

커널 이완 절차에 의한 커널 공간의 저밀도 표현 학습

Sparse Representation Learning of Kernel Space Using the Kernel Relaxation Procedure

류재홍 · 정종철

Jae Hung Yoo and Jong Cheol Jeong

여수대학교 컴퓨터공학과

요약

본 논문은 분류 문제의 훈련 패턴으로부터 형성되는 커널 공간의 저밀도 표현을 가능하게 하는 커널 방법에 대한 새로운 학습방법론을 제안한다. 선형 판별 함수에 대한 기존의 학습법 중에서 이완 절차가 SVM(Support Vector Machine) 분류기와 동등하게 선형분리 가능 패턴분류 문제의 최대 마진 분리 초평면을 얻을 수 있다. 기존의 이완 절차는 지원 벡터에 대한 필요 조건을 만족한다. 본 논문에서는 학습 중 지원 벡터를 확인하기 위한 충분 조건을 제시한다. 순차적 학습을 위하여 기존의 SVM을 확장하고 커널 판별함수를 정의한 후에 체계적인 학습방법을 제시한다. 실험 결과는 새 방법이 기존의 방법과 동등하거나 우수한 분류 성능을 갖고있음을 보여준다.

Abstract

In this paper, a new learning methodology for kernel methods that results in a sparse representation of kernel space from the training patterns for classification problems is suggested. Among the traditional algorithms of linear discriminant function, this paper shows that the relaxation procedure can obtain the maximum margin separating hyperplane of linearly separable pattern classification problem as SVM(Support Vector Machine) classifier does. The original relaxation method gives only the necessary condition of SV patterns. We suggest the sufficient condition to identify the SV patterns in the learning epochs. For sequential learning of kernel methods, extended SVM and kernel discriminant function are defined. Systematic derivation of learning algorithms is introduced. Experiment results show the new methods have the higher or equivalent performance compared to the conventional approach.

Key Words : Sparse Representation, Kernel Space, Kernel Discriminant Function, Kernel Hyperplane, Kernel Relaxation

1. 서론

본 논문은 패턴 분류 문제에 대한 기법 중 SVM(Support Vector Machine)과 RBF(Radial Basis Function) 신경회로망 등 커널 방법(Kernel Methods)으로 패턴 가중치를 학습하는 과정에서 가중치가 영(zero)인 훈련 패턴이 되도록 많이 생성되도록 하는 것이 목표인 저밀도 표현(Sparse Representation)의 새로운 학습방법을 소개한다.

기존의 SVM은 2진 분류 문제에 대하여 입력 공간에서 선형 분류 함수의 분류 초평면에 대한 최대 분류 마진(Maximum Margin of Separation)과 지원 벡터(Support Vector)를 정의하고 입력 패턴 가중치 벡터의 크기를 최소화하는 제한적 최적화 문제(Constrained Optimization Problem)를 제안하였다[4]. 이것은 Lagrange 제2공간

(Dual Space)에서 QP(Quadratic Programming)문제가 된다. SVM은 QP의 해로써 훈련 패턴 가중치를 결정하는 일괄 처리 방식(Batch Mode Processing)이다.

하지만 QP는 연산과 메모리 복잡도가 크다는 단점을 갖고 있다. 이러한 문제점을 해결하기 위해서 Chunking, Active Set 등 QP 분해방법(Decomposition Method)과 최대 강하/상승(Steepest Descent/Ascent) 방법, Relaxation 등 각 훈련 패턴에 대하여 학습하는 방법이 소개되었다[5,6,7,8,9].

특히 ROMMA[9]는 본 논문과 사용하는 기존의 Relaxation과 가장 유사한 방법이다. ROMMA는 가중치 공간(Weight Space)에서 현재의 가중치 벡터에 의한 반공간(Halfspace) 영역을 정의하고 최대 분류 마진에 상응하는 최소 가중치 벡터 학습에 이용하였으나 수렴시 가중치 수정횟수는 기존의 Relaxation 학습 방법[1]과 동일한 상한선(Upper Bound)을 갖는다.

기존의 선형 판별 함수(LDF - Linear Discriminant Function) 학습 방법 중에서 (Perceptron, Relaxation, LMS-Least Mean Squared, Pseudoinverse)[1] SVM의 최대 분류 마진을 갖는 초평면을 Relaxation, Perceptron with Margin 등 마진 분류기(Margin Classifier)는 찾을 수 있다는 것을 본 논문에서 처음으로 밝힌다. SVM의

접수일자 : 2001년 12월 21일

완료일자 : 2001년 12월 21일

감사의 글 : 본 논문은 과학기술부 · 한국과학재단 지정 여수대학교 설비자동화 및 정보시스템 연구개발센터의 연구비지원에 의한 것임.

공간도는 제2 공간(Dual Space) 또는 커널 공간에서 제 대로 분류되는 훈련 패턴의 가중치를 영으로 둠으로써 성립 표현 또는 저 밀도 표현을 가능하게 한 것이다.

기존의 Relaxation 방법은 SV 패턴을 학습하는데 필요 조건(Necessary Condition)을 만족시킨다. 본 논문에서는 SV 패턴을 찾는 것에 대한 충분 조건(Sufficient Condition)을 제안하여 수정된 Relaxation 학습법이 최대 분류 마진을 갖는 초평면을 찾을 수 있도록 한다.

본 논문은 커널 공간에서 kernel 행렬을 패턴 행렬로 해석하는데 SVM의 QP의 Lagrange 승수 벡터(multiplier vector)는 패턴 가중치가 된다. 따라서 선형 판별 함수의 모든 학습 방법들을 그대로 커널 공간에 적용할 수 있다. 일반적으로 논의되는 특징 공간(Feature Space은 내적 커널(Inner Product Kernel))[2] 형성에 대한 유효성 해석에 필요한 것이고 실제 학습 방법에 관해서는 본 논문에서 소개하는 커널 공간, 커널 초평면, 커널 판별함수 등의 개념이 중요한 것이다.

2. 배경 연구

먼저 SVM과 선형판별 함수 학습 방법에 대해 검토하고 본 논문에서 제안하는 수정된 Relaxation 학습에 의한 최대 분류 마진과 SV 패턴 학습법을 다음에 논의하고, 커널 공간에서의 저밀도 표현 학습과 실험 결과를 차례대로 소개한다. 정확성을 기하기 위하여 필요한 용어를 정의한다. 주어진 N개의 훈련 패턴은 m차원 행 벡터 $x_i, (i=1, \dots, N)$ 와 패턴 행렬 $X = [x_1, x_2, \dots, x_N]$ 을 정의한다. 이진 분류 문제에서 목표치는 $d_i \in \{+1, -1\}, i=1, \dots, N$ 이고 목표치 벡터는 $d = [d_1, d_2, \dots, d_N]^T$ 가 된다. 선형 판별 함수 또는 선형 문턱 함수(Linear Threshold Function)는 다음과 같다.

$$g(\mathbf{x}) = \mathbf{w}^t \mathbf{x} + w_0 \quad (1)$$

여기서 w 는 m차원 가중치 벡터이고 w_0 는 바이어스(Bias Term) 또는 문턱 값(Threshold value)이다. 주어진 입력 패턴을 확장하면(augmented) m+1차원 동형 좌표 공간(Homogeneous Coordinate Space)의 $y = [x, 1]^T$ 가 된다. 확장된 패턴 행렬은 $Y = [y_1, y_2, \dots, y_N]^T$ 가 된다. 가중치벡터는 $\mathbf{a} = [w, w_0]^T$ 가 된다. 따라서 선형 판별식은 다음과 같다.

$$g_a(\mathbf{y}) = \mathbf{a}^t \mathbf{y} \quad (2)$$

선형 내적 커널과 그의 확장형은 각각 $X^t X$ 와 $Y^t Y$ 가 된다.

2.1 원본 SVM 와 확장된 SVM 분류기(Classifier)

패턴에서 분리 초평면까지의 거리는 다음과 같다.

$$\frac{d_i g(\mathbf{x}_i)}{\|\mathbf{w}\|} \geq r, \quad i=1, \dots, N \quad (3)$$

선형 판별식에서 분리 초평면은 다음 식을 만족한다.

$$d_i g(\mathbf{x}_i) \geq b, \quad i=1, \dots, N \quad (4)$$

식 3과 4에서 $b = r \|\mathbf{w}\|$ 놓으면, 식 1과 3의 해는

가중치 벡터 w 를 최소화한다.

$$L(\mathbf{w}, \mathbf{a}) = \frac{\|\mathbf{w}\|^2}{2} - \sum_{i=1}^N a_i [d_i g(\mathbf{x}_i) - b] \quad (5)$$

여기서 KT(Khun-Tucker)조건[3]을 사용하면 제2공간에서 QP문제가 성립한다.

$$L(\mathbf{a}) = b \sum_{i=1}^N a_i - \frac{1}{2} \sum_{i,j=1}^N a_i a_j d_i d_j \mathbf{x}_i^t \mathbf{x}_j \quad (6)$$

식 6은 다음의 제한 조건(Constraints)을 갖는다.

$$\sum_{i=1}^N a_i d_i = 0, \quad a_i \geq 0, \quad i=1, \dots, N \quad (7)$$

원본 SVM[4]에서는 바이어스 항을 별도로 구하는 불편을 감수하는데 가중치와 바이어스 항을 함께 최소화하기 위해 확장된 입력 공간에서 패턴으로부터 분리 초평면까지의 거리를 구하면 다음과 같다[1, 9].

$$\frac{d_i g(\mathbf{x}_i)}{\|\mathbf{w}\|} \geq \frac{d_i g_a(\mathbf{y}_i)}{\|\mathbf{a}\|} \geq r_a, \quad i=1, \dots, N \quad (8)$$

식 4를 변형하면 다음과 같다.

$$d_i [d_i * b - g_a(\mathbf{y}_i)] \leq 0, \quad i=1, \dots, N \quad (9)$$

확장 가중치 벡터 \mathbf{a} 를 최소화하면 식 5는 다음과 같이 변한다.

$$L(\mathbf{a}, \mathbf{a}) = \frac{\|\mathbf{a}\|^2}{2} - \sum_{i=1}^N a_i d_i [d_i * b - \mathbf{a}^t \mathbf{y}_i] \quad (10)$$

여기서 KT(Khun-Tucker)조건[3]을 사용하고 $a_i d_i$ 를 a_i 로 놓으면 제2공간에서 QP문제가 성립한다.

$$L(\mathbf{a}) = b \sum_{i=1}^N d_i a_i - \frac{1}{2} \sum_{i,j=1}^N a_i a_j \mathbf{y}_i^t \mathbf{y}_j \quad (11)$$

식 11을 행렬로 표기하면 다음과 같다.

$$L(\mathbf{a}) = b \mathbf{d}^t \mathbf{a} - \frac{1}{2} \mathbf{a}^t \mathbf{Y}^t \mathbf{Y} \mathbf{a} \quad (12)$$

식 11, 12는 다음의 제한 조건(Constraints)을 갖는다.

$$a_i d_i \geq 0, \quad i=1, \dots, N \quad (13)$$

즉 식 7에서 등식이 제거된 것이다. 이것은 4장에서 소개하는 SVM에 대한 순차 학습(Sequential Learning)을 가능하게 한다. 식 9 이후에서 $b=1$ 로 하고 오차 항을 넣고 부등호를 등호로 치환하면 회귀문제에도 공히 적용할 수 있으나 LMS 학습법을 사용한다.

2.2 선형 판별함수 학습법

Perceptron은 잘못 분류된 훈련 패턴에 대하여 가중치를 학습한다.

$$\mathbf{a}(k+1) = \mathbf{a}(k) + d_k \mathbf{y}(k) \quad (14)$$

until $d_k g_a(\mathbf{y}_k) \geq 0, k=1, \dots, N$

Perceptron with Margin은 마진 이하로 학습된 훈련

패턴에 대하여 가중치를 학습한다.

$$\begin{aligned} \mathbf{a}(k+1) &= \mathbf{a}(k) + \eta(k) d_k \mathbf{y}(k) \\ \text{until } d_k g_a(\mathbf{y}_k) &\geq b > 0, k=1, \dots, N \end{aligned} \quad (15)$$

Relaxation도 마찬가지로 학습된 훈련 패턴에 대하여 가중치를 학습한다.

$$\begin{aligned} \mathbf{a}(k+1) &= \mathbf{a}(k) + \\ \eta(k) \frac{[d_k * b - \mathbf{a}^t \mathbf{y}(k)]}{\|\mathbf{y}(k)\|^2} \mathbf{y}(k) \\ \text{until } d_k g_a(\mathbf{y}_k) &\geq \gamma > 0, k=1, \dots, N \end{aligned} \quad (16)$$

Perceptron은 선형 분리 가능한 문제에 대하여 수렴시 가중치 수정횟수는 다음과 같은 상한선(Upper Bound)을 갖는다[1].

$$k_o = \frac{\beta^2 \|\mathbf{a}\|^2}{\gamma^2} \quad (17)$$

여기서

$$\begin{aligned} \beta &= \arg \max_i \|\mathbf{y}_i\|, \\ \gamma &= \arg \min_i d_i * \hat{\mathbf{a}}^t \mathbf{y}_i \end{aligned} \quad (18)$$

Perceptron with Margin은 다음의 상한선을 갖는다.

$$k_o = \frac{\beta^2 \|\hat{\mathbf{a}}\|^2}{b^2} \quad (19)$$

Relaxation 은 다음의 상한선을 갖는다.

$$k_o = \frac{\beta^2 \|\hat{\mathbf{a}}\|^2}{(b-\gamma)^2} \quad (20)$$

따라서 Relaxation은 $b = \gamma$ 인 경우 수렴시간이 오래 걸릴 것을 알 수 있다. 식 16과 20에서 γ 을 조정하면 ($\gamma=0$) Perceptron과 동등한 유한한 수렴 상한선을 얻을 수 있다.

3. Relaxation에 의한 SV 패턴 학습법

식 4와 식 15, 16을 비교하면 SVM에서 요구하는 조건과 Perceptron with Margin과 Relaxation에서의 학습 종결 조건이 동등함을 알 수 있다. 그러나 완전한 학습을 위하여 SV 패턴에 대한 세밀한 정의가 필요하다.

정의 1. : Support Vector는 다음의 조건들을 만족하는 훈련 패턴이다.

1. $SVs = \{ \mathbf{y}_i : d_i g_a(\mathbf{y}_i) = \gamma \pm \epsilon > 0 \}$,
where ϵ is a positive constant
2. Cardinality(SVs) = $N_s \geq 2$,
3. $|\sum_i d_i| < N_s$

이것을 풀이하면 1번 조건은 기존의 마진 학습방법에서 과도한 학습 결과에 만족하여 종결하는 것을 배제한다. 2, 3번 조건은 각 패턴 클래스에 적어도 하나 이상의

SV가 존재해야 한다는 것이다. 상기 3조건을 모두 만족해야 학습이 종료된다.

4. 커널 판별 함수와 저밀도 표현 학습법

식 12를 \mathbf{a} 에 관하여 미분하면 다음과 같다.

$$\begin{aligned} \frac{\partial L(\mathbf{a})}{\partial \mathbf{a}} &= b \mathbf{d} - \mathbf{Y}^t \mathbf{Y} \mathbf{a} = \mathbf{0}, \\ \mathbf{d} &= \mathbf{Y}^t \mathbf{Y} \mathbf{a} / b \end{aligned} \quad (22)$$

마진 b를 1로 놓고 확장된 선형 내적 커널 $\mathbf{Y}^t \mathbf{Y}$ 를 비선형 내적 커널 \mathbf{K} 로 치환하면 다음과 같다.

$$\mathbf{g}_k(\mathbf{Y}) = \mathbf{K}^t \mathbf{a} = \mathbf{a}^t \mathbf{K} = \mathbf{d} \quad (23)$$

여기서 커널을 패턴 행렬로 커널의 각 행 또는 열은 패턴 벡터로 해석하면 SVM의 QP의 Lagrange 승수 벡터 \mathbf{a} 는 패턴 가중치가 된다.

$$g_k(\mathbf{y}_j) = \mathbf{a}^t \mathbf{K}(:, j) = \mathbf{K}(j, :) \mathbf{a} \quad (24)$$

커널 공간과 커널 판별 함수, 커널 초평면 등이 정의된 것이다. 커널 공간은 내적 커널 공간(입력공간 또는 특징공간)의 제2 공간이다. 따라서 선형 판별 함수의 모든 학습 방법들을 그대로 커널 공간에 적용할 수 있다. 저밀도 표현 학습을 위하여 가중치가 식 13을 만족하도록 한다.

입력 공간의 판별함수 식 2를 벡터 함수로 정리하면 다음과 같다.

$$\mathbf{g}_a(\mathbf{Y}) = \mathbf{Y}^t \mathbf{a} = \mathbf{d} \quad (25)$$

입력 공간은 미지수의 개수가 $m+1$ 이고 방정식은 N 개인 과잉 결정 시스템(Over Determined System)이고($N \gg m+1$)이고 커널 공간은 미지수와 방정식 개수가 동일한 N 개로 완전 결정 시스템(Exactly Determined System)이다. 따라서 커널공간에서는 커널의 역 행렬이 정상이면(Non-singular and Well-posed) 식 23의 해가 유용하다. 모든 패턴이 SV가 될 수 있다.

커널 공간에서 커널 초평면에 대한 저밀도 표현과 SV 패턴 학습을 위한 수정된 커널 이완 방법(KR)은 다음 표 1과 같다.

표 1. 수정된 커널 이완 방법

Table 1. Modified KR(Kernel Relaxation) procedure.

```

Initialize  $\mathbf{a} = \mathbf{0}$ ,  $\eta(\cdot)$ , margin  $b$ ,  $\gamma > 0$ 
do /* for each epoch */
  Shuffling the training data using index.
  // Relaxation
  for  $j = 1, \dots, N$ 
     $k = \text{index}(j)$  // from shuffling
    if  $d_k \mathbf{a}^t \mathbf{K}(:, k) \leq \gamma$ 
      if  $d_k(\mathbf{a}(k)|_k + \Delta \mathbf{a}(k)|_k) < 0$ 
         $\mathbf{a}_k = 0$ 
      else
  
```

```

 $\alpha(k+1) = \alpha(k) +$ 

$$\eta(k) \frac{d_k b - \alpha^t \mathbf{K}(:, k)}{\|\mathbf{K}(:, k)\|^2} \mathbf{K}(:, k)$$

endif
else
 $\alpha_k = 0$ 
endif
end for
// SV maintenance
for k = 1, ..., N
    Update and check for SV condition.
end for
until  $d_k \alpha^t \mathbf{K}(:, k) > \gamma$  for all k
and SV condition is true.
Return  $\alpha$ 
    
```

커널 최대 강하/ 상승(Steepest Descent/Ascent) 방법(KSD)은 다음과 같다.

$$\Delta \alpha = \eta(\mathbf{d} - \alpha^t \mathbf{K}) \quad (26)$$

각 패턴 \mathbf{y}_j 에 대하여 α_j 를 학습하는 KA와 SVMseq[7, 8]는 최대 강하 학습법이 아니고 좌표 강하(Coordinate Descent)방법이다[3].

$$\Delta \alpha_j = \eta(d_j - \alpha^t \mathbf{K}(:, j)) \quad (27)$$

이에 반하여 RBF 신경회로망의 델타 규칙은 커널 LMS(KLMS) 방법이다.

$$\Delta \alpha = \eta(d_j - \alpha^t \mathbf{K}(:, j)) \mathbf{K}(:, j) \quad (28)$$

커널 Perceptron(KP)은 이미 퍼텐셜 함수(Potential Function) 학습법으로 소개되었다[1].

$$\Delta \alpha = \eta d_j \mathbf{K}(:, j) \quad (29)$$

이상으로 Duda의 고전에서 제기한 퍼텐셜 함수 학습 방법들을 모두 완성하게 되었다[1].

5. 실험 결과

첫 번째 실험은 표준 XOR 문제에 45개의 데이터를 추가하여 기존의 4개의 표준 패턴만을 SV 패턴으로 선정하는지 조사하여 저밀도 학습이 가능한가를 KA와 수정된 KR에 QP결과를 비교하였다. 그림1, 2, 3을 보면 KA는 19개의 SV패턴을 학습하였다. 수정된 KR과 QP는 최소 개수인 4개의 SV 패턴과 경계면을 동등하게 학습하였다.

두 번째 실험은 일반화 능력 평가이다. 신경회로망 분류기 표준 평가 데이터인 SONAR 분류문제를 갖고 실행하였다[9]. SONAR 데이터의 개수는 208개로 금속 원통의 지뢰와 암석에서 반사되는 SONAR 파형 패턴으로 차원은 60이다. 처음 104개의 데이터는 훈련데이터로 나머지 104개는 평가 데이터로 쓰였다. 표 2는 KA, KLMS와

수정된 KR 방법의 수행 능력을 보여주고 있다.




그림 1. 확장 XOR 문제에 대한 QP 학습결과
Fig 1. OP learning results for the EXOR (extended exclusive or) problem




그림 2. 확장 XOR 문제에 대한 KA 학습결과
Fig 2. KA learning results for the EXOR problem




그림 3. 확장 XOR 문제에 대한 수정된 KR 학습결과
Fig 1. KR learning results for the EXOR problem

표 2. SONAR 분류 문제에 대한 수정된 KR, KLMS, KA 학습결과.

Table 2. Performances of KA, KLMS and KR learning methods for the SONAR classification, problem

Algorithm	Epoch	Training /Test Data Performance	# of SV Patterns
KA	10	100.0/95.19	99
KLMS	20	100.0/94.23	101
KR(b=1, γ=2)	30	100.0/94.23	100
KR(b=1, γ=1.5)	80	100.0/94.23	100
KR(b=1, γ=1.0)	620	94.23/91.35	94
KR(b=1, γ=0.5)	740	89.42/84.62	89
KR(b=1, γ=0.0)	50	80.77/87.50	62

여기서 b 와 γ 는 식 16, 18 과 20에서 언급한 인수로서 KR 의 수렴과 학습 능력에 많은 영향을 미치고 있음을 보여 준다. 수행능력에서는 3 방법 모두 91%이상이며 동등하다. 하지만 KR 방법은 느린 수렴 속도 개선이 풀어야 할 연구과제로 제기된다.

6. 결 론

본 논문은 분류 문제의 훈련 패턴으로부터 형성되는 커널 공간의 저밀도 표현을 위한 커널 방법에 대한 새로운 학습방법론을 제안하였다. 선형 판별 함수학습법 중에서 이완 절차가 SVM 분류기와 동등하게 선형분리 가능 패턴 분류 문제의 최대 마진 분리 초평면을 얻을 수 있다. 이완 절차는 지원 벡터에 대한 필요 조건을 만족한다. 본 논문에서는 학습 중 지원 벡터를 확인하기 위한 충분 조건을 제시하였다. 커널 방법에 대한 순차적 학습을 위하여 기존의 SVM을 확장하고 커널 판별 함수를 정의한 후에 체계적인 학습방법을 제시하였다. 실험 결과는 새 방법이 기존의 방법과 동등하거나 우수한 분류 성능을 갖고 있음을 보여준다. 향후 연구과제로는 가중치 수정 횟수 상한선 식과 실험결과에서 확인된 이완 절차의 느린 수렴속도의 획기적 향상문제가 대두된다. 본 논문에서 정립한 지원 벡터의 정의를 응용하는 것이 하나의 접근 방법이 될 것이다.

참 고 문 헌

- [1] R. O. Duda et al., *Pattern Classification and Scene Analysis*, John Wiley & Sons, 1973.
- [2] S. Haykin, *Neural Networks - A Comprehensive Foundation*, 2nd Ed., Prentice-Hall, 1999.
- [3] D. G. Luenberger, *Linear and Nonlinear Programming*, 2nd Ed., Addison-Wesley, 1984.
- [4] B. E. Boser, et al., "A Training Algorithm for Optimal Margin Classifiers," in *Proc. of the 5th Annual Workshop on Computational Learning Theory* 5, pp. 144-152, Pittsburgh, 1992.
- [5] E. Osuna, et al., "Training Support Vector Machines : an Application to Face Detection." *CVPR'97*, 1997.

- [6] J. C. Platt. "Fast Training of Support Vector Machines using Sequential Minimal Optimization," In *Advances in Kernel Methods - Support Vector Learning*, B. Scholkopf, C. Burges, A. Smola (Eds.), MIT-Press, 1998.
- [7] T. T. Friess et al, "The Kernel-Adatron Algorithm : a Fast and Simple Learning Procedure for Support Vector Machines," *Proc. 15th Intl. Conf. on Machine Learning*, Morgan-Kaufman, 1998
- [8] S. Vijayakumar et al, "Sequential Support Vector Classifiers and Regression", *Int. Conf. Soft Computing*, pp. 610-619 1999.
- [9] Y. Li et al., "The relaxed online maximum margin algorithm." In *Advances in NIPS 13*, 1999.

저 자 소 개



류제홍(Jae Hung Yoo)

1981년 : 한양대학교 기계공학 학사
 1986년 : 디트로이트대 전산학 석사
 1993년 : 웨인주립대 전산학 박사
 1994년~ : 여수대학교 컴퓨터공학과
 부교수

관심분야 : 패턴인식, 신경회로망,
 컴퓨터비전, 영상처리,
 의료영상, 생명정보학



정종철(Jong Cheol Jeong)

2000년 : 여수대학교 컴퓨터공학 학사
 2000년~ : 여수대학교 컴퓨터공학과
 석사과정 재학중

관심분야 : 패턴인식, 신경회로망