

일반화된 판별분석 기법을 이용한 능동소나 표적 식별

김동욱¹ · 김태환² · 석종원³ · 배건성^{1*}

Sonar Target Classification using Generalized Discriminant Analysis

Dong-wook Kim¹ · Tae-hwan Kim² · Jong-won Seok³ · Keun-sung Bae^{1*}

¹School of Electronics Engineering, Kyungpook National University, Daegu 41566, Korea

²Agency for Defense Development, Changwon 51678, Korea

³Department of Information and Communication, Changwon National University, Changwon 51140, Korea

요 약

선형판별분석(LDA) 기법은 특징벡터의 차원을 줄이거나 클래스 식별에 이용되는 통계적 분석 방법이다. 그러나 선형 분리가 불가능한 데이터 집합의 경우에는 비선형 함수를 이용하여 특징벡터를 고차원의 공간으로 사상(mapping) 시켜줌으로써 선형 분리가 가능하도록 만들 수 있는데, 이러한 기법을 일반화된 판별분석(GDA) 또는 커널판별분석(KDA) 기법이라고 한다. 본 연구에서는 인터넷에 공개되어 있는 능동소나 표적신호에 LDA 및 GDA 기법을 이용하여 표적식별 실험을 수행하고, 그 결과를 비교/분석하였다. 실험 결과 104개의 테스트 데이터에 대해 LDA 기법으로는 73.08% 인식률을 얻었으나 GDA 기법으로는 95.19%로 기존의 MLP 또는 커널 기반 SVM에 비해 나은 성능을 보였다.

ABSTRACT

Linear discriminant analysis is a statistical analysis method that is generally used for dimensionality reduction of the feature vectors or for class classification. However, in the case of a data set that cannot be linearly separated, it is possible to make a linear separation by mapping a feature vector into a higher dimensional space using a nonlinear function. This method is called generalized discriminant analysis or kernel discriminant analysis. In this paper, we carried out target classification experiments with active sonar target signals available on the Internet using both linear discriminant and generalized discriminant analysis methods. Experimental results are analyzed and compared with discussions. For 104 test data, LDA method has shown correct recognition rate of 73.08%, however, GDA method achieved 95.19% that is also better than the conventional MLP or kernel-based SVM.

키워드 : 소나표적 식별, 선형판별분석, 커널판별분석

Key word : Sonar target classification, linear discriminant analysis, kernel discriminant analysis

Received 15 November 2017, Revised 29 November 2017, Accepted 05 December 2017

* Corresponding Author Keunsung Bae(E-mail:ksbae@ee.knu.ac.kr, Tel:+82-53-950-5527)

School of Electronics Engineering, Kyungpook National University, Daegu 41566, Korea

Open Access <http://doi.org/10.6109/jkice.2018.22.1.125>

print ISSN: 2234-4772 online ISSN: 2288-4165

©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

수중 표적을 탐지하고 식별하는 문제는 군사적 또는 비군사적 관점에서 중요한 연구주제로 이에 관련된 많은 연구가 꾸준히 진행되고 있다[1-4]. 그러나 실제 수중환경에서의 소나 표적신호 수집에는 시간과 비용 측면에서 많은 어려움이 있으므로 표적모델을 이용한 합성신호를 이용하거나 수조, 호수 등과 같은 제한적인 환경에서 획득한 데이터가 주로 사용된다. Gorman 과 Sejnowski[1]는 해수면 바닥에 놓인 2 종류의 표적에 대해 수집한 능동소나의 반향신호를 이용하여 수중에서의 표적 식별을 위한 실험을 수행하였었는데, 그때 사용한 표적신호의 특징벡터 데이터가 기계학습 분야의 연구자를 위한 인터넷 사이트 UCI machine learning repository[5]의 데이터베이스에 포함되어 있다. 본 연구에서는 UCI 소나 데이터를 이용하여 표적 식별 실험을 수행한다.

선형판별분석(LDA: Linear Discriminant Analysis)는 2개 이상의 클래스를 구분하는데 사용가능한 식별 기법으로서, 클래스 내의 특징벡터들의 분산을 최소화하고 클래스 사이의 분산을 최대화하는 축으로 특징벡터를 사영(projection)시켜 식별을 용이하게 하는 방법이다. 그러나 LDA는 각각의 클래스를 단일 가우시안 분포로 모델링하기 때문에 일반적으로 선형으로 분리가 불가능한 문제에 대해서는 좋은 인식 성능을 기대하기가 어렵다. 이러한 LDA의 단점을 보완하기 위하여 커널 함수를 사용하여 입력 특징벡터를 고차원의 공간으로 사상시켜줌으로써 선형 분리가 가능하도록 만들 수 있는데, 이를 일반화된 판별분석(GDA: Generalized Discriminant Analysis) 또는 커널 판별분석(KDA: Kernel Discriminant Analysis) 기법이라고 한다[6,7].

본 논문에서는 2개 클래스에 대한 특징벡터들로 구성된 UCI 소나 표적 데이터에 대해 LDA 및 GDA 기법을 이용하여 식별 실험을 수행하고, 그 결과를 비교/분석하였다. 본 논문의 구성은 다음과 같다. 먼저 2장에서는 LDA 기법의 기본 개념 및 주요 수식에 대해 설명하고, 이를 확장하여 GDA 기법에 대해 간략하게 기술한다. 3장에서는 UCI 표적 데이터에 대한 설명과 함께 식별 실험 및 그 결과를 제시하고 분석하며, 끝으로 4장에서 결론을 맺는다.

II. LDA 및 GDA를 이용한 식별

2.1. LDA 및 GDA를 이용한 식별

식별하고자 하는 클래스가 2개 인 이진분류 문제에서, d 차원을 갖는 특징벡터를 \mathbf{x} 라고 하면, 각 클래스의 평균 벡터는 식 (1)과 같이 계산 된다.

$$\mathbf{m}_i = \frac{1}{L_i} \sum_{\mathbf{x} \in D_i} \mathbf{x}, \quad i = 1, 2 \quad (1)$$

여기서 i 는 클래스의 번호이고 L_i 는 각 클래스의 표본 개수이며 D_i 는 각 클래스의 집합을 의미한다.

클래스 내의 분산(within-class-scatter) \mathbf{S}_W 와 클래스 사이의 분산(between-class-scatter) \mathbf{S}_B 는 식 (2), (3)으로 정의되며, $()^T$ 는 전치행렬을 의미한다.

$$\mathbf{S}_i = \sum_{\mathbf{x} \in D_i} (\mathbf{x} - \mathbf{m}_i)(\mathbf{x} - \mathbf{m}_i)^T, \quad i = 1, 2 \quad (2-a)$$

$$\mathbf{S}_W = \mathbf{S}_1 + \mathbf{S}_2 \quad (2-b)$$

$$\mathbf{S}_B = (\mathbf{m}_1 - \mathbf{m}_2)(\mathbf{m}_1 - \mathbf{m}_2)^T \quad (3)$$

원래의 데이터 \mathbf{x} 가 클래스 내의 분산을 최소화하고 클래스 사이의 분산을 최대화하는 선형판별 축으로 사영된 데이터 \mathbf{y} 는 식 (4)와 같이 표현할 수 있으며, 이때 \mathbf{w} 는 변환 행렬로 \mathbf{w}^T 는 \mathbf{w} 의 전치행렬이다.

$$\mathbf{y} = \mathbf{w}^T \mathbf{x} \quad (4)$$

LDA에서 변환 행렬 \mathbf{w} 를 구하는 방법은 다음과 같다. 식 (4)를 이용하여 사영된 공간에서의 클래스 내의 분산과 클래스 사이의 분산은 식 (5), (6)과 같이 나타낼 수 있으며, 이때 \mathbf{w} 를 구하기 위한 목적함수 J 는 식 (7)과 같이 표현된다[7]. 여기서 “~” 표시는 사영된 공간에서의 값을 의미한다.

$$\tilde{\mathbf{S}}_i = \sum_{\mathbf{y} \in D_i} (\mathbf{y} - \tilde{\mathbf{m}}_i)(\mathbf{y} - \tilde{\mathbf{m}}_i)^T, \quad i = 1, 2 \quad (5-a)$$

$$\tilde{\mathbf{S}}_W = \tilde{\mathbf{S}}_1 + \tilde{\mathbf{S}}_2 \quad (5-b)$$

$$\tilde{\mathbf{S}}_B = (\tilde{\mathbf{m}}_1 - \tilde{\mathbf{m}}_2)(\tilde{\mathbf{m}}_1 - \tilde{\mathbf{m}}_2)^T \quad (6)$$

$$J(\mathbf{w}) = \frac{\tilde{S}_B}{S_W} = \frac{\mathbf{w}^T \tilde{S}_B \mathbf{w}}{\mathbf{w}^T S_W \mathbf{w}} \quad (7)$$

식 (7)에서 목적함수 J 를 최대화 하는 최적의 변환 행렬 \mathbf{w} 는 고유치 해석(eigenvalue analysis)을 통해 식 (8)로 얻어진다.

$$\mathbf{w} = S_W^{-1} (\mathbf{m}_1 - \mathbf{m}_2) \quad (8)$$

앞에서 설명한 LDA 과정을 요약하여 클래스를 식별 하는 과정을 정리하면 다음과 같다.

- ① 주어진 d 차원의 데이터 집합에서 각 클래스의 평균 벡터를 구한다.
- ② 클래스 사이의 분산 행렬(S_B)과 클래스 내의 분산행렬(S_W)을 구한다.
- ③ 고유치 해석을 통해 $S_W^{-1} S_B$ 의 고유치 및 고유벡터를 구한다.
- ④ 고유치가 큰 값을 갖는 순서로 나열하여, 고유치가 큰 순서로 k 개의 d 차원 고유벡터를 얻는다. 2진 분류의 경우에는 $k=1$ 이 된다.
- ⑤ $\mathbf{y} = \mathbf{w}^T \mathbf{x}$ 에 의해 판별축으로 사영된 새로운 데이터에 대해 적절한 문턱치를 설정해 클래스를 분류한다.

2.2. 일반화된 판별분석(GDA)

앞에서 설명한 LDA는 선형적으로 데이터 분리가 어려운 식별 문제에서는 높은 인식 성능을 기대하기 어렵다. 이러한 문제를 해결하기 위해, 입력 특징벡터를 비선형 변환 함수 ϕ 를 이용하여 보다 고차원의 공간으로 사상시키면 새로운 특징벡터 공간 F 에서는 LDA 방식으로 선형 분리가 가능해지는데, 이러한 방식을 GDA 또는 커널판별분석 기법이라고 한다.

비선형 함수를 이용하여 사상된 새로운 특징벡터의 공간 F 에서, 식 (1)-(3) 및 (7)은 식 (9)-(12)로 쓸 수 있다.

$$\mathbf{m}_i^\phi = \frac{1}{L_i} \sum_{\mathbf{x} \in D_i} \phi(\mathbf{x}), \quad i = 1, 2 \quad (9)$$

$$S_i^\phi = \sum_{\mathbf{x} \in D_i} (\phi(\mathbf{x}) - \mathbf{m}_i^\phi)(\phi(\mathbf{x}) - \mathbf{m}_i^\phi)^T \quad (10-a)$$

$$S_W^\phi = S_1^\phi + S_2^\phi \quad (10-b)$$

$$S_B^\phi = (\mathbf{m}_1^\phi - \mathbf{m}_2^\phi)(\mathbf{m}_1^\phi - \mathbf{m}_2^\phi)^T \quad (11)$$

$$J(\mathbf{w}) = \frac{\mathbf{w}^T S_B^\phi \mathbf{w}}{\mathbf{w}^T S_W^\phi \mathbf{w}}, \quad \mathbf{w} \in F \quad (12)$$

GDA 기법에서는 효율적인 계산을 위해 입력 특징벡터를 직접 $\phi(\mathbf{x})$ 로 사상시키지 않고 새로운 특징벡터 공간 F 에서의 내적 계산을 식 (13)과 같이 비선형 커널 함수(kernel function)를 이용하여 구한다. 표 1에 일반적으로 많이 사용되는 커널 함수를 나타내었다.

$$\mathbf{k}(\mathbf{x}, \mathbf{y}) = \phi(\mathbf{x}) \cdot \phi(\mathbf{y}) \quad (13)$$

새로운 특징벡터 공간에서 \mathbf{w} 는 식 (14)와 같이 표현할 수 있으며, 이를 이용하여 식 (15)-(18)을 얻을 수 있다[7]. 여기서 L 은 각 클래스의 표본 개수를 더한 전체 표본 개수, 즉, L_1 및 L_2 를 합한 값이다.

$$\mathbf{w} = \sum_{i=1}^N \alpha_i \phi(\mathbf{x}_i) \quad (14)$$

$$\mathbf{w}^T \mathbf{m}_i^\phi = \frac{1}{L_i} \sum_{j=1}^L \sum_{\mathbf{x} \in D_i} \alpha_j k(\mathbf{x}_j, \mathbf{x}) = \alpha^T \mathbf{M}_i \quad (15)$$

$$\{\mathbf{M}_i\}_j = \frac{1}{L_i} \sum_{\mathbf{x} \in D_i} k(\mathbf{x}_j, \mathbf{x}), \quad 1 \leq j \leq L \quad (16)$$

$$\mathbf{M} = (\mathbf{M}_1 - \mathbf{M}_2) (\mathbf{M}_1 - \mathbf{M}_2)^T \quad (17)$$

$$\mathbf{w}^T S_W^\phi \mathbf{w} = \alpha^T \mathbf{M} \alpha \quad (18)$$

Table. 1 Typical kernel functions

Type	Kernel Function
Polynomial	$k(\mathbf{x}_i, \mathbf{x}_j) = (1 + \mathbf{x}_i \cdot \mathbf{x}_j)^p$
Gaussian(radial-basis function)	$k(\mathbf{x}_i, \mathbf{x}_j) = \exp\left(-\frac{1}{2\sigma^2} \ \mathbf{x}_i - \mathbf{x}_j\ ^2\right)$
Sigmoid	$k(\mathbf{x}_i, \mathbf{x}_j) = \tanh(\beta_0 \mathbf{x}_i \cdot \mathbf{x}_j + \beta_1)$

비슷한 방법으로, 사상된 공간에서 클래스 사이의 분산은 식 (19)-(20)으로 표현된다[7].

$$\mathbf{w}^T S_B^\phi \mathbf{w} = \alpha^T \mathbf{N} \alpha \quad (19)$$

$$N_i = K_i (I - 1_{L_i}) K_i \quad (20-a)$$

$$N = N_1 + N_2 \quad (20-b)$$

여기서 K_i 는 $L \times L_i$ 행렬로서, i 는 클래스 번호를 의미하며, K_i 의 (n 행, m 열) 성분은 식 (21)과 같다.

$$\{K_i\}_{nm} = k(x_n, x_m^i), \begin{cases} 1 \leq n \leq L \\ 1 \leq m \leq L_i \end{cases} \quad (21)$$

따라서 식 (12)는 식 (22)로 표현되며, LDA의 식 (8)과 같이 고유치 해석을 통해 식 (23)을 얻을 수 있으며, 최종적으로 입력 데이터 \mathbf{x} 에 대해 판별축으로 사영된 공간에서의 값은 식 (24)로 얻어진다.

$$J(\alpha) = \frac{\alpha^T M \alpha}{\alpha^T N \alpha}, \quad \alpha \in F \quad (22)$$

$$\alpha = N^{-1} (M_2 - M_1) \quad (23)$$

$$y(\mathbf{x}) = \sum_{i=1}^L \alpha_i k(x_i, \mathbf{x}) \quad (24)$$

III. 실험 및 검토

실험에 사용된 UCI 데이터는 해저 모래바닥에 위치한 대략 1.5m 크기의 금속 실린더(cylinder)와 실린더 형태의 바위에 맞고 반사된 LFM(Linear Frequency Modulated) 반향신호의 단구간푸리에변환(STFT: Short Time Fourier Transform)에서 그림 1과 같이 시간-주파수 평면에서 창함수(window function)를 적용하여 구한 파워스펙트럼 값을 0과 1사이 값으로 정규화 하여 얻은 60차의 특징벡터로 구성된다[2]. 전체 데이터는 표적의 다양한 방향에서 수집된 금속 실린더의 반향신호 111개와 실린더 형태의 바위에 의한 반향신호 97개로, 총 208개의 반향신호에 대한 특징벡터들로 구성되어 있는데, 식별 실험의 훈련과 테스트에 사용될 수 있도록 각각 104개의 훈련 데이터와 테스트 데이터가 나누어져 있다. 훈련 데이터는 금속 실린더의 반향신호에서 얻은 49개의 특징벡터와 실린더 형태의 바위에서 얻은 55개의 특징벡터로 구성되어 있고, 테스트 데이터는 금속




Fig. 1 Feature vector extraction of UCI sonar data [1]
(a) Spectrogram of the sonar return
(b) 60-dimension average power spectrum

실린더에서 얻은 62개의 특징벡터와 바위에서 얻은 42개의 특징벡터로 구성되어 있다. 소나 표적신호 식별 실험에는 LDA 및 [8]에 주어진 GDA 프로그램을 분석하여 사용하였는데, σ^2 값으로 0.5를 갖는 가우시안 커널 함수를 사용하였다.

Table. 2 Experimental results using LDA (training data)

Class	Metal	Rock
Metal	42/49(85.71%)	6/55(10.91%)
Rock	7/49(14.29%)	49/55(89.09%)

Table. 3 Experimental results using LDA (test data)

Class	Metal	Rock
Metal	46/62(74.19%)	12/42(28.57%)
Rock	16/62(25.81%)	30/42(71.43%)

표 2와 3은 각각 훈련 데이터와 테스트 데이터에 대해 LDA 기법을 이용한 식별실험 결과이다. 표 2에서 보면, 훈련 데이터를 이용한 식별 결과에서도 12.5%의 오인식률을 보이는데 이를 통해 주어진 UCI 소나 데이터는 선형적으로 분리가 어려움을 알 수 있다. 표 3의 테스트 데이터에 대한 식별 결과는 26.92%의 오인식률, 즉, 73.08%의 인식률을 보이는데, 이것은 MLP 또는 커널함수를 사용한 SVM과 같은 패턴인식 기법을 이용했을 경우의 88.37%, 91.34% 인식률에 비해 성능이 많이 떨어짐을 볼 수 있다[5].

그림 2(a)는 훈련 데이터의 특징벡터 104개에 GDA 기법을 적용하여 얻은 변환 행렬을 이용하여 판별축에 사영된 값을 보인 것인데, 특징벡터 번호 1 ~ 49는 금속

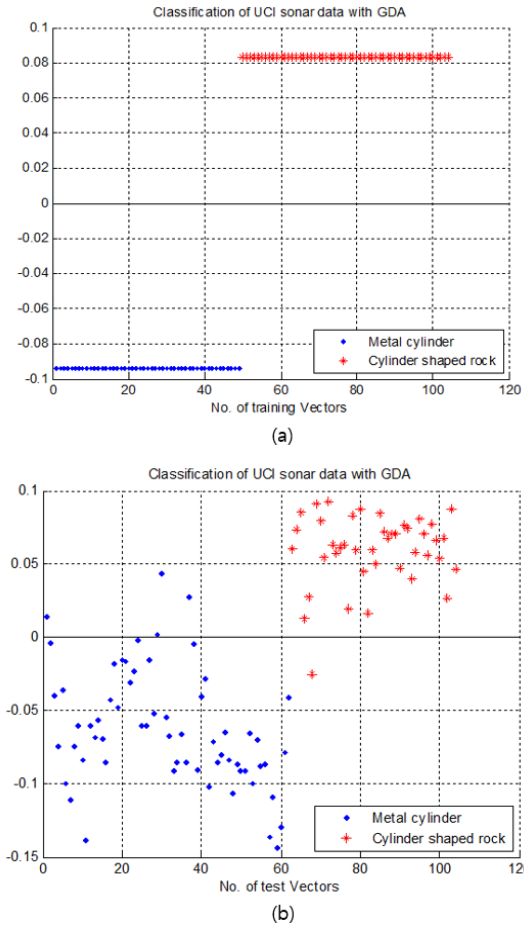


Fig. 2 (a) Projected value of training data using GDA, (b) projected value of test data using GDA

실린더의 반향신호이며, 55 ~ 104는 실린더 형태의 바위 반향신호로 두 클래스가 확연히 구분됨을 볼 수 있다. 그림 2(b)는 훈련 데이터에서 구한 변환 행렬을 테스트 데이터에 적용하여 판별축에 사영된 값을 보인 것으로 특징벡터 번호 1 ~ 62는 금속실린더, 63 ~ 104는 바위에 의한 반향신호로 두 클래스가 잘 분리됨을 볼 수 있다.

표 4와 5는 GDA 기법을 적용한 경우의 식별 실험 결과이다. 표 4는 훈련 데이터에 GDA 기법을 적용한 경우로 그림 2(a)에서 볼 수 있듯이 100%의 인식률이 얻어졌음을 볼 수 있는데, 이것은 GDA의 경우 적절한 커널 함수를 사용하여 새로운 특징벡터 공간에서는 비

선형 분리가 가능해졌으며, 또한 실험에 사용된 데이터의 클래스가 2개로 별로 크지 않기 때문이라고 생각한다. 표 5는 테스트 데이터에 GDA 기법을 적용한 경우로 95.19%의 인식률을 얻었는데, MLP 또는 커널함수를 사용한 SVM의 결과보다 높은 인식률을 얻을 수 있었다.

Table. 4 Experimental results using GDA (training data)

Class	Metal	Rock
Metal	49/49(100%)	0/55(0%)
Rock	0/49(0%)	55/55(100%)

Table. 5 Experimental results using GDA (test data)

Class	Metal	Rock
Metal	58/62(93.55%)	1/42(2.38%)
Rock	4/62(6.45%)	41/42(97.62%)

IV. 결 론

본 논문에서는 UCI의 소나 데이터에 대해 LDA 및 GDA 기법을 이용하여 표적 식별 실험을 수행하였다. LDA 기법은 클래스 사이의 거리가 최대화 되도록 훈련 데이터에 대해서 식별 성능을 최대화하는데, 데이터의 특성이 선형적으로 분리가 어려울 경우에는 좋은 성능을 얻기 어렵다.

따라서 LDA 기법에 커널 함수를 적용한 GDA를 이용하여 UCI 소나 데이터의 인식 실험을 수행하고 그 결과를 제시하였다. 실험결과 적절한 커널 함수를 적용한 GDA 기법에서는 MLP 또는 SVM과 같은 패턴인식 기법과 비교하여 그에 상응하거나 높은 인식 성능을 얻을 수 있음을 보였다.

ACKNOWLEDGEMENTS

This work was supported by Agency of Defense Development under the contract UD160001DD.


REFERENCES

- [1] R. P. Gorman, T. J. Sejnowski, "Analysis of hidden units in a layered network trained to classify sonar targets," *Neural Networks*, vol. 1, no 1, pp. 75-89, Jan, 1988.
- [2] Jongwon Seok, "Multi-aspect Based Active Sonar Target Classification," *Journal of Korea Multimedia Society*, vol. 19, no. 10, pp. 1775-1781, Oct, 2016.
- [3] J. W. Seok, K. S. Bae, "Target Classification Using Features Based on Fractional Fourier Transform," *IEICE Trans. Information and Systems*, vol. E97-D, no. 9, pp. 2518-2521, Sep, 2014.
- [4] J. H. Park, C. S. Hwang, and K. S. Bae, "Analysis of target classification performances of active sonar returns depending on parameter values of SVM kernel functions," *Journal of the Korea Institute of Information and Communication Engineering*, vol. 17, no. 5, pp. 1083-1088, 2013.
- [5] UCI Machine Learning Repository: Connectionist Bench (Sonar, Mines vs. Rocks) Data Set [Internet]. Available: [http://archive.ics.uci.edu/ml/datasets/connectionist+bench+\(sonar,+mines+vs.+rocks\)/](http://archive.ics.uci.edu/ml/datasets/connectionist+bench+(sonar,+mines+vs.+rocks)/).
- [6] G. Baudat, F. Anouar, "Generalized Discriminant Analysis Using a Kernel Approach," *Neural Computation*, vol. 12, no. 10, pp. 2385-2404, Oct, 2000.
- [7] Kernel Fisher discriminant analysis - Wikipedia [Internet]. Available: https://en.wikipedia.org/wiki/Kernel_Fisher_discriminant_analysis, edited on 22 Jan, 2017.
- [8] <http://www.kernel-machines.org/software>.



김동욱(Dong-wook Kim)

2010년 8월 경북대학교 전자공학부 석사
2013년 9월 ~ 현재 경북대학교 전자공학부 박사과정
※관심분야 : 수중음향신호처리, 디지털신호처리, 패턴인식 등



김태환(Tae-hwan Kim)

2008년 2월 경북대학교 전자공학과 석사
2013년 8월 경북대학교 전자공학과 박사
2014년 ~ 현재 국방과학연구소 선임연구원
※관심분야 : 수중음향신호처리, 디지털신호처리, 음성신호처리, 패턴인식 등



석종원(Jong-won Seok)

1995년 경북대학교 전자공학과 석사
1999년 경북대학교 전자공학과 박사
2004년 ~ 현재 창원대학교 정보통신공학과 부교수
※관심분야 : 디지털신호처리, 수중음향신호처리, 패턴인식, 디지털콘텐츠보호관리 등



배건성(Keun-sung Bae)

1977년 2월 서울대학교 전자공학과 학사
1979년 2월 한국과학기술원 전기 및 전자공학과 석사
1989년 5월 University of Florida 공학박사
1979년 ~ 현재 경북대학교 전자공학부 교수
※관심분야 : 음성신호처리, 디지털신호처리, 적응필터링, 패턴인식, 소나/레이더신호처리 등