함수 $K(\mathbf{x}_i, \mathbf{x})$ 를 도입하여 입력벡터, 즉, 입력 샘플을 더 높은 차원의 특징 공간으로 사상하여 그 공간에서 초평면(hyper plane)을 얻음으로써 선형적으로 분리할 수 있다. 커널함수를 이용할 경우 최종적으로 얻어지는 SVM 분류기는 식 (3)과 같이 표현되며, 이를 이용하여 두 개의 비선형 분리면을 갖는 클래스를 분류할 수 있다[8].

$$f(\mathbf{x}) = \text{sign}\left(\sum_{i=1}^N \alpha_{o,i} d_i K(\mathbf{x}_i, \mathbf{x}) + b_o\right) \quad (3)$$

여기서 $\alpha_{o,i}$ 는 식(4-1)로 주어지는 목적함수를 최대화하는 라그랑지승수를 나타낸다.

$$Q(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j d_i d_j K(\mathbf{x}_i, \mathbf{x}_j) \quad (4-1)$$

$$\sum_{i=1}^N \alpha_i d_i = 0, \quad 0 \leq \alpha_i \leq C \quad \text{for } i=1,2,\dots,N \quad (4-2)$$

커널함수는 입력벡터를 고차원의 특징벡터로 변환한 후 내적을 구하는 과정을 수행하는 함수로 표 1에 주어진 polynomial, RBF 등이 일반적으로 많이 사용된다.

표 1. 일반적으로 많이 이용되는 커널함수
Table. 1 Typical kernel functions

Type	kernel function	
polynomial	$(\mathbf{x}^T \mathbf{x} + 1)^p$	p : power
radial basis function	$\exp\left(-\frac{1}{2\sigma^2} \ \mathbf{x} - \mathbf{x}_i\ ^2\right)$	σ^2 : variance

III. 실험 및 결과

실험에 사용된 UCI 능동소나 데이터는 수중 바닥에 놓인 금속 실린더와 비슷한 형상의 바위에 대해 LFM (Linear Frequency Modulated) 능동신호를 여러 각도에서 수신한 각 신호를 STFT (Short-time Fourier transform)으로 분석하여 주파수 대역에 대해 0에서 1 사이의 값으로 정규화한 60차의 스펙트럼으로 구성되는 특징벡터 형태로 제공된다. 전체 DB는 총 208개의 표적 방향신호에서 얻어진 특징벡터들로, 111개는 금속 실린더로부터 얻어진 방향신호의 특징벡터로 구성되어 있다. 208개의 데이터는 다양한 각도에서 수신된 신호가 고르게 분포되도록 나누어 104개는 훈련데이터로, 나머지 104개는 테스트데이터로 레이블링 된 형태로 제공되는데, 본 연

구에서는 이를 이용하여 SVM의 훈련과 식별 실험에 사용하였다. 식별 실험을 위한 분류기는 SVM toolbox[9]를 이용하였으며, polynomial, RBF 두 개의 커널함수를 사용한 SVM 시스템에 대해 식별 성능을 비교하였다. 표 1에서, polynomial 커널함수의 경우에는 p 값을, RBF 커널함수의 경우에는 σ 에 해당하는 값을 사용자가 지정하여야 한다. 또한, 두 함수 모두 라그랑지승수의 상한 값에 해당하는 C 값도 설정해주어야 한다. SVM toolbox에서 RBF 커널함수는 식 (5)의 형태로 계산되는데, 여기서 v_{dim} 은 입력되는 특징벡터의 차원이며 γ 값을 사용자가 설정해주어야 한다.

$$K(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\|\mathbf{x}_i - \mathbf{x}_j\|^2 / (\gamma v_{\text{dim}})) \quad (5)$$

SVM 커널함수의 적절한 파라미터 값을 찾으면서 그에 따른 식별 성능을 비교하기 위하여 일반적인 그리드 탐색 (grid-search) 기법[9]을 적용하여 (C, p) 와 (C, γ) 에 따른 식별 실험을 수행하였다. 커널함수가 polynomial인 경우에는 1차, 2차 다항식에 해당되는 $p = [1, 2]$ 에 $C = [2^1, 2^2, \dots, 2^{15}]$ 값을 변화시키면서 실험하였으며, RBF 커널함수 경우에는 $\gamma = [2^{-15}, 2^{-14}, \dots, 2^{-1}]$ 와 $C = [2^1, 2^2, \dots, 2^{15}]$ 값의 조합에 대해 식별 실험을 수행하였다.

그림 1은 polynomial 커널함수의 파라미터 값에 따른 식별 성능을 보인 것이다. 여기서 각 값은 10번 시행에 대한 평균 식별률을 보인 것이며, 가로축의 k 는 $C = 2^k$ 의 지수 값을 의미한다.




그림 1. polynomial 커널함수의 C 값에 따른 식별 결과
Fig. 1 Classification results with a polynomial kernel function depending on its C values

그림 1에서 보면, $p=1$ 일 때는 C 값이 증가 할수록 식별률이 다소 저하되는 경향을 보였지만 $p=2$ 인 경우에는 C 값의 영향을 적게 받는 것으로 나타났다. 또한, 모든 C 값에 대해 $p=2$ 에서 더 좋은 인식률을 나타내었으며, $p=2$, $C=2^3$ 일 경우 가장 높은 87.5%로 [4]에서의 인공신경망을 이용했을 경우와 비슷한 식별률을 보였다.

그림 2는 RBF 커널함수에서 γ 값에 따른 식별 성능을 나타낸 그래프인데, $\gamma=2^{-10}$ 미만의 값에서는 식별률이 50% 이하의 낮은 성능을 보여, $\gamma=2^{-10}$ 이상의 값에 대해서만 그래프에 나타내었다. 그래프 가로축의 k 값은 $\gamma=2^k$ 에서의 지수 값을 의미하며 그래프 아래쪽의 범례에 보이는 수는 $C=2^k$ 의 지수 값, 즉, $2^1, 2^5, 2^{10}, 2^{15}$ 의 지수 값을 의미한다. 그림 2를 보면 $\gamma=2^{-9}$ 이상에서 식별률이 크게 변하여 γ 값이 $2^{-5} \sim 2^{-6}$ 일 때 대체로 높은 식별률이 얻어짐을 확인할 수 있으며, [4]의 경우보다 훨씬 향상된 최고 93.27%의 식별률을 보였다.




그림 2. RBF 커널함수의 파라미터 γ 값에 따른 식별 실험 결과
 Fig. 2 Classification results with RBF kernel function depending on its γ values

표 2는 RBF 커널함수를 사용했을 경우의 (C, γ) 값에 따른 식별 결과에서 높은 식별률이 얻어지는 일부 구간을 보인 것이다. 표 2에서 보면 식별률이 대체로 C 값보다는 γ 값에 민감하다는 것을 볼 수 있다.

그림 3은 C 값에 따른 식별 성능을 나타낸 그래프이다. 그래프 가로축의 k 값은 그림 1에서와 마찬가지로 $C=2^k$ 에서 지수 값을 의미하며, 범례에 보이는 수는 γ

의 값 $2^{-9}, 2^{-7}, 2^{-5}, 2^{-3}, 2^{-1}$ 의 지수 값을 나타낸다.

표 2. RBF 커널함수의 파라미터에 따른 식별률
 Table. 2 Classification results with RBF kernel function depending on its parameter values

	$C=2^7$	$C=2^8$	$C=2^9$	$C=2^{10}$	$C=2^{11}$
$\gamma=2^{-7}$	87.88%	87.88%	87.98%	87.60%	87.79%
$\gamma=2^{-6}$	93.08%	93.17%	93.27%	93.17%	93.08%
$\gamma=2^{-5}$	93.27%	93.27%	93.27%	93.27%	93.27%
$\gamma=2^{-4}$	90.38%	90.38%	90.38%	90.38%	90.38%
$\gamma=2^{-3}$	88.46%	88.46%	88.46%	88.46%	88.46%

그림 3을 보면 γ 값 대부분의 경우에서, $C=2^5$ 이상에서의 식별률이 거의 일정한 것을 볼 수 있다. 그림 2와 3을 비교해 보면 C 값보다 γ 값의 변화가 식별률에 더 큰 영향을 미치는 것을 알 수 있다. 그림 4는 polynomial 커널함수와 RBF 커널함수의 식별 성능을 비교한 것이다. RBF 커널함수는 $\gamma=2^{-6}$ 에 대해서, polynomial 커널함수는 $p=2$ 에 대한 성능을 나타내었으며, 가로축의 k 는 $C=2^k$ 에서 지수 값을 의미한다. 위의 실험 결과에서 비선형 특성을 갖는 능동소나 표적 신호의 SVM을 이용한 식별에서 RBF 커널함수의 식별 성능이 polynomial 커널함수의 식별 성능 보다 훨씬 우수함을 볼 수 있다.




그림 3. RBF 커널 함수의 C 값에 따른 식별 실험 결과
 Fig. 3 Classification results with RBF kernel function depending on its C values




그림 4. 커널함수에 따른 인식 성능 비교
Fig. 4 Comparison of classification rates according to kernel functions

IV. 결 론

본 논문에서는 SVM의 커널함수와 각 함수의 파라미터 값에 따른 능동소나 표적신호의 식별 성능을 분석하였다. 사용한 커널함수는 polynomial과 RBF 커널함수이며, 각 함수에 대한 파라미터 (C, p)와 (C, γ) 값의 변화에 따른 식별률을 분석하였다. 실험에 사용된 능동소나 신호의 경우, SVM에서 polynomial 커널함수보다는 일반적인 RBF 커널함수를 사용하는 것이 더 높은 식별 성능을 얻을 수 있음을 보였다. RBF 커널 함수에서는 γ 값이 2^{-9} 이상에서 식별률이 크게 변하여 $2^{-5} \sim 2^{-6}$ 일 경우 대체로 높은 식별률을 보였는데, 이것은 가우시안 형태의 커널함수인 RBF를 이용하여 특징벡터를 고차원 공간으로 매핑할 때 spreading에 해당하는 γ 의 적절한 선택이 중요함을 의미한다. 반면에 SVM의 조절 인자인 C 는 일정한 값 이상에서는 식별률에 큰 영향을 미치지 않음을 보였다. 또한, RBF 커널 함수를 이용한 SVM에서 $\gamma = 2^{-5}$ 값일 때 93.27%의 식별률을 보여 일반적인 인공신경망을 이용한 기존의 식별률에 비해 훨씬 높은 식별 성능을 얻을 수 있음을 보였다.

참고문헌

- [1] Paul R. Runkle, Priya K. Bharadwaj, Luise Couchman, and Lawrence Carin, "Hidden Markov models for multiaspect target classification," IEEE Trans. Signal Processing, vol. 47, no. 7, pp. 2035-2040, July 1999.
- [2] Taehwan Kim and Keunsung Bae, "HMM-based underwater target classification with synthesized active sonar signals," IEICE Trans. Fundamentals, vol. E94-A, no. 10, pp. 2039-2042, Oct. 2011.
- [3] <http://archive.ics.uci.edu/ml/index.html>
- [4] R. P. Gorman and T. J. Sejnowski, "Analysis of hidden units in a layered network trained to classify sonar targets," Neural Networks. vol. 1, pp. 75-89, 1988.
- [5] Burcu Erkmén, Tulay Yildirim, "Improving classification performance of sonar targets by applying general regression neural network with PCA," Expert Systems with Applications, vol. 35, no. 1-2, pp.472-475, July-August 2008.
- [6] Donghui Li, Azimi-Sadjadi M.R., Robinson M., "Comparison of different classification algorithms for underwater target discrimination," IEEE Transactions on Neural Networks, vol. 15, no. 1, pp. 189-194, Jan. 2004.
- [7] V. Vapnik, The Nature of Statistical Learning Theory. New York: Springer-Verlag, 1995.
- [8] Chih-Wei Hsu, Chih-Jen Lin, "A Comparison of methods for multiclass support vector machines," Neural Networks, IEEE Transactions on, vol. 13, no. 2, pp. 415-425-194, March 2002.
- [9] <http://ida.first.fraunhofer.de/~anton/software.html>

저자소개



박정현 (Jeonghyun Park)

2002년 2월: 경북대학교 전자전기
공학부 (공학사)
2005년 2월: 경북대학교 전자전기
컴퓨터학부 (공학석사)

2007년 3월~현재: 경북대학교 전자전기컴퓨터학부
(박사과정)

※ 관심분야: 패턴인식, 디지털신호처리, 수중음향신
호처리



황찬식 (Chansik Hwang)

1977년 2월: 서강대학교 전자공학과
1979년 8월: 한국과학기술원 전기
및 전자공학과
(공학석사)

1996년 8월: 한국과학기술원 전기 및 전자공학과
(공학박사)

1979년 9월~현재: 경북대학교 IT대학 전자공학부 교수
※ 관심분야: 디지털신호처리, 영상처리



배건성 (Keunsung Bae)

1977년 2월: 서울대학교 전자공학과
1979년 2월: 한국과학기술원 전기
및 전자공학과
(공학석사)

1989년 5월: University of Florida (공학박사)

1979년 3월~현재: 경북대학교 IT대학 전자공학부 교수

※ 관심분야: 음성신호처리, 디지털신호처리, 수중
음향신호처리, 패턴인식