

Wavelet 이론과 신경회로망을 이용한  
천이 수중 신호의 특징벡터 추출 및 자동 식별

Feature Vector Extraction and Automatic Classification  
for Transient SONAR Signals  
using Wavelet Theory and Neural Networks

양 성 철\*, 남 상 원\*, 정 용 민\*\*, 조 용 수\*\*, 오 원 천\*\*\*  
(Seung-Chul Yang\*, Sang-Won Nam\*,  
Yong-Min Jung\*\*, Yong-Soo Cho\*\*, and Won-Tcheon Oh\*\*\*)

이 연구는 93년도 국방 과학 연구소의 연구비 지원에 의한 결과임

요 약

본 논문에서는 수중에서 발생하는 천이 신호의 자동 식별을 위하여 특징벡터를 추출하는 기법과 식별 알고리즘에 대하여 논한다. 특징벡터 추출기법으로 적은 계수로도 우수한 성능을 보이는 wavelet 변환을 사용한 방법을 제안하고 기존의 고전적인 방법들과 비교한다. 자동식별을 위해서는 MLP(Multilayer Perceptron), RBF(Radial Basis Function), MLP-클래스 등 세 종류의 신경회로망을 사용하고, 성능 및 신뢰성을 높이기 위해서 두가지 특징벡터 및 세 식별기를 결합하는 방법을 사용한다. Traco의 표준 천이 데이터 집합(standard transient data set) I 과 모의실험 데이터를 사용하여, 주어진 천이신호가 배경잡음에 비하여 충분히 에너지가 크고, 유한개의 소음원이 존재하며, 동시에 둘 이상의 소음원이 존재하지 않는다는 가정하에서 제안된 특징벡터 추출기법과 식별 알고리즘의 우수성을 확인한다.

ABSTRACT

In this paper, feature vector extraction methods and classification algorithms for the automatic classification of transient signals in underwater are discussed. A feature vector extraction method using wavelet transform, which shows good performance with small number of coefficients, is proposed and compared with the existing classical

\*한양대학교 전기공학과  
Department of Electrical Engineering, Hang-Yang University

\*\*중앙대학교 전자공학과  
Department of Electronic Engineering, Chung-Ang University

\*\*\*국방과학연구소  
Agency for Defense Development (Chinhae)

접수일자: 1995년 3월 10일

methods. For the automatic classification, artificial neural networks such as multilayer perceptron(MLP), radial basis function(RBF), and MLP-Class are utilized, where those neural networks as well as extracted feature vectors are combined to improve the performance and reliability of the proposed algorithm. It is confirmed by computer simulation with Traco's standard transient data set I and simulated data that the proposed feature vector extraction method and classification algorithm perform well, assuming that the energy of a given transient signal is sufficiently larger than that of a ambient noise, that there are the finite number of noise sources, and that there does not exist noise sources more than two simultaneously.

## I. 서 론

최근 과학기술의 급속한 발전과 함께 정숙화 기술, 방사소음 감소 기술 등이 개발되어 잠수함 등에 이용되고 있다. 또한 수중에서 짧은 시간동안 발생하는 많은 종류의 천이 신호(transient signal)로 인하여 소나 운용자에 의한 실시간 표적 탐지 및 식별이 점점 어려워지고 있다. 따라서 본 논문에서는 소나 운용자에 의하여 현재까지 주로 수동적으로 이루어져 왔던 식별 방법을 최근 급속히 발달된 디지털 신호처리 기술과 신경회로망(artificial neural network) 기법을 이용하여 자동화함으로써 사전 정보 없이 높은 신뢰성으로 소나 천이 신호를 탐지하고 식별할 수 있는 알고리즘을 제안하고, 실제 소나 천이 신호 데이터에 적용하여 그 성능을 분석하고자 한다.<sup>[1,2,3]</sup> 이를 위하여, 입력된 소나 천이 신호로부터 자동 식별에 적절한 특징벡터를 선정하는 디지털 신호처리 기법과 선정된 특징벡터를 입력으로 하는 신경회로망을 사용한 자동식별기법에 대한 두 분야의 연구가 필요하여 본 논문에서는 이에 대하여 논하고자 한다.

천이 수중 신호의 자동식별기의 성능은 식별기에 입력되는 특징벡터의 구성에 따라 현저히 달라질 수 있으므로, 일반적인 천이 수중신호를 잘 특징지어 줄 수 있고 자동 식별기의 입력 벡터로서 적당한 특징벡터의 설정이 매우 중요하며 이를 위하여 다음과 같은 신호처리 기법들을 고려할 수 있다. 첫째, 고전적인 특징벡터를 사용하는 방법으로 이 기법은 강인한 장점이 있으나 정확도가 떨어진다<sup>[4]</sup>. 둘째, 최근 연구되고 있는 시간-주파수 표현 기법중의 하나인 Wigner 분포는 고해상도를 갖고 에너지 분포를 시간과 주파수영역에서 잘 나타내지만, 다중음 신호의 경우 상호항(cross-term)을 발생시키고 음의 에너지 값을 갖는다는 단점이 있다<sup>[5]</sup>. 셋째, constant-Q를 갖고 시간과 주파수 영역에서 다중의 해상도(multi-resolution)를 갖는 wavelet 변환을 고려할 수 있는데 이

를 위해서는 천이 수중 신호의 식별에 적절한 최적의 wavelet 계수를 구해야 한다<sup>[6,7,8]</sup>.

식별 알고리즘은 패턴분류 기법의 일종으로 볼 수 있는데, 신호에서 특징벡터가 추출되면 그 특징벡터의 패턴 공간에 경계선을 그어 신호의 클래스(class)를 구분하는 것이다. 식별을 위한 방법으로 linear discriminant analysis, k-nearest neighbor, binary decision tree 등의 전통적인 패턴분류 방법들<sup>[9]</sup>이 있는데, 이들은 패턴의 분포를 가정해야 하거나 계산량이 많다는 단점이 있다. 신경회로망은 계산량이 많기는 하지만 패턴들에 대한 사전 지식 없이 패턴들에 대한 정보를 학습을 통해 얻을 수 있으며, 학습하지 않은 패턴에 대해서도 분류 능력이 뛰어난 장점을 갖고 있다<sup>[10]</sup>. 본 논문에서는 MLP(multilayer perceptron), RBF(radial basis function), MLP-클래스 등 세 종류의 신경회로망을 기본 식별기로 사용하고, 전체 식별 시스템은 기본 식별기별로 특징벡터에 대해 결합하고 각 식별기별 결과를 엔트로피(entropy) 방법으로 다시 결합하였다.

2절에서 이들 방법중 실제 천이 수중 신호의 식별기에 사용 가능한 특징벡터, 즉 고전적인 방법과 wavelet 변환을 사용한 방법에 대하여 설명하고, 3절에서는 자동식별 기법에 대하여 논한다. 4절에서는 모의실험을 통하여 특징벡터와 식별 시스템의 성능을 비교, 분석하며, 5절에서는 결론을 맺는다.

## II. 특징벡터 추출 방법

### 2.1 고전적인 방법

수중에서 발생하는 천이 신호는 일반적으로 특징벡터로 구성하고자 하는 천이 신호와 수중배경잡음(ambient noise)으로 구성되어 있다. 따라서 특징벡터를 구성하기 위한 신호처리의 첫단계에서는 백색화 필터(whitening filter)를 사용하여 수중배경잡음을 무상관 신호로 변화시킨다. 또한 천이 수중 신호

는 시간에 따라 그 특성이 빠르게 변해가는 nonstationary 신호이기 때문에 특징벡터는 시간 정보(temporal information)를 보유해야 한다. 이를 위해 고전적인 방법에서는 우선 각 천이 수중 신호의 지속시간을 정규화한 후 각 천이 신호를 유한개의 non-overlapping 부벡터(sub-vector)로 분리하는데 이때의 각 부벡터는 시간에 따른 특징의 변화를 나타낸다. 여기서 중심주파수(DT: dominant tone), 주파수 대역폭(BW: band width), 에너지, 평균주파수(AT: average tone), AR(autoregressive) 계수, AR cepstral 계수를 각각 정의하고 각 부프레임(sub-frame)에 대하여 이 계수들을 구하여 특징벡터로 이용할 수 있다. 표 1은 이러한 특징벡터를 20개의 부 벡터로 구성할 경우 필요한 전체 부벡터 수를 나타낸다<sup>[3]</sup>.

표 1. 각 특징벡터의 전체 부벡터 수  
Table 1. Total number of sub-vectors for each feature vector

No.	Components per slice	total # of elements
1	Duration	1
2	DT, BW, Energy, AT	80
3	11 AR coefficients	220
4	11 AR cepstral coefficients	220

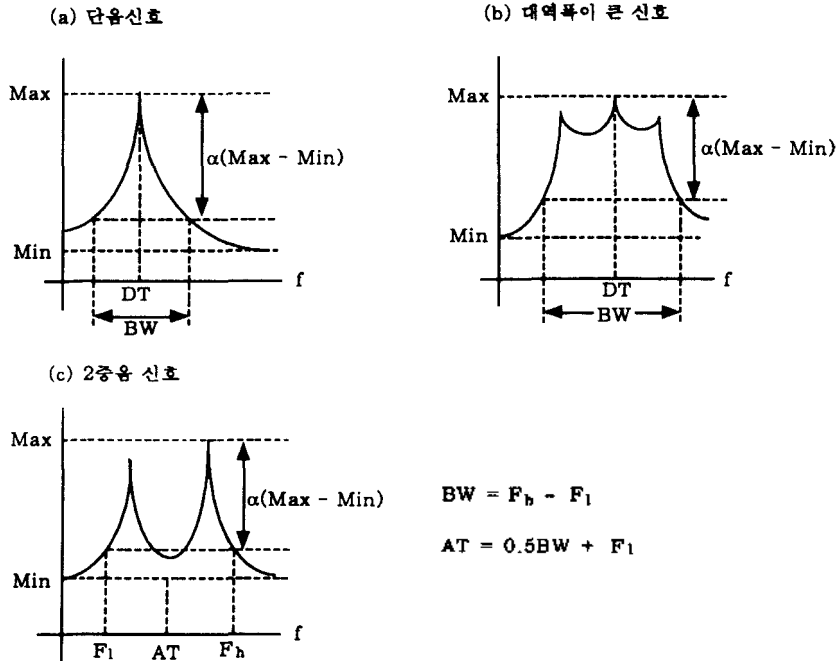
위에서 기술한 첫번째 특징벡터 추출 방법의 단점은 각 특징벡터의 구성을 위해 많은 수의 element가 필요하다는 것이다. 예를 들면 11 AR 계수를 사용할 경우 전체 220개의 element가 필요하며 이를 자동 식별단에 입력할 경우 실시간 처리가 힘들어진다. 따라서 두번째 특징벡터 추출 방법에서는 회귀 모델을 사용하여 DT와 BW를 curve fitting한 후 그때 계수를 계산한다. 즉 DT, BW, 에너지, AT를 p차의 다항식을 사용하여 fitting 시킨후 이 계수값으로 특징벡터를 형성한다. 이 경우 특징벡터는 작은 수의 element로서도 시간에 따른 변화를 내포하게 되며, 표 2는 p=3인 경우의 예를 보인다.

표 2. 3차 polynomial curve fitting시 필요한 element 수  
Table 2. Total number of elements required for third-order polynomial curve fitting

No.	Components per slice	total # of elements
1	3rd order fit to DT, BW, 에너지, AT	16

2.2 Wavelet 변환을 이용한 방법

시간에 따라 특성이 변화하는 신호의 주파수 해석을 위하여 일반적으로 STFT(short-time Fourier tr-



$$BW = F_h - F_1$$

$$AT = 0.5BW + F_1$$

그림 1. 고전적인 특징벡터 구성을 위한 DT, BW, AT 선정 방법  
Fig. 1. Selection method of DT, BW, and AT for classical feature vector extraction

ansform)이 널리 이용된다<sup>[4]</sup>. 천이 수중 신호와 같이 지속시간이 짧고 nonstationary 특성을 갖는 신호의 특징을 더 잘 표현하는데 있어서 STFT보다 wavelet 변환을 사용하는 것이 적합하며 여기에 필요한 이산 wavelet 변환은 다음과 같이 정의 된다<sup>[7]</sup>.

$$c_{j,k} = \int x(t) h_{j,k}^*(t) dt \quad (1)$$

여기서

$$h_{j,k}(t) = a_0^{-\frac{j}{2}} h(a_0^{-j}t - kT) \quad (2)$$

식(1)에서  $h(t)$ 는 표준형 wavelet이며  $h_{j,k}$ 는  $h(t)$ 를 시프트(shift)와 dilation하여 구해진다. Wavelet 변환을 이용한 계수 구현을 더욱 용이하게 하기 위해  $a_0 = 2$ 로 하는 dyadic wavelet 변환은 다음과 같이 주어진다.

$$c_{j,k} = \frac{1}{\sqrt{2^j}} \int x(t) h^*\left(\frac{t}{2^j} - kT\right) dt \quad (3)$$

여기서

$$h_{j,k}(t) = 2^{-\frac{j}{2}} h(2^{-j}t - kT) \quad (4)$$

결국 식(3)의  $c_{j,k}$ 가 인식단의 입력에 사용될 특징벡타가 되며 그림 2는 이 경우의 계수들의 샘플점을 나타낸다.




그림 2. Dyadic wavelet transform의 계수들의 샘플점  
Fig. 2. Sampling points for the coefficients in dyadic wavelet transform

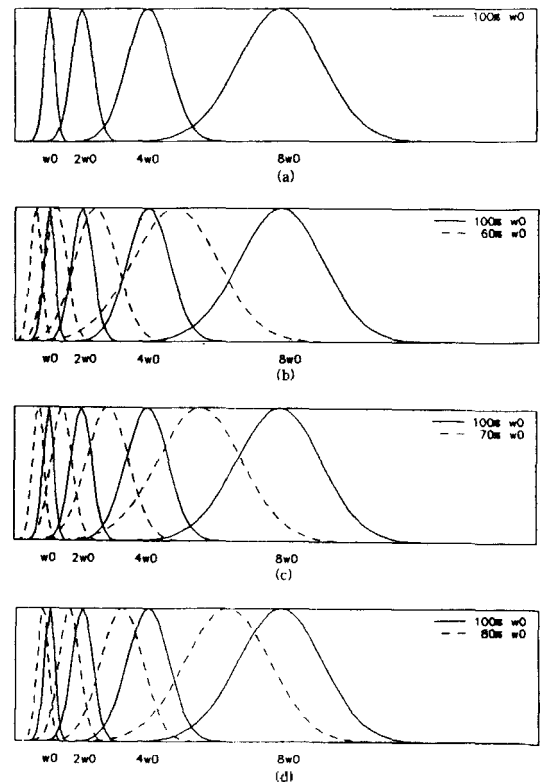
표준형 wavelet으로 식(5)와 같은 Gabor wavelet 함수를 선택하고, 샘플데이터에 따라 변화하는 지속

시간을 정규화시키기 위해 식(5)를 다시 수정한 연속 Gabor wavelet은 식(6)과 같다.

$$h(t) = e^{j\omega_0 t} e^{-\frac{t^2}{2a^2}} \quad (5)$$

$$h\left(\frac{t}{a}\right) = e^{j\omega_0 \frac{t}{a}} e^{-\frac{t^2}{2a^2}} \quad (6)$$

식(6)의 표준형 wavelet을 갖는 dyadic wavelet 변환을 사용한 경우 각 wavelet이 차지하는 주파수 범위가 그림 3(a)에 나타나 있다. 그림에서 신호가  $\omega_0$ 의 정수배 주파수에서 존재하지 않을 경우 상대적으로 작은 하중값(weighting)을 취하게 되므로 결국 입력 신호의 주파수에 따라 다른 결과를 받게 된다. 이를 방지하기 위하여 초기치 주파수  $\omega_0$ 를 변화하여 각 wavelet 계수를 구하고 합산하여 평균하는 방식으로 모든 주파수 대역에 대하여 비슷한 하중값을 가할 수 있다. 그림 3(b)~(e)는 60%~90%의  $\omega_0$ 를 갖는 wavelet을 사용할 경우 각 wavelet이 포함하는 주파수 분포를 나타낸다.






그림 3. Gabor wavelet에서  $\omega_0$ 에 따른 주파수 분포  
Fig. 3. Frequency distribution of Gabor wavelets for the variation of  $\omega_0$

본 논문에서는 적은 계산량으로 모든 주파수 영역을 비교적 비슷하게 weighting을 가하기 위하여 80%, 90%, 100%의  $\omega_0$ 를 갖는 dyadic wavelet을 평균하여 계수를 구하였으며 이를 인식단의 입력 신호로 사용하였다.

### III. 자동 식별 기법

#### 3.1 기본 식별기

식별을 위해서는 신경회로망을 기본 식별기로 사용하였다. 신경회로망을 이용한 식별기로는 MLP (multilayer perceptron)<sup>[11]</sup>, RBF(radial basis function)<sup>[12]</sup>, 클래스별로 MLP를 사용한 MLP-클래스<sup>[13]</sup>, LVQ(learning vector quantization), AKC(adaptive kernel classifier), 결정 트리와 MLP를 결합한 MLP-트리, 결정 트리와 LVQ를 결합한 LVQ-트리<sup>[14]</sup>, PSN(Pi-Sigma network) 등이 있고, 이들을 구현하였다. 이 중에서 불안정하거나, 식별 능력이 떨어지는 AKC, MLP-트리, LVQ-트리, PSN과 식별 능력은 비교적 우수하나 이전 출력값으로 클래스를 결정하기 때문에 결합에 부적합한 LVQ를 제외하고, 식별 능력이 우수하면서도 0에서 1사이의 출력값으로 클래스를 결정하는 MLP, RBF, MLP-클래스 등 세 종류를 기본 식별기로 사용하였다.

#### 3.2 식별 시스템

전체 식별 시스템은 실험을 통해서 인식이 비교적 우수하면서도 입력 갯수가 적은 2가지의 특징벡터 (Wavelet 계수, DT\_BW\_E\_AT-DT, BW, 에너지, AT를 하나로 결합한 것)를 같은 종류의 식별기를 통과시켜 결합한 후에 3 종류의 식별기(MLP, RBF, MLP-클래스) 결과를 다시 결합하는 알고리즘으로 구성하여 전체 식별 시스템의 성능 및 신뢰도를 향상시켰다.

결합 방법에는 엔트로피 방법, 평균 방법, 다수결 방법 등이 있다<sup>[15,16]</sup>. 엔트로피 방법은 분류가 잘 된 식별기에 보다 큰 가중치를, 식별이 제대로 되지 않은 식별기에는 보다 작은 가중치를 주고, 이것을 각 클래스별로 평균하여 분류하는 방법이다. 평균 방법은 각 식별기의 출력을 클래스별로 평균한 후 가장 큰 출력값을 갖는 클래스를 그 패턴의 클래스로 결정한다. 다수결 방법은 3 종류의 식별기에서 가장 큰 출력값을 낸 클래스가 2개 이상일 때, 그 클래스를 패턴에 할당하는 방법이다. 특히 세개의 각 식별기 출력이 서로 다른 경우 가장 큰 출력값을 낸 클래스를 패턴에 할당하게 된다. 본 실험에서는 위 세 가지 결합 방법이 모두 비슷한 성능을 보여 주었다(표 3(b) 참조).

다음에 설명된 특징벡터에 대한 결합에는 각 식별기 출력 결과를 다시 한번 식별기 결합에 사용하기 위하여 평균 방법을 사용하였고, 각 식별기 출력들을 다시 결합하여 최종 출력값을 낼 때는 식별기의 분류 능력에 차이를 두는 엔트로피 방법으로 결합하였다.

#### 3.2.1 특징벡터 결합

하나의 특징벡터로서는 신호를 완전히 특징지우기가 어려우며, 천이 신호의 경우에는 더욱 그렇다. 따라서 본 논문에서는 실험을 통하여 인식이 우수하면서도 입력 갯수가 많지 않은 2 종류의 특징벡터

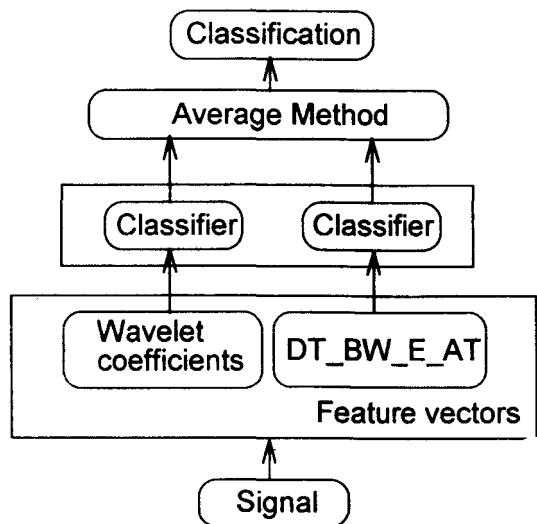


그림 4. 특징벡터의 식별기별 결합  
Fig. 4. Feature vector combination for each classification algorithm

(Wavelet 갯수, DT BW E AT)를 선정하고 이것을 식별기별로 평균 방법으로 결합하였다. 이것은 특징 벡터를 추출하면서 생길 수 있는 정보의 손실로 인한 인식률의 저하를 줄이기 위한 것이다. 그림 4에 특징 벡터에 대한 결합을 보이고 있는데, 중간 단계의 두 개의 식별기는 MLP, RBF, MLP 클래스 중 하나로 구성된 깊은 식별기를 나타낸다.

3.2.2 식별기 결합

하나의 식별기만을 사용할 때보다는 여러 식별기를 결합하게 되면 신뢰도를 향상시킬 수 있다. 즉 각각의 식별기에 대한 인식률이 서로 다르고 같은 패턴에 대해서도 다른 결과를 낼 수 있기 때문에 각각의 출력을 결합하게 되면 전반적인 인식률을 향상시킬 수 있게 된다. 본 논문에서는 MLP, RBF, MLP 클래스를 엔트로피 방법으로 결합하였다(그림 5 참조).

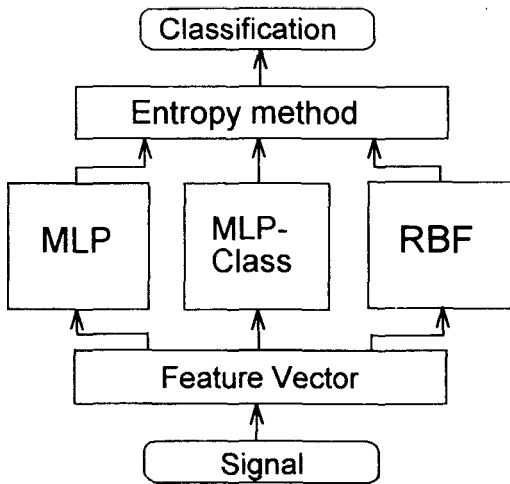


그림 5. 식별기 결합  
Fig. 5. Classification algorithm combination

식별기에 대한 결합을 검증하기 위해 다음과 같은 합성파형<sup>17)</sup>에 대한 식별실험을 하였다. 그림 6과 같은 세 종류의  $h_1(i)$ ,  $h_2(i)$ ,  $h_3(i)$ 를 사용하여 식 (7), (8), (9)에 의해 세 클래스의 패턴을 만들어 낸다.

$$\text{class 1. } x_i = uh_1(i) + (1-u)h_2(i) + \epsilon_i, i=1 \dots 21 \quad (7)$$

$$\text{class 2. } x_i = uh_1(i) + (1-u)h_3(i) + \epsilon_i, i=1 \dots 21 \quad (8)$$

$$\text{class 3. } x_i = uh_2(i) + (1-u)h_3(i) + \epsilon_i, i=1 \dots 21 \quad (9)$$

위 식에서  $u$ 는 [0,1]의 균일한 확률 분포를 갖는 랜덤 값이고  $\epsilon_1 \dots \epsilon_{21}$ 은 각각 평균이 0이고 분산이 1인 가우시안 랜덤 값이다. 이와같이 만들어진 합성파형은 분포간에 어느 정도의 중복이 있어서 이상적인 경우 14%의 최소 식별 에러율<sup>17)</sup>을 갖는다.

학습패턴으로는 클래스 당 100개씩 300개의 패턴을 사용하였고, 클래스 당 1000개씩 3000개의 패턴으로 테스트하였다. 여기서는 특징벡터 대신 21개의 입력 갯수를 갖는 합성파형을 입력으로 하였다. 표 3의 결과에서 각 식별기가 모두 15.5-16.6% 정도의 에러율을 내었으며 각 식별기 출력을 결합한 경우 이상적인 에러율인 14%<sup>17)</sup>에 근접한 14.7%안밖의 에러율을 보여주는데 이는 식별기에 대한 결합으로 식별기의 인식률이 향상되었음을 보여준다. 이상의 실험 결과로부터, 식별기 결합으로 인식률이 향상될 수 있음을 알 수 있다.




그림 6. 합성을 위한 기본파형  
Fig. 6. Basic waveforms to generate the synthetic test signals

표 3. 합성파형 식별 에러율  
(a) 각 식별기별 식별 에러율  
(b) 결합 방법에 따른 식별 에러율

Table 3. Classification error rate for the synthetic test signals

(a) Classification error rate of each classifier  
(b) Classification error rate by each combination method

MLP	MLP-클래스	RBF
496/3000(16.5%)	498/3000(16.6%)	465/3000(15.5%)

(a)

엔트로피 방법	평균 방법	다수결 방법
443/3000(14.77%)	441/3000(14.70%)	445/3000(14.83%)

(b)

### 3.2.3 전체 식별 시스템

전체 식별 시스템은 특징벡터를 결합한 후에 이로부터 다시 식별기에 대해 결합하여 구성하였다. 그림 7이 본 논문에서 채택된 2 종류의 특징벡터(Wavelet 계수, DT BW E DT)와 3 종류의 기본 식별기(MLP, RBF, MLP-Class)를 사용한 전체 식별 시스템이다.

전체 식별 시스템에서는 특징벡터 결합의 결과를 입력으로 사용하여 식별기 결합을 하게 되며, 다음 4절에서 설명된 모의실험에서는 단일 특징벡터를 사용하여 식별기 결합을 한 결과와 특징벡터 결합 후에 식별기 결합을 한 결과를 보여준다.

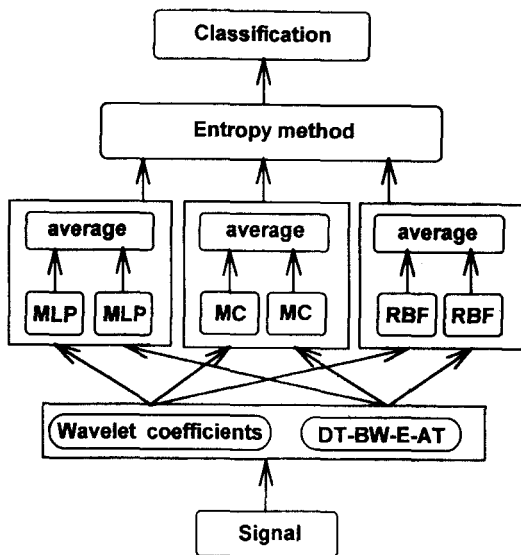


그림 7. 전체 식별 시스템  
Fig. 7. Total classification system

## IV. 모의실험

본 논문에서 제안된 특징벡터 추출기법과 식별 알고리즘의 성능을 비교하기 위하여 사용된 천이 수중 신호원은 Traco에서 제작한 표준 천이 데이터 집합 I 과 천이 신호를 모델링한 데이터로 구성되어 있다. 표준 천이 데이터 집합 I은 100ms-1800ms의 지속시간을 갖는 수중 천이 신호(seismic, biological)로 구성되어 있으며 25KHz로 샘플링되었다. 또한 각 샘플은 16 비트(1 부호 비트, 15 데이터 비트)로 구성되어 있다. 본 모의실험의 특징벡터 추출과 자동 식별을 위하여 사용된 데이터 클래스와 샘플수는 표 4에 주

어져 있다.

표 4. 모의실험에 사용한 천이 수중 신호의 데이터 클래스  
Table 4. Data classes of transient SONAR signals used for simulation

No.	class	description	# of data
1	geological	seismic	4
2	biological	cowfish	4
3	biological	pilotwhale	4
4	biological	spermwhale	4
5	biological	toadfish	4
6	biological	triggerfish	4
7	non-threat	CW	4
8	non-threat	LFM	4
9	non-threat	can	4
10	non-threat	balloon	4
11	non-threat	hull-popping	4
12	non-threat	hammer	4
13	threat	rocket	4
14	threat	whistle-rocket	4

그림 8은 본 연구의 특징벡터 추출과 자동 식별을 위하여 사용된 전형적인 triggerfish 샘플신호의 시간영역파형, spectrogram, 그리고 고전적인 방법을 사용한 특징벡터 추출방법의 결과를 나타낸다. 그림 8의 오른쪽의 맨 윗 블록은 시간영역파형을 나타내며 중간은 spectrogram, 우 하단은 화살표로 표시된 시점의 LPC 스펙트럼, 좌 하단은 화살표로 표시된 지점의 FFT 스펙트럼을 보인다. 그 아래 블록은 2.1 절에서 기술한 고전적인 방법의 첫 번째 방법과 두 번째 방법을 사용한 경우의 특징벡터(DT, BW, 에너지, AT)을 보인다(AR 계수 제외). 상단의 spectrogram 과 하단의 DT, BW, 에너지, AT을 비교해 보면 예상대로 20개의 부 벡터로서 신호를 근사화함을 알 수 있고, 이를 3차 curve fitting하여 구한 두 번째 방법의 경우 역시 20개의 부 벡터를 잘 근사화함을 알 수 있다.

표 5에서는 2.2절에서 기술한 wavelet 변환을 사용하여 추출한 전체 63개의 특징벡터와 이에 해당하는 스케일 인자(scale factor)와 주파수를 보여주며, 이 경우 사용된 wavelet 계수의 갯수를 나타낸다.

식별을 위한 실험은 두 가지로 하였다. 즉 표 4에서 설명된 전체 56개 패턴 중 절반인 28개(클래스별로 2개씩)를 학습에 사용하고 나머지 절반으로 테스트하는 방법(a)과, 전체 56개 패턴 중 3/4인 42개(클래스




그림 8. 특징벡타 추출을 위한 전형적인 triggerfish 신호의 spectrogram 및 DT, BW, 에너지, AT

Fig. 8. Spectrogram, DT, BW, energy, and AT for feature vector extraction of a typical triggerfish signal

표 5. 스케일 인자에 따른 wavelet 계수의 element 수(총 63개)  
Table 5. Number of elements in wavelet coefficients when the scale factor varies (total: 63)

the number of coefficients	a	f(Hz) ( $f_s=20\text{kHz}$ )
32	$2^2$	5000
16	$2^3$	2500
8	$2^4$	1250
4	$2^5$	625
2	$2^6$	313
1	$2^7$	156

표 6. 여러가지 특징벡타의 식별기별 인식률(1/2 학습, 1/2 테스트)

Table 6. Classification rate of each classifier when one feature vector is used as an input

특징벡타	MLP	MLP-클래스	RBF	Total(인식률)
DT	18/28	17/28	20/28	55/84(65.5%)
BW	19/28	21/28	22/28	62/84(73.8%)
DT,BW	25/28	23/28	25/28	73/84(86.9%)
AT,BW	24/28	23/28	25/28	71/84(84.5%)
DT,BW,E	24/28	25/28	26/28	75/84(89.3%)
DT,BW,E,AT	26/28	25/28	24/28	75/84(89.3%)
DT,BW,E,AT3	22/28	21/28	17/28	60/84(71.4%)
AR 캐스트럼 계수	26/28	26/28	27/28	79/84(94.0%)
Wavelet 계수	26/28	27/28	26/28	79/84(94.0%)



별로 3개씩)를 학습에 사용하고 나머지 1/4인 14개를 테스트하는 방법(b)을 사용하였다. 표 6은 고전적인 방법으로 구해진 특징벡타와 그것들을 조합한 것(DT, BW, DT\_BW, AT\_BW, DT\_BW E, DT\_BE, E\_AT, DT\_BW\_E\_AT3, AR 캡스트럼), 그리고 Wavelet 계수를 입력으로 사용하였을 경우의 (a) 방법에 의한 식별기별 인식률이고 (b) 방법에 의한 결과는 지면 관계상 생략하였다.

표 6에서 DT, BW, 에너지, AT의 경우, 어느 하나를 사용한 경우보다는 조합하여 사용할 경우 인식률이 좋아짐을 보이고 있고, 조합을 늘릴수록 일반적으로 인식률이 좋아짐을 보이고 있다. DT\_BW\_E와 DT\_BW\_E\_AT가 전체 인식률에서 89.3%로 동일한 결과를 보였는데 3/4 학습, 1/4 테스트의 경우에는 DT\_BW\_E의 85.7%보다 DT\_BW\_E\_AT가 더 좋은 인식률인 92.9%를 보였다. 또한 DT\_BW\_E\_AT3은 표 2에 설명된 방법으로 curve fitting을 하여 만들어진 특징벡타의 경우인데, 입력 갯수를 줄이기 위해 curve fitting을 할 경우 인식률이 다소 떨어짐을 알 수 있다. 고전적인 방법 중에서는 AR 캡스트럼이 가장 좋은 인식률인 94.0%를 보이고 있지만 입력 갯수가 많은 단점이 있고, 그 다음으로 DT\_BW\_E\_AT가 좋은 인식률을 보이고 있다. Wavelet 계수의 경우, 보다 적은 입력 갯수를 사용하면서도 좋은 인식률을 보이고 있음을 알 수 있다(즉 1/2 학습 1/2 테스트의 경우 94%, 3/4 학습 1/4 테스트의 경우 92.9%).

표 6의 결과로부터 고전적인 특징벡타 중 인식률이 좋은 AR 캡스트럼, DT\_BW\_E\_AT와 Wavelet 계수를 특징벡타 결합에 사용하였다. 표 7은 3 종류 특징벡타 결합과 2 종류 특징벡타 결합의 식별기별 인식률을 보여주는데 단일 특징벡타를 사용하였을 경우(표 6 참조)보다 인식률이 향상되었음을 볼 수 있다.

표 7. 특징벡타 결합의 경우 식별기별 인식률(1/2 학습, 1/2 테스트)

Table 7. Classification rate of each classifier when feature vectors are combined.

식별기	3 종류 특징벡타 결합	2 종류 특징벡타 결합
MLP	27/28(96.4%)	27/28(96.4%)
MLP-클래스	27/28(96.4%)	27/28(96.4%)
RBF	25/28(89.3%)	25/28(89.3%)

3 종류 특징벡타 결합(Wavelet 계수, AR Cepstral, DT\_BW\_E\_AT)  
2 종류 특징벡타 결합(Wavelet 계수, DT\_BW\_E\_AT)

그러나 3 종류 특징벡타 중 AR 캡스트럼의 경우 입력 갯수가 많은 단점이 있어 이것을 사용할 경우 실시간 처리가 어렵게 된다. 표 7의 결과에서 AR 캡스트럼을 제외한 나머지 2 종류의 특징벡타만으로 결합한 결과가 3 종류를 사용할 경우와 동일한 결과를 보여 준다. 표 7의 결과에서 2 종류의 특징벡타만으로도 전체 식별 시스템을 구성하면 적어도 인식률의 저하가 없다는 것이 확인되었다.

표 8은 1 종류의 특징벡타를 사용한 경우(Wavelet 계수, DT\_BW\_E\_AT, AR Cepstral 계수 중 하나) 엔트로피 방법으로 3 식별기(MLP, RBF, MLP-클래스)의 각각의 출력을 결합한 경우를 나타내는데 본 실험에서 사용된 실험 데이터의 경우 인식률이 향상되지 않았다. 그러나 특징벡타 결합을 한 결과를 입력으로 사용하게 되면 인식률이 향상됨을 표 9에서 보여준다.

표 8. 식별기 결합의 경우 특징벡타별 인식률(1/2 학습, 1/2 테스트)

Table 8. Classification rate of the algorithm-combined classifier with each feature vector as an input.

특징벡타	인식률
DT_BW_E_AT	24/28(85.7%)
AR 캡스트럼 계수	27/28(96.4%)
Wavelet 계수	26/28(92.9%)

표 9는 전체 식별 시스템을 통과한 후의 인식률이다. 특징벡타 결합 및 식별기 결합의 두 단계를 거치면서 인식률이 높아지고 있다. 식별기 결합 시에 특징벡타를 결합한 결과를 입력으로 사용하게 되면 인식률이 높아지고 있음을 알 수 있다. 표 7의 결과에서 보여주었던(특징벡타 결합 시 많은 입력 갯수를 요구하는 AR 캡스트럼을 제외하고 입력 갯수가 많지 않은 Wavelet 계수와 DT\_BW\_E\_AT를 사용) 최종 식별결과(표 9)에서도 2 종류의 특징벡타만으로 결합

표 9. 전체 식별 시스템을 통과한 후의 최종 인식률

Table 9. Classification rate of the total classification system

사용된 특징벡타	1/2 학습, 1/2 테스트	3/4 학습, 1/4 테스트
세 종류(AR 캡스트럼 계수, Wavelet 계수, DT_BW_E_AT)	27/28(96.4%)	13/14(92.9%)
두 종류(Wavelet 계수, DT_BW_E_AT)	27/28(96.4%)	13/14(92.9%)

한 결과가 3 종류의 특징벡타로 결합한 경우와 동일한 결과를 내고 있다. 최종 식별 결과가 하나의 특징 벡타 및 식별기에 대한 결과나 특징벡타만을 결합한 결과, 그리고 식별기만을 결합한 결과에 비해 일반적으로 인식률이 향상되었음을 볼 수 있다. 3/4을 학습에 사용하고 1/4을 테스트에 사용한 경우에도 마찬가지로 향상된 인식률인 92.9%였다.

위의 실시결과로부터 천이 수중 신호 자동식별을 위해 Wavelet 계수와 DT\_BW\_E\_AT를 입력 특징벡타로 하여 결합하고, MLP, RBF, MLP-Class 등의 각 식별기 출력을 다시 결합하여 전체 식별 시스템을 구성함으로써 본 논문에서 제안된 식별 알고리즘이 우수한 인식 성능과 높은 신뢰도를 나타낼 수 있음을 입증할 수 있었다.

## V. 결 론

본 논문에서는 수중에서 발생하는 천이 신호의 자동식별을 위하여 특징벡타 추출 방법과 식별 알고리즘에 대하여 기술하였다. 첫번째로 Gabor wavelet을 표준형 wavelet으로 사용하여 구성된 특징벡타는 고전적인 방법에 비하여 적은 계수로도 높은 인식률을 얻을 수 있으므로 천이 수중 신호 식별에 더 적합한 특징벡타 추출방법임을 확인하였다.

또한 식별 알고리즘은 하나의 특징벡타와 하나의 식별기를 사용하기보다는 두 단계에 걸친 결합을 사용하였다. 첫번째 단계인 특징벡타에 대한 결합에서는 입력 갯수가 많지 않음에서도 비교적 우수한 인식률을 보인 Wavelet 계수와 고전적인 방법으로 구해진 특징벡타 중 DT\_BW\_E\_AT를 사용하여 한 종류의 특징벡타를 사용할 때보다 인식률을 높일 수 있음을 보였다. 두번째 단계인 식별기에 대한 결합에서는 MLP, RBF, MLP-Class를 결합하였고, 이를 충분한 데이터를 가진 합성파형 식별실험을 통하여 검증하여 보았다. 이와같은 두 단계를 거치는 전체 식별 시스템을 구성함으로써 신뢰도를 향상시킬 수 있음을 보였다.

그러나 본 논문에서는 주어진 천이 신호가 배경잡음에 비하여 충분히 에너지가 크고, 유한개의 소음원이 존재하며, 동시에 둘 이상의 소음원이 존재하지 않는다는 가정하에서 특징벡타의 추출이 이루어졌으므로 앞으로 이런 상황에서 robust한 특징벡타의 구성에 대한 연구가 필요하며, 결합에 사용되는 특징

벡타의 종류, 기본 식별기의 종류, 그리고 결합방법에 따라 인식률이 조금씩 달라질 수 있으므로, 전체 식별 시스템의 신뢰도 향상을 위하여 신호를 보다 잘 특징지을 수 있는 특징벡타, 추출된 특징벡타에 보다 적합한 식별기, 그리고 이들을 보다 적합하게 결합할 수 있는 결합 방법에 대한 추후 연구 또한 요구된다.

## 참 고 문 헌

1. A. Kundu, G. Chen, and C. E. Persons, "Transient Sonar Signal Classification Using Hidden Markov Models and Neural Nets," *IEEE Journal of Oceanic Engineering*, vol. 19, no. 1, pp. 87-99, Jan. 1994.
2. J. Ghosh, L. Deuser, and S. Beck, "A Neural Network Based Hybrid System for Detection, Characterization and Classification of Short-Duration Oceanic Signals," *IEEE Journal of Oceanic Engineering*, vol. 17, no. 4, pp. 351-363, 1992.
3. Traco Project No. 035-761, "Automated Transient System IR&D Study," Traco Applied Science, Inc., Jan. 1989.
4. S.L. Marple, *Digital Spectral Analysis with Applications*: Prentice-Hall, New Jersey, 1987.
5. B. Boashash, *Time-Frequency Signal Analysis*: Wiley, 1992.
6. F. Hlawatsch and G. F. Boudreaux-Bartels, "Linear and quadratic time-frequency signal representation," *IEEE Signal Processing Magazine*, pp. 21-67, Apr. 1992.
7. O. Rioul and M. Vetterli, "Wavelets and Signal Processing," *IEEE Signal Processing Magazine*, pp. 14-38, Oct. 1991.
8. R. Kronland-Martinet, J. Morlet, and A. Grossmann, "Analysis of Sound Patterns through Wavelet Transforms," *International Journal of Pattern Recognition and Artificial Intelligence*, World Scientific Publishing Company, Vol. 1, No. 2, pp. 97-126. 1987.
9. R. Schalkoff, *Pattern Recognition: Statistical, Structural and Neural Approaches*: John Wiley & Sons, 1992.
10. Edited by E. Sanchez-Sinencio and C. Lau, *Artificial Neural Networks*: IEEE Press, New York, 1992.
11. J.A. Freeman and D.M. Skapura, *Neural Networks: Algorithms, Applications, and Programming Techniques*: Addison Wesley, 1991.
12. P.D. Wasserman, *Advanced Methods in Neural Computing*: Van Nostrand Reinhold, New York, 1993.
13. S.Y. Kung, *Digital neural networks*: Prentice Hall,

1993.

- 14. 양성철, 남상원, 오원천, "LVQ와 결정 트리를 결합한 패턴분류 알고리즘," 대한전기학회 하계학술대회 논문집 B, pp. 1037-1039, 1994.
- 15. J. Ghosh, S. Beck, and C.C. Chu, "Evidence combination techniques for robust classification of short-duration oceanic signals," SPIE Conference on Adaptive and Learning Systems, Orlando, FL, Apr. 1992.
- 16. 윤병수, 양성철, 남상원, 오원천, "신경회로망을 이용한 신호 자동식별기 구현 및 성능분석," 대한전기학회 추계학술대회 논문집, pp. 397-399, 1994.
- 17. L. Breiman, J.H. Friedman, R.A. Olshen, and C.J. Stone, *Classification and Regression Trees*: Belmont, CA., Wadsworth, 1984.

▲梁 盛 結 (Seung Chul Yang) 1969년 11월 3일생  
 1993년 2월: 한양대학교 전기공학과 졸업(학사)  
 1995년 2월: 한양대학교 대학원 전기공학과 졸업(석사)  
 1995년 3월~현재: LG 전자 영상 미디어 연구소 연구원



▲南 尚 沅 (Sang Won Nam) 1957년 2월 24일생  
 1981년 2월: 서울대학교 전자공학과 졸업(학사)  
 1987년 5월: 미국 The University of Texas at Austin, Dept. of Electrical and Computer Engineering (석사)




1990년 12월: 미국 The University of Texas at Austin, Dept. of Electrical and Computer Engineering (박사)  
 1991년 9월~현재: 한양대학교 전기공학과 조교수

▲趙 鎔 洙 (Yong Soo Cho) 1959년 9월 15일생  
 1984년 2월: 중앙대학교 전자공학과 졸업(공학사)  
 1987년 8월: 연세대학교 전자공학과 졸업(공학석사)  
 1991년 5월: 미국 The University of Texas at Austin, Department of Electrical and Computer Engineering (Ph. D)



1992년 3월~현재: 중앙대학교 전자공학과 조교수

▲鄭 鎔 敏 (Yong Min Jung) 1968년 8월 28일생  
 1993년 2월: 중앙대학교 전자공학과 졸업(공학사)  
 1993년 9월~현재: 중앙대학교 전자공학과 대학원 석사과정



▲吳 元 天 (Won Tcheon Oh) 1956년 9월 7일생  
 1980년 2월: 고려대학교 전자공학과 졸업(학사)  
 1982년 2월: 고려대학교 대학원 전자공학과 졸업(석사)  
 1992년 5월: 미국 The University of Texas at Austin, Dept. of Electrical and Computer Engineering (박사)



1982년 1월~현재: 국방과학연구소 수중음향신호처리 연구실 선임연구원